

CIENCIA, INCERTIDUMBRE Y CONSTRUCCIÓN CONTEMPORÁNEA DE LA EVIDENCIA

Martha García, Jonathan López,
María Zambrano, Francisco
Espinoza, Ángel Herrera, Mario
Herrera & Franklin Vásquez





CIDPROS
EDITORIAL



Ciencia, incertidumbre y construcción contemporánea de la evidencia

Martha Clemencia García Cifuentes, Jonathan Eduardo
López Poveda, María Andrea Zambrano Delgado,
Francisco Javier Espinoza Huaipatin, Ángel Patricio
Herrera Carrión, Mario Fernando Herrera Venegas &
Franklin Patricio Vásquez Chicaiza





Datos bibliográficos

ISBN	978-9907-848-03-8
Título del libro	Ciencia, incertidumbre y construcción contemporánea de la evidencia
Autores	Martha Clemencia García Cifuentes Jonathan Eduardo López Poveda María Andrea Zambrano Delgado Francisco Javier Espinoza Huaipatin Ángel Patricio Herrera Carrión Mario Fernando Herrera Venegas Franklin Patricio Vásquez Chicaiza
Editorial	CIDPROS EDITORIAL
Materia	001.4 - Investigación
Público objetivo	Profesional / académico
Año	2026
Número de edición	1
Tamaño	3,55Mb
Soporte	Libro digital descargable
Formato	PDF (.pdf)
Idioma	Español
DOI	https://doi.org/10.70577/fa3t4g85
	Hecho en Ecuador / Made in Ecuador

AUTORES

Martha Clemencia García Cifuentes

Investigador Independiente

marthygar@hotmail.com

<https://orcid.org/0009-0006-9970-7154>

Guayaquil, Guayas, Ecuador

Jonathan Eduardo López Poveda

Investigador Independiente

jonathan.elp@hotmail.com

<https://orcid.org/0009-0009-7058-4279>

Guayaquil, Guayas, Ecuador

María Andrea Zambrano Delgado

Investigador Independiente

andreazambdel@hotmail.com

<https://orcid.org/0009-0009-5314-2807>

Portoviejo, Manabí, Ecuador

Francisco Javier Espinoza Huaipatin

Investigador Independiente

fjespinoza9@gmail.com

<https://orcid.org/0009-0001-9393-4333>

Quito, Pichincha, Ecuador

Ángel Patricio Herrera Carrión

Investigador Independiente

hererapato@gmail.com

<https://orcid.org/0009-0001-5501-6988>

Tena, Napo, Ecuador

Mario Fernando Herrera Venegas

Investigador Independiente

einsamkeit83@hotmail.com

<https://orcid.org/0000-0003-1874-7295>

Guayaquil, Guayas, Ecuador


Franklin Patricio Vásquez Chicaiza

Investigador Independiente

vchfpdv@gmail.com

<https://orcid.org/0009-0009-8333-6055>

Quito, Pichincha, Ecuador



El contenido y las ideas expuestas en esta obra se encuentran protegidos por la normativa vigente en materia de propiedad intelectual y constituyen derechos exclusivos de su(s) autor(es).

Derechos de Autor © 2026

Este documento se publica bajo los términos y condiciones de la licencia:



Creative Commons Reconocimiento – No Comercial – Compartir Igual 4.0 Internacional (CC BY-NC-SA 4.0)

Usted es libre de compartir y adaptar el material, siempre que otorgue el crédito correspondiente, no lo utilice con fines comerciales y distribuya sus contribuciones bajo la misma licencia.

Para ver una copia de esta licencia, visite: <https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>

Sinopsis

Ciencia, incertidumbre y construcción contemporánea de la evidencia examina las condiciones mediante las cuales el conocimiento científico se produce, evalúa y utiliza en escenarios donde la certeza absoluta no siempre es posible. La obra analiza la incertidumbre como un componente inherente de la investigación y diferencia sus principales manifestaciones, entre ellas el error, la variabilidad, la indeterminación y los límites epistemológicos. A partir de esta base, profundiza en la naturaleza de la evidencia, su relación con la observación y los datos, así como en los criterios empleados para valorar su calidad, consistencia y capacidad justificativa. El libro aborda además los procesos inferenciales que permiten construir generalizaciones, contrastar hipótesis y formular explicaciones, junto con los desafíos asociados con resultados contradictorios, reproducibilidad, replicación y sesgos. También estudia el impacto de los datos masivos, los modelos computacionales, la inteligencia artificial y las simulaciones en la producción contemporánea de evidencia científica. Finalmente, analiza la toma de decisiones bajo información incompleta, la comunicación de riesgos, el principio de precaución y la responsabilidad vinculada con la interpretación y aplicación de resultados. La propuesta integra perspectivas metodológicas, epistemológicas y tecnológicas para comprender cómo gestionar la incertidumbre sin debilitar el rigor científico.

Palabras clave: incertidumbre científica, evidencia científica, inferencia, reproducibilidad, inteligencia artificial.

Synopsis

Science, Uncertainty, and the Contemporary Construction of Evidence examines the conditions under which scientific knowledge is produced, evaluated, and applied in contexts where absolute certainty is not always possible. The book analyzes uncertainty as an inherent component of research and distinguishes its main manifestations, including error, variability, indeterminacy, and epistemological limits. From this foundation, it explores the nature of scientific evidence, its relationship with observation and data, and the criteria used to assess its quality, consistency, and justificatory capacity. The book also addresses the inferential processes involved in developing generalizations, testing hypotheses, and formulating explanations, together with the challenges posed by contradictory results, reproducibility, replication, and bias. It further examines the impact of big data, computational models, artificial intelligence, and simulations on the contemporary production of scientific evidence. Finally, it considers decision-making under incomplete information, risk communication, precaution, and the responsibility involved in interpreting and applying scientific findings. The work integrates methodological, epistemological, and technological perspectives to explain how uncertainty can be managed without weakening scientific rigor.

Keywords: scientific uncertainty, scientific evidence, inference, reproducibility, artificial intelligence.

Índice de Contenido

Sinopsis	7
Synopsis	8
Introducción	11
Capítulo 1. La incertidumbre en el conocimiento científico.....	14
1.1 Conceptualización de la incertidumbre científica	15
1.2 Fuentes de incertidumbre en los procesos de investigación.....	18
1.3 Error, variabilidad e indeterminación científica.....	20
1.4 Incertidumbre epistemológica y límites del conocimiento	24
1.5 Representación de la incertidumbre en los resultados científicos.....	27
Capítulo 2. Evidencia y justificación del conocimiento	31
2.1 Naturaleza de la evidencia científica.....	32
2.2 Relación entre observación, datos y evidencia.....	35
2.3 Criterios para valorar la solidez de la evidencia	37
2.4 Evidencia directa e indirecta en la investigación	41
2.5 Justificación de afirmaciones científicas bajo condiciones de incertidumbre.....	44
Capítulo 3. Construcción y evaluación de la evidencia	48
3.1 Producción de datos en los procesos científicos	49
3.2 Calidad y confiabilidad de las fuentes de evidencia	51
3.3 Triangulación y convergencia de evidencias	54
3.4 Consistencia de resultados entre diferentes estudios.....	58
3.5 Interpretación crítica de hallazgos científicos.....	61
Capítulo 4. Inferencia científica frente a la incertidumbre	64
4.1 Inferencia inductiva y construcción de generalizaciones.....	65
4.2 Inferencia deductiva y contrastación científica.....	67
4.3 Razonamiento abductivo y formulación de explicaciones.....	70
4.4 Probabilidad y evaluación de hipótesis	75
4.5 Límites de la inferencia en escenarios complejos	78

Capítulo 5. Controversia, reproducibilidad y confianza científica	82
5.1 Resultados contradictorios en la investigación científica	83
5.2 Reproducibilidad como criterio de confiabilidad.....	86
5.3 Replicación y estabilidad de los hallazgos.....	88
5.4 Sesgos y distorsiones en la producción de evidencia.....	92
5.5 Confianza científica ante resultados inciertos.....	95
Capítulo 6. Nuevas tecnologías en la construcción de evidencia	99
6.1 Datos masivos y nuevas fuentes de evidencia.....	100
6.2 Modelos computacionales como instrumentos de inferencia.....	102
6.3 Inteligencia artificial en el análisis de evidencia científica.....	105
6.4 Evidencia generada mediante simulaciones.....	109
6.5 Validación de resultados producidos por sistemas automatizados.....	112
Capítulo 7. Decisión científica en contextos de incertidumbre	116
7.1 Toma de decisiones basada en evidencia incompleta	117
7.2 Comunicación científica de riesgos e incertidumbres.....	119
7.3 Precaución ante consecuencias científicamente inciertas	122
7.4 Responsabilidad en la interpretación y aplicación de evidencia	126
7.5 Nuevos criterios para gestionar la incertidumbre científica.....	128
Conclusión	132
Bibliografía	135

Introducción

La ciencia contemporánea se desarrolla en un escenario donde la producción de conocimiento exige reconocer que los resultados no siempre pueden expresarse en términos de certeza absoluta. La investigación opera con observaciones limitadas, mediciones sujetas a variación, modelos que simplifican los fenómenos y datos cuya interpretación depende de condiciones metodológicas específicas. La incertidumbre forma parte de este proceso y acompaña tanto la construcción de explicaciones como la evaluación de hipótesis. Comprender su presencia permite delimitar con mayor precisión qué puede sostenerse a partir de la evidencia disponible y qué aspectos permanecen abiertos a revisión.

El análisis de la incertidumbre requiere distinguir entre fenómenos diferentes que suelen agruparse bajo una misma denominación. El error, la variabilidad, la indeterminación y los límites epistemológicos tienen orígenes y consecuencias distintas para la investigación. Algunas incertidumbres pueden reducirse mediante mejores instrumentos, diseños más rigurosos o nuevas observaciones, mientras que otras derivan de la complejidad del fenómeno, de información inaccesible o de la existencia de varias explicaciones compatibles con los mismos datos. Esta diferenciación resulta necesaria para evitar que cualquier margen de duda sea interpretado automáticamente como una deficiencia del conocimiento científico.

La evidencia ocupa una posición central en este contexto porque constituye el fundamento mediante el cual las afirmaciones científicas adquieren respaldo. Los datos no funcionan como evidencia por el simple hecho de haber sido recopilados. Deben guardar relación con una pregunta, hipótesis o explicación y haber sido producidos mediante procedimientos que permitan valorar su calidad y pertinencia. La transición desde la observación hasta la conclusión incorpora decisiones de selección, medición, organización y análisis que condicionan aquello que finalmente puede afirmarse. Examinar estas operaciones permite comprender cómo se construye la capacidad justificativa de los resultados científicos.

La solidez de la evidencia tampoco depende de un único criterio. La calidad metodológica, la pertinencia de las fuentes, la consistencia entre resultados, la transparencia del proceso y la posibilidad de evaluar explicaciones alternativas contribuyen conjuntamente a determinar cuánto respaldo posee una conclusión. La convergencia de diferentes líneas de evidencia puede fortalecer una interpretación, pero las discrepancias también proporcionan información relevante. Los resultados contradictorios obligan a examinar diferencias de contexto,

población, diseño y análisis antes de decidir si representan incompatibilidades genuinas o variaciones explicables dentro de un fenómeno más complejo.

La inferencia científica conecta la evidencia con las afirmaciones que exceden aquello que ha sido observado directamente. La inducción permite construir generalizaciones a partir de casos particulares; la deducción deriva consecuencias contrastables desde hipótesis o premisas; y la abducción propone explicaciones posibles para los patrones encontrados. Estos procedimientos responden a propósitos distintos y presentan límites específicos. La incertidumbre aparece cuando los datos admiten más de una interpretación, las generalizaciones dependen de condiciones particulares o las hipótesis no pueden discriminarse completamente mediante la evidencia disponible. La probabilidad ofrece herramientas para representar algunos de estos grados de respaldo sin convertirlos en certezas definitivas.

La confiabilidad del conocimiento también depende de la posibilidad de examinar la estabilidad de los hallazgos. La reproducibilidad permite comprobar si un resultado puede reconstruirse mediante los mismos datos y procedimientos, mientras que la replicación evalúa si un hallazgo reaparece cuando se genera nueva evidencia. Ambos procesos contribuyen a detectar errores, dependencias metodológicas y resultados sensibles a condiciones particulares. La ausencia de reproducción o replicación no admite una explicación única, por lo que debe analizarse junto con las características del diseño, la calidad de la documentación y la independencia de las fuentes utilizadas.

Los sesgos introducen otra dimensión en la evaluación de la evidencia. Pueden aparecer durante la selección de participantes, la medición, el procesamiento de datos, la elección de modelos o la interpretación de resultados. Su identificación exige revisar el recorrido completo de la investigación y distinguir entre decisiones metodológicas justificadas y procedimientos capaces de producir desviaciones sistemáticas. La transparencia, la trazabilidad y el análisis de sensibilidad permiten examinar cómo determinadas elecciones influyen en las conclusiones. Esta evaluación resulta especialmente relevante cuando varios estudios comparten bases de datos, instrumentos o procedimientos que podrían reproducir las mismas limitaciones.

Las tecnologías digitales han ampliado de manera considerable las formas de producir y analizar evidencia. Los datos masivos, los modelos computacionales, la inteligencia artificial y las simulaciones permiten estudiar relaciones que difícilmente podrían examinarse mediante procedimientos exclusivamente manuales. Estas herramientas aumentan la capacidad para procesar información, explorar escenarios y detectar patrones complejos, pero también

introducen nuevas fuentes de incertidumbre. La calidad de los datos, el sobreajuste, la fuga de información, la opacidad de ciertos modelos y las dificultades de validación obligan a establecer procedimientos que permitan comprobar la estabilidad y pertinencia de los resultados automatizados.

La incertidumbre adquiere especial importancia cuando la evidencia debe utilizarse para orientar decisiones. En numerosos problemas científicos no es posible esperar hasta disponer de información completa, por lo que resulta necesario decidir con estimaciones provisionales, escenarios alternativos y consecuencias parcialmente desconocidas. La comunicación del riesgo debe expresar estas condiciones sin transformar la incertidumbre en una apariencia de certeza ni convertirla en una razón automática para la inacción. La precaución, la proporcionalidad, la reversibilidad y la posibilidad de revisar decisiones permiten relacionar el conocimiento disponible con las consecuencias potenciales de su aplicación.

Este libro examina estas cuestiones mediante siete capítulos articulados alrededor de la incertidumbre, la evidencia, la inferencia, la reproducibilidad, las nuevas tecnologías y la decisión científica. El recorrido parte de los fundamentos conceptuales y avanza hacia los procedimientos mediante los cuales se producen, evalúan e interpretan resultados en contextos de conocimiento incompleto. La atención se dirige tanto a las condiciones que fortalecen una afirmación como a los límites que deben permanecer visibles. Desde esta perspectiva, construir evidencia implica establecer qué se conoce, con qué grado de respaldo y bajo qué condiciones las conclusiones pueden mantenerse, modificarse o ser sustituidas.



Capítulo **1**.



La incertidumbre en el conocimiento científico

Martha Clemencia García Cifuentes

1.1 Conceptualización de la incertidumbre científica

La incertidumbre científica puede entenderse como la ausencia de certeza completa respecto de una afirmación, una medición, una explicación o una predicción. No equivale simplemente a desconocimiento, porque puede surgir incluso cuando existe evidencia suficiente para formular conclusiones razonables. Su presencia expresa que el conocimiento científico se construye con grados variables de seguridad y permanece abierto a revisión cuando aparecen nuevos datos o mejores procedimientos de análisis. Por ello, reconocer la incertidumbre constituye una condición normal de la investigación y permite distinguir entre lo que está sólidamente sustentado y aquello que conserva márgenes relevantes de duda (Covitt & Anderson, 2022).

La incertidumbre adquiere diferentes formas según el objeto estudiado y el tipo de conocimiento disponible. Puede relacionarse con información insuficiente, interpretaciones alternativas, variabilidad en los fenómenos o desacuerdos acerca de cómo valorar los datos existentes. Estas situaciones muestran que la incertidumbre no constituye una categoría única, sino un conjunto de condiciones que afectan de manera distinta la producción y evaluación del conocimiento. Diferenciar sus manifestaciones permite precisar dónde se encuentra la limitación y evita tratar como equivalentes problemas que requieren respuestas metodológicas o epistemológicas diferentes dentro de una investigación científica (Chen et al., 2024).

Una característica central de la incertidumbre científica es su relación con los límites de la evidencia disponible. Las conclusiones dependen de observaciones, mediciones, modelos y procedimientos que nunca capturan de forma absoluta todas las propiedades de un fenómeno. Incluso cuando el diseño de investigación es riguroso, pueden permanecer aspectos insuficientemente determinados. Esto obliga a expresar las conclusiones de acuerdo con el alcance real de la evidencia y no como afirmaciones definitivas. La incertidumbre actúa, en este sentido, como indicador de aquello que la evidencia permite sostener y de aquello que todavía excede su capacidad justificativa (Schnarr & Mertz, 2022).

El reconocimiento de la incertidumbre también modifica la manera de comprender la objetividad científica. Una conclusión puede ser válida dentro de determinadas condiciones sin pretender ofrecer una descripción completa e invariable del fenómeno. La ciencia trabaja mediante aproximaciones que dependen de conceptos, métodos y marcos explicativos susceptibles de corrección. Esta condición no elimina la posibilidad de producir conocimiento confiable, pero exige diferenciar la confiabilidad de la certeza absoluta. La evaluación

científica debe atender al fundamento de las afirmaciones, a las limitaciones declaradas y a la posibilidad de revisar las interpretaciones cuando cambian las condiciones de conocimiento (Metzen, 2024).

Desde una perspectiva epistemológica, la incertidumbre permite reconocer que los sistemas estudiados pueden presentar relaciones difíciles de reducir a explicaciones lineales. En fenómenos complejos, las interacciones entre componentes introducen condiciones que dificultan anticipar completamente los resultados a partir del conocimiento aislado de cada elemento. La explicación científica requiere entonces considerar relaciones, contextos y niveles de organización que pueden permanecer parcialmente abiertos. Esta situación amplía el concepto de incertidumbre más allá del error técnico y lo vincula con las dificultades inherentes a la comprensión de sistemas cuya dinámica no siempre puede representarse mediante modelos simples (Villalobos Antúnez et al., 2023).

La incertidumbre debe distinguirse del error porque ambos conceptos describen problemas diferentes. El error se refiere a la diferencia entre un resultado obtenido y un valor de referencia cuando este puede establecerse, mientras que la incertidumbre expresa el grado de duda asociado con el resultado. En determinadas mediciones, el valor verdadero puede permanecer desconocido, lo que impide reducir la evaluación a una corrección exacta del error. Esta distinción resulta importante porque evita interpretar todo margen de incertidumbre como una falla del procedimiento y permite comprender que una medición puede ser técnicamente válida aun cuando conserve un intervalo de indeterminación (Lee et al., 2022).

La incertidumbre tampoco implica que todas las interpretaciones tengan el mismo valor. Una afirmación científicamente justificable requiere evidencia, coherencia metodológica y una relación razonable entre los datos disponibles y la conclusión formulada. Cuando estas condiciones se cumplen, es posible establecer diferentes grados de confianza sin eliminar por completo la incertidumbre. La evaluación debe considerar la calidad de las razones que sostienen una afirmación y la existencia de explicaciones alternativas. De este modo, la incertidumbre puede integrarse en la argumentación científica sin convertir el conocimiento en una colección de opiniones equivalentes o carentes de criterios de valoración (Gough, 2021).

Otro aspecto de su conceptualización corresponde a la relación entre incertidumbre y probabilidad. Determinados problemas científicos permiten representar la incertidumbre mediante distribuciones, probabilidades o grados de credibilidad asignados a distintos resultados posibles. Estas herramientas no eliminan aquello que se desconoce, pero permiten

organizarlo y expresarlo de manera más precisa. La probabilidad adquiere así una función inferencial al ofrecer procedimientos para actualizar valoraciones a medida que se incorpora nueva evidencia. Esta perspectiva resulta particularmente relevante cuando las hipótesis no pueden clasificarse únicamente como verdaderas o falsas y deben evaluarse según el respaldo relativo que reciben de los datos (Wei et al., 2022).

La incertidumbre también interviene en el lenguaje utilizado para comunicar conocimiento científico. La fuerza de una afirmación debería corresponder con la solidez de la evidencia que la sustenta, por lo que expresiones de cautela pueden ser necesarias cuando existen limitaciones relevantes. Sin embargo, matizar una conclusión no significa debilitarla arbitrariamente, sino ajustar su alcance al nivel de justificación disponible. Una formulación excesivamente categórica puede ocultar condiciones importantes, mientras que una formulación excesivamente cautelosa puede dificultar la comprensión de aquello que sí está respaldado. La comunicación responsable requiere mantener una correspondencia entre evidencia, incertidumbre y grado de afirmación (Ward & Creel, 2024).

La incertidumbre posee además una dimensión cuantitativa cuando se relaciona con procesos de medición. En estos casos puede expresarse mediante parámetros que describen la dispersión o el intervalo dentro del cual resulta razonable situar el valor de una magnitud. Esta representación permite comunicar de manera explícita las limitaciones asociadas con un resultado y evita presentar una cifra aislada como si poseyera precisión absoluta. El tratamiento adecuado de la incertidumbre exige seleccionar formas de expresión que sean coherentes con la información disponible y con el propósito de la medición, especialmente cuando diferentes representaciones pueden producir interpretaciones distintas del mismo resultado (Cox & O'Hagan, 2022).

Conceptualizar la incertidumbre científica implica, finalmente, incorporarla como parte del proceso mediante el cual se construye y revisa el conocimiento. Su reconocimiento permite delimitar lo conocido, identificar aquello que permanece abierto y establecer qué tipo de evidencia sería necesaria para reducir determinadas dudas. Esta perspectiva evita asociar automáticamente incertidumbre con debilidad científica, pero tampoco permite utilizarla como argumento para aceptar conclusiones insuficientemente sustentadas. Su valor depende de que pueda identificarse, describirse y relacionarse con las condiciones concretas de producción del conocimiento. La incertidumbre se convierte así en un componente evaluable de la investigación y de sus afirmaciones (Covitt & Anderson, 2022).

1.2 Fuentes de incertidumbre en los procesos de investigación

La incertidumbre en los procesos de investigación puede originarse desde las primeras decisiones que delimitan un problema científico. La selección del objeto de estudio, la formulación de preguntas, la definición de variables y la elección de procedimientos condicionan qué aspectos podrán observarse y cuáles permanecerán fuera del análisis. Cuando la información disponible es incompleta o admite interpretaciones diferentes, estas decisiones incorporan márgenes de incertidumbre que después influyen en los resultados. Identificar su origen desde el diseño permite diferenciar limitaciones propias del fenómeno de aquellas relacionadas con las decisiones metodológicas adoptadas durante la investigación (Chen et al., 2024).

Una fuente frecuente de incertidumbre procede de la cantidad y calidad de la información disponible. Las investigaciones pueden desarrollarse con evidencia limitada, datos incompletos o conocimiento previo insuficiente para establecer con precisión todas las condiciones relevantes. Esta situación resulta especialmente importante cuando las decisiones dependen de muestras pequeñas o de resultados todavía preliminares. La incorporación de información adicional puede modificar considerablemente las estimaciones iniciales, lo que muestra que algunas conclusiones dependen del volumen de evidencia acumulada y del grado en que esta permite reducir la incertidumbre asociada con las inferencias realizadas (Sondhi et al., 2021).

Los procedimientos de medición constituyen otra fuente importante de incertidumbre. Todo proceso de medición opera mediante instrumentos, escalas, condiciones experimentales y criterios de interpretación que pueden introducir variaciones en los valores obtenidos. La imposibilidad de conocer con exactitud un valor verdadero obliga a distinguir entre el error que puede identificarse y la incertidumbre que permanece asociada con el resultado. Por ello, la precisión instrumental no elimina completamente la incertidumbre, sino que permite caracterizarla dentro de márgenes determinados y evaluar hasta qué punto una medición ofrece información adecuada para sustentar una conclusión científica (Lee et al., 2022).

La producción de datos también introduce incertidumbre porque depende de decisiones acerca de qué información obtener, mediante qué procedimientos y bajo qué condiciones. La selección de participantes, contextos, técnicas y momentos de recopilación puede modificar las características de los datos generados. En investigaciones cualitativas, por ejemplo, la estrategia de generación debe corresponder con la pregunta de investigación y con el tipo de experiencia que se pretende comprender. Estas decisiones muestran que los datos no son

elementos independientes del proceso metodológico, sino productos de procedimientos concretos cuya adecuación condiciona el alcance y la confiabilidad de las interpretaciones posteriores (Jack et al., 2023).

Otra fuente aparece durante la interpretación y utilización de la evidencia. Una misma información puede adquirir significados distintos según el contexto, los criterios de evaluación empleados y las preguntas que orientan su análisis. La calidad de una fuente no garantiza por sí sola que su utilización sea adecuada, porque también debe considerarse su pertinencia para el problema estudiado y la forma en que se integra con otros conocimientos disponibles. La incertidumbre puede aumentar cuando existe una correspondencia insuficiente entre la evidencia seleccionada y la afirmación que se pretende sostener, incluso cuando los datos originales fueron obtenidos mediante procedimientos rigurosos (Rickinson et al., 2021).

Tabla 1

Fuentes de incertidumbre y puntos críticos del proceso de investigación

Momento del proceso	Fuente de incertidumbre	Condición que la origina	Aspecto que debe examinarse
Delimitación del problema	Incertidumbre conceptual	Definiciones incompletas o ambiguas	Correspondencia entre conceptos y fenómeno
Diseño metodológico	Incertidumbre procedimental	Elección entre métodos posibles	Adecuación del método a la pregunta
Producción de datos	Incertidumbre empírica	Cobertura, selección y condiciones de obtención	Representatividad y pertinencia de los datos
Medición	Incertidumbre instrumental	Precisión limitada y condiciones de medición	Magnitud y expresión de la incertidumbre
Análisis	Incertidumbre inferencial	Modelos, supuestos y decisiones analíticas	Robustez de las conclusiones
Interpretación	Incertidumbre explicativa	Existencia de explicaciones alternativas	Correspondencia entre evidencia y afirmación

Nota. La clasificación permite localizar la incertidumbre según la etapa en que surge y distinguir las condiciones que requieren control metodológico, evaluación inferencial o reconocimiento explícito de límites.

Los modelos empleados para analizar los datos constituyen otra fuente de incertidumbre cuando representan de manera incompleta el fenómeno investigado. Todo modelo incorpora supuestos, simplificaciones y criterios de selección que determinan qué relaciones pueden identificarse. En sistemas complejos, estas limitaciones adquieren mayor importancia porque distintas estructuras matemáticas pueden resultar compatibles con los mismos datos disponibles. El ruido y la información insuficiente pueden dificultar incluso la identificación

del modelo generador, estableciendo límites concretos para inferir mecanismos o relaciones a partir de observaciones empíricas (Fajardo-Fontiveros et al., 2023).

La incertidumbre puede surgir además de la relación entre observación, datos y explicación. Las observaciones deben transformarse en registros interpretables antes de utilizarse como evidencia, y este tránsito supone operaciones de selección, organización y representación. Los datos adquieren función evidencial cuando se relacionan con preguntas y afirmaciones específicas, de modo que su significado depende del marco en el que son analizados. Las diferencias entre aquello que se observa y aquello que finalmente se utiliza para justificar una explicación pueden introducir incertidumbre sobre el alcance de las conclusiones y sobre la suficiencia de los elementos empleados para sostenerlas (Duschl et al., 2021).

Las fuentes de incertidumbre también pueden combinarse y producir efectos acumulativos. Una medición imprecisa, una muestra limitada y un modelo sustentado en supuestos discutibles pueden afectar simultáneamente una misma inferencia. En estas condiciones, resulta insuficiente valorar cada limitación de manera aislada, porque su interacción puede modificar el grado de confianza atribuible al resultado. El análisis de incertidumbre requiere considerar tanto la procedencia de cada limitación como la relación entre ellas, especialmente cuando las decisiones posteriores dependen de estimaciones cuyo respaldo empírico permanece condicionado por información incompleta o por supuestos todavía sujetos a revisión (Schnarr & Mertz, 2022).

Reconocer las fuentes de incertidumbre permite ajustar la fuerza de las afirmaciones a las condiciones reales de la investigación. Cuando permanecen dudas relevantes sobre los datos, el procedimiento o la inferencia, las conclusiones deben expresar esos límites sin ocultarlos ni exagerarlos. La comunicación científica requiere que el grado de seguridad transmitido corresponda con la evidencia disponible, porque una formulación excesivamente categórica puede presentar como establecido aquello que todavía depende de supuestos o información incompleta. Identificar dónde surge la incertidumbre facilita formular afirmaciones más precisas y conservar una relación justificable entre resultados, interpretación y alcance del conocimiento producido (Ward & Creel, 2024).

1.3 Error, variabilidad e indeterminación científica

El error científico se refiere a la diferencia entre un valor observado y un valor de referencia o valor verdadero cuando este puede establecerse. Su presencia no implica necesariamente una

falla grave del proceso de investigación, porque toda medición está expuesta a limitaciones instrumentales, condiciones ambientales y procedimientos de registro. Distinguir entre error sistemático y error aleatorio permite reconocer si la desviación sigue un patrón constante o si varía entre observaciones. Esta diferenciación es necesaria para interpretar adecuadamente los resultados y evitar que la incertidumbre asociada con la medición se confunda con una incorrección metodológica absoluta (Lee et al., 2022).

La variabilidad describe las diferencias que pueden observarse entre mediciones, sujetos, muestras, contextos o momentos de observación. A diferencia del error, no siempre constituye una desviación que deba corregirse, porque puede reflejar propiedades reales del fenómeno estudiado. En investigaciones empíricas, parte de la variabilidad procede de la heterogeneidad de los casos y otra parte de las condiciones de medición. La tarea analítica consiste en distinguir qué proporción corresponde a características propias del sistema y cuál puede atribuirse a factores técnicos o metodológicos. Esta distinción condiciona la interpretación de la estabilidad y generalización de los resultados (Cox & O'Hagan, 2022).

La indeterminación científica aparece cuando la información disponible no permite establecer con precisión un único valor, explicación o resultado posible. Puede surgir porque existen varios escenarios compatibles con la evidencia, porque determinadas variables no son observables directamente o porque el sistema presenta relaciones difíciles de aislar. En estos casos, la incertidumbre no se reduce a un problema de precisión instrumental, sino que refleja una limitación en la capacidad de identificar completamente las condiciones que producen un fenómeno. Esta situación obliga a formular conclusiones que reconozcan explícitamente la existencia de alternativas plausibles y los márgenes dentro de los cuales permanece abierta la interpretación (Schnarr & Mertz, 2022).

El análisis del error requiere considerar la calidad de los procedimientos mediante los cuales se generan los datos. Una medición puede resultar técnicamente precisa y, sin embargo, no representar adecuadamente el fenómeno si el instrumento o la estrategia de recolección no corresponde con la variable de interés. Por ello, la evaluación del error no debe limitarse a la dispersión numérica de los resultados. También debe examinarse la pertinencia del diseño, la correspondencia entre concepto y medición y la consistencia de las condiciones de observación. Estas decisiones influyen directamente en la confiabilidad de los datos que sostienen las inferencias posteriores (Jack et al., 2023).

La variabilidad adquiere especial importancia cuando los resultados deben compararse entre estudios. Diferencias en las poblaciones, contextos, instrumentos o criterios analíticos pueden producir estimaciones distintas incluso cuando las investigaciones abordan una misma pregunta. La existencia de variación entre estudios no significa automáticamente que los resultados sean incompatibles, pero exige examinar si las diferencias pueden explicarse por factores metodológicos o por heterogeneidad real. Los procedimientos de síntesis de evidencia deben evaluar esta consistencia antes de integrar los hallazgos, porque una combinación acrítica puede ocultar discrepancias importantes y generar conclusiones artificialmente homogéneas (Pedder et al., 2022).

La indeterminación también aparece cuando distintos modelos explicativos se ajustan de manera similar a los datos disponibles. En sistemas complejos, la información empírica puede ser insuficiente para identificar una única estructura causal o matemática. Esta situación establece límites concretos para la inferencia, porque varias formulaciones pueden reproducir patrones observados sin representar necesariamente el mecanismo real que los genera. El aumento del volumen de datos puede reducir parte de esta ambigüedad, pero no siempre elimina el problema si el ruido o la estructura del sistema impiden discriminar entre modelos alternativos (Fajardo-Fontiveros et al., 2023).

La relación entre error y variabilidad también depende del nivel de análisis seleccionado. Una variación que parece aleatoria en observaciones individuales puede mostrar regularidades cuando se examina en conjunto, mientras que un patrón estable puede descomponerse en componentes heterogéneos al aumentar la resolución del análisis. Esta condición exige cautela al atribuir una desviación exclusivamente al error. Los resultados deben interpretarse considerando la estructura de los datos, las escalas de observación y los supuestos utilizados para organizar la información. La confiabilidad de una conclusión depende en parte de que estos elementos sean coherentes con la naturaleza del fenómeno estudiado (Rickinson et al., 2021).

Los procedimientos probabilísticos permiten representar parte de la variabilidad y de la indeterminación mediante distribuciones y grados de credibilidad. En lugar de producir únicamente estimaciones puntuales, estos métodos permiten expresar qué valores reciben mayor o menor respaldo según la evidencia disponible. El enfoque bayesiano, por ejemplo, actualiza la evaluación de hipótesis al incorporar nueva información y hace explícita la incertidumbre asociada con las inferencias. Sin embargo, estos resultados dependen de los supuestos del modelo y de las distribuciones utilizadas, por lo que la cuantificación

probabilística no elimina la necesidad de analizar críticamente las condiciones que originan la **incertidumbre** (Wei et al., 2022).

Figura 1

Error, variabilidad e indeterminación en la interpretación de resultados científicos



Nota. Organiza las principales formas de incertidumbre y los criterios que orientan una interpretación rigurosa de los resultados.

La comunicación del error y la variabilidad requiere evitar expresiones que sugieran una precisión mayor que la permitida por los datos. Presentar únicamente un valor central puede ocultar diferencias relevantes entre observaciones y generar una percepción equivocada de

estabilidad. Los intervalos, distribuciones y otras medidas de incertidumbre permiten mostrar de manera más completa el rango de resultados compatibles con la información disponible. La elección de la representación debe responder al tipo de medición y al propósito del análisis, porque distintas formas de expresar incertidumbre pueden modificar la interpretación que lectores y usuarios realizan de un mismo resultado científico (Cox & O'Hagan, 2022).

La presencia de error, variabilidad e indeterminación obliga también a revisar la fuerza con que se formulan las conclusiones. Una afirmación que omite limitaciones relevantes puede presentar como estable un resultado cuya evidencia es todavía sensible a cambios en los datos o en el modelo. Por el contrario, reconocer explícitamente estas condiciones permite delimitar con mayor precisión qué puede sostenerse y bajo qué supuestos. Las expresiones de cautela cumplen una función epistemológica cuando ajustan el lenguaje al grado real de respaldo empírico, siempre que no se utilicen para introducir ambigüedad innecesaria o evitar compromisos justificables con la evidencia disponible (Ward & Creel, 2024).

Error, variabilidad e indeterminación representan dimensiones distintas pero relacionadas de la incertidumbre científica. El error remite a desviaciones respecto de una referencia, la variabilidad describe diferencias entre observaciones o condiciones y la indeterminación expresa la imposibilidad de establecer completamente un resultado o explicación. Distinguir las permite elegir procedimientos de análisis adecuados y evita atribuir a una sola causa todas las limitaciones del conocimiento. Esta diferenciación también mejora la evaluación de la confiabilidad, porque permite identificar qué incertidumbres pueden reducirse mediante mejores mediciones y cuáles dependen de restricciones más profundas del modelo, de los datos o del fenómeno investigado (Covitt & Anderson, 2022).

1.4 Incertidumbre epistemológica y límites del conocimiento

La incertidumbre epistemológica se refiere a las limitaciones que afectan lo que puede conocerse, justificarse o afirmarse con fundamento dentro de un proceso científico. No depende únicamente de errores de medición o de falta de datos, porque también surge cuando los conceptos, modelos y marcos explicativos disponibles resultan insuficientes para representar completamente un fenómeno. En estos casos, la incertidumbre expresa una restricción en la capacidad de conocimiento y no solo una deficiencia técnica. Reconocer esta dimensión permite diferenciar entre problemas que podrían resolverse con mejores procedimientos y límites que permanecen asociados a la propia estructura del conocimiento científico (Covitt & Anderson, 2022).

Los límites del conocimiento también aparecen cuando varias explicaciones son compatibles con la misma evidencia. Un conjunto de datos puede respaldar más de una interpretación, especialmente en fenómenos complejos o cuando existen variables no observadas. Esta situación impide considerar que la relación entre evidencia y conclusión sea siempre directa. La justificación científica requiere entonces examinar hipótesis alternativas, supuestos metodológicos y condiciones bajo las cuales una explicación mantiene su validez. La incertidumbre epistemológica se manifiesta precisamente en esa distancia entre lo observado y lo que puede afirmarse acerca de sus causas, mecanismos o consecuencias (Gough, 2021).

En sistemas complejos, estos límites se vuelven más visibles porque las interacciones entre componentes pueden producir comportamientos difíciles de anticipar a partir del conocimiento aislado de cada parte. La explicación científica necesita integrar múltiples niveles de organización y aceptar que determinados procesos no pueden reducirse a relaciones simples. Esta condición no implica renunciar a la explicación, sino reconocer que el conocimiento puede ser parcial y dependiente de modelos que capturan algunos aspectos del fenómeno y dejan otros fuera. La incertidumbre epistemológica surge así de la propia dificultad de representar estructuras dinámicas mediante marcos conceptuales necesariamente selectivos (Villalobos Antúnez et al., 2023).

Los modelos científicos también establecen límites porque operan mediante simplificaciones. Toda representación selecciona variables, relaciones y condiciones consideradas relevantes, lo que permite analizar un fenómeno, pero también excluye elementos que podrían modificar la interpretación. Cuando diferentes modelos producen resultados plausibles, la evidencia disponible puede no ser suficiente para determinar cuál representa mejor el mecanismo real. Esta dificultad es especialmente importante cuando existe ruido, escasez de datos o alta dimensionalidad, porque aumenta la posibilidad de que varias estructuras sean compatibles con las observaciones y limita la capacidad de identificar una explicación única (Fajardo-Fontiveros et al., 2023).

La incertidumbre epistemológica también está relacionada con la confianza atribuida a las afirmaciones científicas. La confiabilidad no exige que una conclusión sea definitiva, sino que esté sustentada por procedimientos transparentes, evidencia pertinente y criterios de evaluación identificables. Una afirmación puede ser razonablemente confiable aun cuando conserve incertidumbre, siempre que sus límites sean reconocidos y su alcance no exceda lo que la evidencia permite sostener. Esta distinción evita confundir objetividad con ausencia absoluta

de duda y permite comprender que la ciencia puede producir conocimiento válido dentro de condiciones explícitas de revisión y corrección (Metzen, 2024).

Tabla 2
Manifestaciones de la incertidumbre epistemológica y sus límites

Dimensión	Manifestación principal	Límite que introduce	Implicación para la investigación
Conceptual	Definiciones incompletas o disputadas	Dificultad para delimitar el objeto	Precisar conceptos y supuestos
Empírica	Evidencia insuficiente o ambigua	Imposibilidad de discriminar explicaciones	Ampliar y contrastar la evidencia
Modelística	Simplificaciones y supuestos	Representación parcial del fenómeno	Comparar modelos alternativos
Inferencial	Varias conclusiones compatibles	Menor certeza sobre mecanismos o causas	Explicitar condiciones de inferencia
Explicativa	Múltiples interpretaciones plausibles	Ausencia de una explicación única	Evaluar hipótesis competidoras
Comunicativa	Exceso o defecto de cautela	Distorsión del grado real de conocimiento	Ajustar el lenguaje a la evidencia

Nota. La clasificación distingue límites derivados de conceptos, evidencia, modelos e inferencias para evitar tratar toda incertidumbre como un mismo problema metodológico.

La existencia de límites epistemológicos exige distinguir entre desconocimiento temporal y restricciones más persistentes. Algunas incertidumbres pueden reducirse mediante nuevas observaciones, mejores instrumentos o datos adicionales, mientras que otras dependen de la estructura del problema y pueden mantenerse incluso después de ampliar la evidencia. Esta diferencia resulta importante porque evita asumir que todo vacío de conocimiento desaparecerá automáticamente con mayor acumulación de datos. En determinados escenarios, la incertidumbre permanece porque la evidencia no permite identificar una única explicación o porque las variables relevantes no pueden observarse directamente con los procedimientos disponibles (Schnarr & Mertz, 2022).

La incertidumbre epistemológica también afecta la formulación de afirmaciones científicas. Cuando el respaldo empírico es limitado, el lenguaje debe reflejar con precisión el grado de justificación disponible. Expresiones como “sugiere”, “es compatible con” o “es probable” pueden ser adecuadas cuando existen razones para sostener una conclusión sin alcanzar certeza completa. La cautela cumple una función científica cuando evita convertir inferencias provisionales en afirmaciones categóricas. Sin embargo, debe utilizarse de forma proporcional, porque una formulación excesivamente ambigua también puede ocultar resultados que cuentan

con respaldo suficiente y dificultar la evaluación de su verdadero alcance (Ward & Creel, 2024).

Los límites del conocimiento pueden hacerse más evidentes cuando la evidencia procede de dominios donde las observaciones son escasas o indirectas. En estas condiciones, las teorías deben sostenerse mediante cadenas inferenciales más largas y dependen en mayor medida de supuestos intermedios. Esto aumenta la necesidad de examinar cuidadosamente la relación entre los datos disponibles y las explicaciones propuestas. La evidencia indirecta no carece de valor, pero exige mayor atención a las alternativas plausibles y a los pasos que conectan observación y conclusión, especialmente cuando no es posible acceder directamente al fenómeno que se pretende explicar (Woensdregt et al., 2024).

Reconocer los límites epistemológicos permite establecer con mayor precisión qué se sabe, qué permanece abierto y qué tipo de evidencia sería necesaria para avanzar. Esta práctica no debilita el conocimiento científico, sino que evita presentar resultados provisionales como certezas definitivas. La incertidumbre epistemológica funciona como un criterio para delimitar el alcance de las explicaciones y valorar hasta qué punto una afirmación puede sostenerse con la evidencia disponible. Su análisis contribuye a mantener una relación coherente entre observación, inferencia y conclusión, especialmente cuando los fenómenos investigados exceden la capacidad explicativa de un único modelo o procedimiento (Covitt & Anderson, 2022).

1.5 Representación de la incertidumbre en los resultados científicos

La representación de la incertidumbre permite mostrar de manera explícita el grado de precisión, variabilidad o confianza asociado con un resultado científico. Un valor aislado puede transmitir una apariencia de exactitud que no corresponde con las condiciones reales de medición o análisis. Por esta razón, los resultados suelen acompañarse de intervalos, distribuciones, errores estándar u otras medidas que expresan el rango dentro del cual se considera razonable situar una estimación. La representación adecuada debe corresponder con la naturaleza de los datos y con el propósito inferencial, evitando tanto ocultar la incertidumbre como exagerarla mediante procedimientos que dificulten su interpretación (Cox & O'Hagan, 2022).

En los procesos de medición, representar la incertidumbre supone reconocer que el valor obtenido no coincide necesariamente con un valor verdadero conocido. Cuando este último no puede establecerse con exactitud, la incertidumbre proporciona información sobre la dispersión

de valores plausibles y sobre las condiciones que afectan la medición. Esta distinción es importante porque evita presentar el error como si fuera completamente observable y corregible. La representación debe informar qué se conoce sobre la magnitud medida y qué parte permanece indeterminada, de manera que el usuario pueda interpretar el resultado considerando sus restricciones técnicas y epistemológicas (Lee et al., 2022).

Los intervalos constituyen una de las formas más utilizadas para representar incertidumbre porque permiten mostrar un conjunto de valores compatibles con los datos y el procedimiento analítico. Sin embargo, su interpretación depende del método estadístico empleado y no debe reducirse a una lectura mecánica. En contextos bayesianos, por ejemplo, las distribuciones posteriores permiten asignar distintos grados de credibilidad a valores o hipótesis a partir de la evidencia disponible. Estas herramientas ofrecen una representación más amplia que una estimación puntual, aunque siguen dependiendo de supuestos y decisiones analíticas que deben mantenerse visibles para evitar interpretaciones excesivamente concluyentes (Wei et al., 2022).

La representación de la incertidumbre también puede realizarse mediante expresiones lingüísticas cuando no resulta apropiado reducirla a una medida numérica. Términos como probable, posible, compatible o incierto comunican distintos grados de respaldo, pero su significado puede variar entre lectores. Por ello, la elección del lenguaje debe guardar correspondencia con la fuerza real de la evidencia. Una afirmación demasiado categórica puede sobreestimar el grado de certeza, mientras que una formulación excesivamente cautelosa puede ocultar resultados suficientemente sustentados. El reto consiste en ajustar el lenguaje científico a la calidad y alcance de la evidencia disponible (Ward & Creel, 2024).

Las representaciones gráficas cumplen una función importante cuando la incertidumbre debe comunicarse junto con tendencias, comparaciones o estimaciones centrales. Barras de error, bandas de confianza y distribuciones permiten visualizar simultáneamente el resultado y su grado de dispersión. No obstante, la eficacia de estas formas depende de que el lector pueda distinguir entre variabilidad de los datos, precisión de la estimación y probabilidad asociada con diferentes valores. Una representación ambigua puede inducir interpretaciones equivocadas incluso cuando los cálculos sean correctos, por lo que la comunicación de incertidumbre debe considerar tanto la precisión estadística como la comprensión de quienes utilizan los resultados (Schneider et al., 2022).

Tabla 3*Formas de representación de la incertidumbre en resultados científicos*

Forma de representación	Información principal	Aplicación habitual	Riesgo de interpretación
Intervalo	Rango de valores compatibles	Estimaciones y mediciones	Interpretarlo como límite absoluto
Distribución probabilística	Grados relativos de plausibilidad	Inferencia probabilística	Ignorar los supuestos del modelo
Error estándar	Precisión de una estimación	Comparación de estimadores	Confundirlo con variabilidad total
Banda de incertidumbre	Variación alrededor de una tendencia	Modelos y predicciones	Considerarla como certeza predictiva
Expresión verbal	Grado cualitativo de seguridad	Comunicación de resultados	Diferencias de interpretación
Escenarios	Conjunto de resultados posibles	Sistemas complejos y decisiones	Confundir posibilidad con probabilidad

Nota. Las formas de representación responden a distintos tipos de incertidumbre y deben seleccionarse según el origen de la variación, el método de análisis y el propósito comunicativo.


La elección de una representación también depende del tipo de incertidumbre que se pretende comunicar. Una variación atribuible a la medición no debería presentarse de la misma manera que una incertidumbre derivada de modelos alternativos o de información incompleta. Cada forma de representación enfatiza aspectos distintos y puede ocultar otros. Cuando el origen de la incertidumbre no se especifica, el lector puede interpretar el rango mostrado como si resumiera todas las limitaciones del estudio. Por ello, resulta necesario vincular cada medida o indicador con la fuente concreta de incertidumbre que pretende describir (Schnarr & Mertz, 2022).

En estudios que combinan evidencia procedente de diferentes investigaciones, la representación debe mostrar también el grado de consistencia entre resultados. La variación entre estudios puede reflejar diferencias reales entre poblaciones, diseños o contextos, por lo que resumir toda la evidencia mediante una única estimación puede ocultar heterogeneidad relevante. Los procedimientos de síntesis deben hacer visible tanto la estimación conjunta como las discrepancias que condicionan su interpretación. De este modo, la representación de la incertidumbre permite evaluar si los resultados convergen suficientemente o si permanecen diferencias que impiden formular conclusiones homogéneas (Pedder et al., 2022).

La comunicación de resultados inciertos tiene consecuencias para la confianza depositada en la ciencia. Explicitar la incertidumbre no implica necesariamente reducir la credibilidad de una conclusión, especialmente cuando se explican las razones que originan esa incertidumbre y el

grado de respaldo disponible. La confianza depende en parte de que exista correspondencia entre lo que los datos permiten afirmar y la manera en que se presenta el resultado. Ocultar márgenes de duda puede generar una apariencia artificial de certeza, mientras que una representación transparente permite comprender tanto la solidez de una conclusión como las condiciones bajo las cuales podría revisarse (Metzen, 2024).

La representación de la incertidumbre debe integrarse en el resultado científico y no añadirse únicamente como una advertencia secundaria. Mostrar rangos, distribuciones, escenarios o expresiones calibradas permite conservar información que se perdería al comunicar solo una cifra o una conclusión categórica. Esta práctica contribuye a diferenciar entre resultados robustos y estimaciones sensibles a cambios en los datos, modelos o supuestos. La utilidad de una representación depende de que permita reconocer qué aspectos están bien establecidos y cuáles permanecen sujetos a variación, revisión o indeterminación dentro del proceso científico (Cox & O'Hagan, 2022).



Capítulo 2.



Evidencia y justificación del conocimiento

Jonathan Eduardo López Poveda

2.1 Naturaleza de la evidencia científica

La evidencia científica puede entenderse como el conjunto de observaciones, datos, registros y resultados que adquieren valor justificativo dentro de una investigación. Su importancia no depende únicamente de existir como información disponible, sino de la relación que establece con una pregunta, hipótesis o explicación determinada. Un mismo dato puede ser relevante para una afirmación y resultar insuficiente para otra, porque la función evidencial depende del contexto en que se interpreta. Por ello, la evidencia debe valorarse atendiendo a su procedencia, pertinencia y capacidad para sustentar inferencias compatibles con los objetivos y procedimientos del estudio (Duschl et al., 2021).

La evidencia no constituye un elemento independiente de los procesos mediante los cuales se produce conocimiento. Su significado depende de decisiones metodológicas acerca de qué observar, cómo registrar la información y mediante qué criterios analizarla. Los datos adquieren condición de evidencia cuando se integran dentro de una estructura argumentativa que permite relacionarlos con determinadas afirmaciones. Esta condición evita considerar que toda información recolectada posee automáticamente el mismo valor científico. La naturaleza de la evidencia está vinculada con su función dentro del razonamiento y con la posibilidad de establecer una conexión justificable entre los resultados obtenidos y las conclusiones formuladas (Gough, 2021).

La evidencia científica también posee una dimensión disciplinar. Cada campo desarrolla procedimientos, instrumentos y criterios específicos para determinar qué información resulta pertinente y cómo debe interpretarse. Las formas de evidencia aceptadas en investigación experimental pueden diferir de aquellas utilizadas en estudios cualitativos, históricos o clínicos sin que esta diversidad elimine la necesidad de justificación. Lo decisivo es que exista correspondencia entre el objeto estudiado, el método empleado y el tipo de afirmación que se pretende sostener. Esta relación permite comprender la evidencia como una construcción metodológicamente situada y no como una categoría uniforme aplicable de manera idéntica a todas las disciplinas (Queirós, 2022).

La fuerza de una evidencia depende en parte de la calidad de los procedimientos que permiten obtenerla y utilizarla. Una fuente metodológicamente rigurosa puede perder utilidad si se aplica fuera del contexto para el cual fue producida, mientras que una información pertinente puede resultar insuficiente cuando presenta limitaciones importantes en su obtención. La valoración debe considerar simultáneamente la calidad técnica, la relevancia para el problema investigado

y la manera en que la evidencia se incorpora al razonamiento. Estas condiciones muestran que la naturaleza de la evidencia incluye tanto propiedades de la información como características de su utilización dentro del proceso científico (Rickinson et al., 2021).

La evidencia tampoco equivale a una prueba definitiva e independiente de interpretación. En numerosos problemas científicos, los datos pueden ser compatibles con más de una explicación y requieren procedimientos inferenciales para establecer cuál recibe mayor respaldo. Esta situación resulta especialmente visible cuando la evidencia es escasa o indirecta, porque las conclusiones dependen de cadenas de razonamiento más extensas. La existencia de alternativas plausibles obliga a evaluar cuidadosamente los supuestos que conectan los datos con una teoría. La evidencia conserva valor científico, pero su capacidad justificativa debe establecerse de acuerdo con la distancia inferencial que separa la observación de la afirmación propuesta (Woensdregt et al., 2024).

La naturaleza de la evidencia está relacionada además con la confiabilidad atribuida a las afirmaciones científicas. Una conclusión puede considerarse bien respaldada sin alcanzar certeza absoluta, siempre que la evidencia haya sido obtenida mediante procedimientos adecuados y sus limitaciones sean explícitas. La confianza científica depende de que exista una relación transparente entre los datos, los métodos y la interpretación realizada. Esta perspectiva permite separar la confiabilidad de la infalibilidad y reconocer que una afirmación puede ser racionalmente aceptable aun cuando permanezca abierta a revisión. La evidencia sustenta conocimiento provisional cuando proporciona razones suficientes dentro de condiciones metodológicas claramente identificadas (Metzen, 2024).

Los datos se transforman en evidencia mediante procesos de selección, organización e interpretación. Las observaciones registradas no hablan por sí mismas, porque requieren categorías, modelos o marcos analíticos que permitan identificar patrones y establecer relaciones relevantes. Este tránsito desde el dato hacia la evidencia introduce decisiones que deben hacerse visibles para comprender cómo se construye una conclusión. La transparencia sobre estas operaciones permite evaluar si la información utilizada realmente respalda la afirmación correspondiente. La naturaleza de la evidencia comprende así tanto el contenido empírico como los procedimientos intelectuales y metodológicos mediante los cuales dicho contenido adquiere significado científico (Duschl et al., 2021).

La evidencia científica puede adoptar formas cuantitativas y cualitativas sin que una de ellas posea automáticamente mayor valor que la otra. Las mediciones numéricas permiten estimar

magnitudes, asociaciones y probabilidades, mientras que los materiales cualitativos pueden aportar información sobre procesos, significados y contextos difícilmente reducibles a variables numéricas. La calidad debe juzgarse según la pregunta planteada, el diseño y el grado de correspondencia entre la información producida y la conclusión. La evaluación crítica de diferentes tipos de evidencia requiere criterios capaces de considerar sus particularidades metodológicas sin asumir una jerarquía basada únicamente en la forma de los datos (Olaghere et al., 2023).

Otra característica de la evidencia es su carácter acumulativo. Una afirmación científica rara vez depende de un único resultado aislado, especialmente cuando pretende generalizarse más allá de las condiciones específicas de un estudio. La comparación entre investigaciones permite identificar convergencias, discrepancias y patrones de heterogeneidad que modifican la valoración inicial de los resultados. La evidencia acumulada puede fortalecer una conclusión cuando diferentes estudios ofrecen resultados consistentes, pero también puede revelar limitaciones que permanecían ocultas en análisis individuales. La naturaleza de la evidencia incluye, por tanto, su capacidad de integrarse y contrastarse con otros resultados dentro de procesos más amplios de evaluación científica (Pedder et al., 2022).

La evidencia debe distinguirse de la mera disponibilidad de información. La abundancia de datos no garantiza que exista respaldo suficiente para una conclusión si los registros presentan problemas de calidad, pertinencia o interpretación. En contextos donde se utilizan grandes volúmenes de información, el conocimiento especializado continúa siendo necesario para decidir qué variables resultan significativas y cómo deben relacionarse con las preguntas científicas. La naturaleza de la evidencia depende de que los datos puedan incorporarse a estructuras explicativas justificables, no únicamente de su cantidad. Esta condición adquiere especial relevancia cuando los procedimientos automatizados procesan información a escalas que dificultan su revisión directa (Hansen & Quinon, 2023).

Comprender la naturaleza de la evidencia exige reconocer simultáneamente su dimensión empírica, metodológica e inferencial. La evidencia surge de observaciones o datos, pero adquiere fuerza científica mediante procedimientos que permiten establecer su relevancia para una afirmación concreta. Su valor no es absoluto ni independiente del contexto, porque depende de la calidad de la información, de los supuestos utilizados y de las alternativas explicativas existentes. Esta concepción permite evaluar con mayor precisión por qué algunas afirmaciones reciben un respaldo sólido y otras permanecen abiertas a discusión, sin reducir la evidencia a una acumulación de datos ni equipararla con certeza definitiva (Gough, 2021).

2.2 Relación entre observación, datos y evidencia

La observación constituye uno de los puntos de partida de la producción científica, pero no equivale todavía a evidencia. Observar implica registrar propiedades, acontecimientos o comportamientos mediante procedimientos determinados, mientras que la evidencia surge cuando esos registros se relacionan con una pregunta o afirmación concreta. Esta diferencia resulta importante porque una misma observación puede adquirir significados distintos según el marco analítico utilizado. La transformación de una observación en evidencia requiere selección, organización e interpretación, de manera que su valor depende tanto de lo registrado como de los procedimientos mediante los cuales se incorpora al razonamiento científico (Duschl et al., 2021).

Los datos representan una forma estructurada de registrar observaciones, mediciones o respuestas obtenidas durante una investigación. Pueden expresarse mediante valores numéricos, textos, imágenes, categorías, secuencias u otros formatos adecuados al fenómeno estudiado. Su producción depende de decisiones previas sobre qué variables considerar, cómo medirlas y bajo qué condiciones registrar la información. Por esta razón, los datos no pueden interpretarse como elementos completamente independientes del diseño metodológico. La calidad de la evidencia posterior estará condicionada por la correspondencia entre las estrategias de generación de datos y las preguntas que orientan la investigación (Jack et al., 2023).

El paso de los datos hacia la evidencia requiere determinar su pertinencia para una afirmación científica específica. Un conjunto de datos puede ser técnicamente correcto y, sin embargo, resultar insuficiente para justificar una conclusión si no existe una relación clara con aquello que se pretende demostrar o explicar. La valoración exige examinar qué información aporta cada dato, cómo se combina con otros resultados y qué supuestos intervienen en su interpretación. La evidencia se configura cuando los datos adquieren una función argumentativa dentro del proceso científico, lo que exige una conexión explícita entre información empírica, razonamiento y conclusión (Gough, 2021).

La relación entre observación y datos también está condicionada por los instrumentos y categorías utilizados para registrar el fenómeno. Los procedimientos de medición seleccionan determinados aspectos de la realidad y los representan mediante escalas o valores que simplifican sus características. Esta transformación puede introducir incertidumbre porque el resultado registrado no reproduce de manera absoluta aquello que se observa. En determinadas

situaciones, el valor verdadero de una magnitud permanece desconocido y solo puede estimarse dentro de márgenes determinados. Por ello, interpretar los datos requiere considerar las condiciones de medición y las limitaciones asociadas con su producción (Lee et al., 2022).

La evidencia adquiere mayor solidez cuando puede relacionarse transparentemente con las observaciones y los datos que la originan. Esta trazabilidad permite revisar cómo se produjo la información, qué transformaciones experimentó y mediante qué criterios se seleccionó para sustentar una conclusión. Cuando estas operaciones permanecen ocultas, resulta más difícil valorar si la evidencia representa adecuadamente el fenómeno o si responde a decisiones analíticas insuficientemente justificadas. La transparencia metodológica permite distinguir entre una conclusión respaldada por datos pertinentes y otra sustentada en interpretaciones que exceden la capacidad justificativa de las observaciones disponibles (Rickinson et al., 2021).

Tabla 4

Relación entre observación, datos y evidencia en el proceso científico

Elemento	Función principal	Transformación necesaria	Resultado dentro de la investigación
Observación	Identificar características o acontecimientos	Registro mediante procedimientos definidos	Información inicial sobre el fenómeno
Medición	Asignar valores o categorías	Aplicación de instrumentos y escalas	Registro comparable y analizable
Dato	Representar la información obtenida	Organización, codificación y depuración	Base empírica del análisis
Análisis	Identificar patrones y relaciones	Aplicación de criterios metodológicos	Resultados interpretables
Evidencia	Respaldar o cuestionar una afirmación	Relación entre resultados y problema científico	Fundamento de la inferencia
Conclusión	Formular una respuesta sustentada	Integración de evidencia y razonamiento	Afirmación delimitada por los datos

Nota. La secuencia muestra que la evidencia surge de un proceso de transformación e interpretación y no de la simple acumulación de observaciones o registros.

La interpretación constituye un punto decisivo entre los datos y la evidencia, porque determina qué relaciones se consideran relevantes y qué significado reciben los resultados. Los procedimientos analíticos permiten identificar patrones, asociaciones o diferencias que no siempre son visibles en los registros iniciales. Sin embargo, estas operaciones incorporan supuestos que deben ser examinados para evitar que el análisis atribuya a los datos significados que no pueden sostener. Una interpretación crítica requiere valorar simultáneamente la calidad metodológica de los registros y la coherencia entre los resultados obtenidos y las conclusiones derivadas de ellos (Olaghere et al., 2023).

La observación científica tampoco es completamente independiente de los marcos conceptuales utilizados para organizarla. Las categorías disponibles influyen en aquello que se considera relevante, en la forma de describirlo y en los procedimientos seleccionados para convertirlo en datos. Esta condición no elimina el contenido empírico de la investigación, pero obliga a reconocer que la evidencia se construye mediante relaciones entre observación y teoría. Los datos adquieren significado cuando se integran en explicaciones que permiten establecer por qué determinados registros respaldan una interpretación y no otra, manteniendo visible la trayectoria que conecta el fenómeno observado con la afirmación científica (Duschl et al., 2021).

La abundancia de datos introduce desafíos adicionales en esta relación. Los sistemas de gran escala pueden generar cantidades de información que exceden la capacidad de revisión directa de los investigadores, por lo que se utilizan procedimientos computacionales para identificar regularidades y seleccionar variables relevantes. Sin embargo, el volumen de datos no determina automáticamente su valor evidencial. La interpretación continúa dependiendo del conocimiento especializado necesario para evaluar qué patrones son científicamente significativos y cuáles pueden responder a características accidentales del conjunto analizado. La evidencia exige integrar capacidad computacional con criterios conceptuales y metodológicos que permitan justificar las conclusiones obtenidas (Hansen & Quinon, 2023).

La relación entre observación, datos y evidencia puede comprenderse como un proceso continuo de transformación y evaluación. Las observaciones proporcionan registros iniciales, los datos organizan esa información y la evidencia emerge cuando dichos datos adquieren capacidad para respaldar una afirmación. Cada transición incorpora decisiones que pueden fortalecer o limitar la inferencia posterior. Por ello, la calidad del conocimiento no depende únicamente del resultado final, sino también de que exista coherencia entre la forma de observar, el procedimiento empleado para producir datos y la interpretación mediante la cual estos se convierten en fundamentos de una conclusión científica (Gough, 2021).

2.3 Criterios para valorar la solidez de la evidencia

La solidez de la evidencia depende de la calidad de los procedimientos mediante los cuales se obtiene, analiza e interpreta la información. No basta con disponer de resultados para considerar que una afirmación está suficientemente respaldada. Es necesario examinar la correspondencia entre la pregunta de investigación, el diseño metodológico, los datos producidos y la conclusión formulada. Una evidencia sólida muestra una relación justificable

entre estos elementos y permite identificar con claridad las condiciones bajo las cuales puede aceptarse una afirmación. La valoración debe considerar también posibles explicaciones alternativas y limitaciones que reduzcan la fuerza del respaldo disponible (Gough, 2021).

La pertinencia constituye otro criterio fundamental. Una fuente puede presentar elevada calidad metodológica y, sin embargo, ofrecer evidencia limitada para una pregunta distinta de aquella que orientó su producción. Valorar la pertinencia implica determinar hasta qué punto los datos, la población, el contexto y las variables analizadas corresponden con el problema que se pretende resolver. La utilización adecuada de evidencia requiere considerar no solo sus características internas, sino también la forma en que se incorpora a una decisión o argumento específico. Esta relación evita trasladar resultados fuera de condiciones en las que conservan capacidad justificativa suficiente (Rickinson et al., 2021).

La consistencia entre resultados proporciona información adicional sobre la solidez de un cuerpo de evidencia. Cuando diferentes estudios que investigan preguntas comparables obtienen conclusiones semejantes, aumenta la posibilidad de que el patrón observado no dependa exclusivamente de condiciones particulares de una investigación. Sin embargo, la consistencia no debe evaluarse únicamente mediante semejanza superficial. Es necesario examinar diferencias entre poblaciones, diseños, intervenciones y procedimientos analíticos. La presencia de heterogeneidad puede revelar variaciones relevantes que deben mantenerse visibles durante la síntesis, en lugar de ser eliminadas para producir artificialmente una conclusión uniforme (Pedder et al., 2022).

La evaluación crítica de la evidencia también requiere examinar la adecuación metodológica de cada estudio. Los criterios aplicables pueden variar según se trate de investigaciones cuantitativas, cualitativas o de diseños que combinan diferentes aproximaciones. Una valoración rigurosa debe atender a las características propias del método empleado y no aplicar automáticamente estándares diseñados para otro tipo de investigación. La calidad de los hallazgos depende de factores como la coherencia del diseño, la transparencia del análisis y la correspondencia entre los datos y la interpretación. Esta perspectiva permite comparar evidencia diversa sin reducir su valoración a un único criterio metodológico (Olaghere et al., 2023).

La transparencia constituye un criterio transversal para valorar la solidez de la evidencia. Un resultado resulta más evaluable cuando se conocen las decisiones metodológicas, los procedimientos de análisis y las limitaciones que condicionan su interpretación. La

transparencia permite determinar qué aspectos del conocimiento están bien respaldados y cuáles conservan incertidumbre relevante. También facilita distinguir entre confianza razonable y certeza injustificada. Una evidencia sólida no necesita eliminar toda incertidumbre, pero sí debe permitir identificarla y valorar cómo afecta las conclusiones. Esta condición resulta central para establecer una relación proporcionada entre la fuerza de los datos y el grado de confianza atribuido a una afirmación (Covitt & Anderson, 2022).


Tabla 5
Criterios para valorar la solidez de la evidencia científica

Criterio	Pregunta de valoración	Indicador principal	Riesgo si no se cumple
Calidad metodológica	¿El procedimiento fue adecuado?	Coherencia entre diseño y objetivo	Resultados poco confiables
Pertinencia	¿La evidencia responde al problema?	Correspondencia con población y contexto	Aplicación fuera de alcance
Consistencia	¿Los resultados convergen?	Concordancia entre estudios comparables	Conclusiones inestables
Transparencia	¿El proceso puede examinarse?	Métodos y decisiones explícitos	Dificultad para evaluar el resultado
Robustez	¿La conclusión resiste cambios razonables?	Estabilidad ante análisis alternativos	Dependencia excesiva de supuestos
Suficiencia	¿La evidencia disponible permite sostener la afirmación?	Relación proporcional entre datos y conclusión	Sobreinterpretación

Nota. Los criterios permiten valorar conjuntamente la calidad interna de la evidencia, su pertinencia para el problema y la estabilidad de las conclusiones derivadas.

La robustez constituye otro elemento relevante porque permite determinar si una conclusión permanece estable ante modificaciones razonables en los procedimientos analíticos o en los supuestos del modelo. Un resultado que cambia sustancialmente cuando se introduce una pequeña variación metodológica requiere mayor cautela que otro que permanece consistente bajo diferentes especificaciones. Esta sensibilidad resulta especialmente importante cuando los modelos son complejos o cuando existe ruido en los datos. La evaluación de la solidez debe considerar, por tanto, si la inferencia depende de una única configuración analítica o si conserva respaldo al explorar alternativas plausibles (Fajardo-Fontiveros et al., 2023).

Figura 2
Criterios integrados para valorar la solidez de la evidencia científica



Nota. La organización relaciona los criterios que permiten examinar la calidad, pertinencia, estabilidad y suficiencia del respaldo científico antes de formular conclusiones.

La suficiencia de la evidencia debe valorarse en relación con la fuerza de la afirmación que se pretende sostener. Una conclusión limitada puede estar adecuadamente respaldada por un conjunto moderado de datos, mientras que una afirmación general o causal exige evidencia más amplia y procedimientos capaces de excluir explicaciones alternativas. Este criterio evita tratar la solidez como una propiedad absoluta de una fuente. Lo relevante es determinar si el cuerpo de evidencia disponible ofrece razones suficientes para la conclusión concreta

formulada. La distancia entre evidencia y afirmación aumenta cuando los datos son escasos o indirectos, lo que exige mayor cautela inferencial (Woensdregt et al., 2024).

La solidez también puede evaluarse considerando el grado de incertidumbre asociado con los resultados. Intervalos amplios, estimaciones sensibles o evidencia incompleta no invalidan automáticamente una investigación, pero modifican la confianza que puede atribuirse a sus conclusiones. La valoración debe distinguir entre resultados con incertidumbre cuantificada y afirmaciones cuya incertidumbre permanece poco caracterizada. Cuando los límites son explícitos, resulta posible ajustar la interpretación al nivel real de conocimiento disponible. Esta práctica contribuye a evitar conclusiones excesivamente categóricas y permite establecer qué información adicional podría modificar de manera relevante la evaluación existente (Schnarr & Mertz, 2022).

Valorar la solidez de la evidencia exige integrar calidad metodológica, pertinencia, consistencia, transparencia, robustez y suficiencia sin reducir el proceso a un único indicador. Ninguno de estos criterios funciona de manera aislada, porque una evidencia metodológicamente rigurosa puede resultar poco pertinente y un resultado consistente puede depender de procedimientos compartidos que reproduzcan las mismas limitaciones. La evaluación debe examinar cómo se relacionan estas dimensiones dentro de un cuerpo de conocimiento concreto. Esta aproximación permite fundamentar la confianza científica en razones explícitas y revisables, en lugar de atribuir credibilidad únicamente por la cantidad de estudios o por la autoridad de una fuente (Metzen, 2024).

2.4 Evidencia directa e indirecta en la investigación

La evidencia directa se obtiene cuando existe una relación inmediata entre la observación realizada y la afirmación que se pretende sostener. Su fuerza depende de que el fenómeno pueda examinarse mediante datos estrechamente vinculados con el objeto de estudio, reduciendo la cantidad de pasos inferenciales necesarios. Esto no significa que la evidencia directa esté libre de interpretación, porque toda observación requiere procedimientos de registro y análisis. Sin embargo, cuando la conexión entre dato y conclusión es más próxima, resulta más sencillo evaluar la pertinencia de la información y detectar posibles limitaciones metodológicas que afecten la inferencia (Duschl et al., 2021).

La evidencia indirecta aparece cuando la afirmación no puede sustentarse mediante una observación inmediata y requiere conectar distintos elementos mediante inferencias intermedias. Este tipo de evidencia es frecuente en campos donde los fenómenos no son

directamente accesibles, los datos son escasos o las variables relevantes deben inferirse a partir de indicadores. La distancia entre observación y conclusión puede aumentar la incertidumbre, porque cada paso introduce supuestos que deben justificarse. Aun así, la evidencia indirecta puede ser científicamente válida si las conexiones inferenciales están bien fundamentadas y se consideran explicaciones alternativas compatibles con los datos disponibles (Woensdregt et al., 2024).

La distinción entre evidencia directa e indirecta no debe interpretarse como una jerarquía rígida. Una evidencia directa puede ser débil si procede de mediciones imprecisas o de diseños poco adecuados, mientras que una evidencia indirecta puede resultar sólida cuando distintas fuentes convergen y los supuestos que conectan los datos con la conclusión están bien establecidos. La calidad depende de la estructura completa de la justificación y no solo de la proximidad entre observación y afirmación. Por ello, valorar la evidencia exige examinar su pertinencia, consistencia, transparencia y capacidad para excluir interpretaciones alternativas relevantes (Gough, 2021).

En muchos procesos científicos, la evidencia directa e indirecta se complementan. Las observaciones inmediatas pueden proporcionar información inicial sobre un fenómeno, mientras que modelos, comparaciones y datos secundarios amplían la explicación hacia relaciones que no pueden registrarse directamente. Esta combinación permite construir argumentos más completos, especialmente cuando el objeto de estudio presenta múltiples niveles de análisis. Sin embargo, integrar diferentes tipos de evidencia requiere distinguir con claridad qué resultados provienen de observaciones directas y cuáles dependen de inferencias adicionales. Esa separación ayuda a identificar dónde se concentra la incertidumbre y qué elementos del razonamiento requieren mayor justificación (Arias Valencia, 2022).

La triangulación constituye una estrategia útil cuando se pretende fortalecer conclusiones sustentadas por evidencia de diferente naturaleza. La combinación de métodos, fuentes o perspectivas permite examinar si distintos procedimientos conducen hacia interpretaciones compatibles. La convergencia no elimina automáticamente la incertidumbre, pero puede reducir la dependencia de una única fuente o técnica. También puede revelar discrepancias que obliguen a revisar la explicación propuesta. La utilidad de la triangulación radica en utilizar la diversidad de evidencias para evaluar la estabilidad de una conclusión, no en acumular resultados sin considerar sus diferencias metodológicas y epistemológicas (Arias Valencia, 2022).

Tabla 6*Diferencias entre evidencia directa e indirecta en la investigación*

Criterio	Evidencia directa	Evidencia indirecta
Relación con el fenómeno	Observación o medición próxima al objeto estudiado	Relación mediada por indicadores, modelos o inferencias
Número de pasos inferenciales	Menor	Mayor
Dependencia de supuestos	Generalmente más limitada	Mayor dependencia de supuestos intermedios
Riesgo principal	Sobreinterpretar una observación puntual	Acumular incertidumbre entre pasos inferenciales
Forma de validación	Calidad de observación y medición	Coherencia de la cadena inferencial
Utilidad	Examinar propiedades accesibles directamente	Estudiar fenómenos no observables o evidencia escasa

Nota. La distinción se refiere a la distancia inferencial entre los datos y la afirmación, no a una superioridad automática de un tipo de evidencia sobre el otro.

La evidencia indirecta adquiere especial importancia cuando la observación directa resulta imposible, costosa o insuficiente. En estos casos, los investigadores recurren a variables sustitutas, modelos teóricos, registros históricos o patrones derivados de otras fuentes. La validez de la conclusión depende entonces de que exista una relación suficientemente justificada entre el indicador y el fenómeno que se pretende explicar. Cuanto mayor sea la distancia entre ambos, mayor debe ser la atención dedicada a los supuestos intermedios y a la posibilidad de que otras explicaciones produzcan resultados compatibles con los mismos datos (Woensdregt et al., 2024).

La evaluación de evidencia indirecta también exige considerar la convergencia entre estudios independientes. Cuando diferentes investigaciones, métodos o fuentes respaldan una misma interpretación, la acumulación puede fortalecer una conclusión aunque ninguna observación individual sea decisiva. Sin embargo, la convergencia debe examinarse críticamente, porque varios estudios pueden compartir sesgos, supuestos o procedimientos que reproduzcan una misma limitación. La consistencia resulta más informativa cuando proviene de diseños suficientemente diversos y cuando las diferencias entre estudios se analizan en lugar de ocultarse bajo una estimación conjunta (Pedder et al., 2022).

La evidencia directa también requiere cautela porque la proximidad al fenómeno no elimina los problemas de medición. Un registro puede parecer inmediato y, sin embargo, depender de instrumentos, escalas o condiciones que introducen incertidumbre. La interpretación debe considerar la precisión del procedimiento y distinguir entre el valor observado y aquello que

se pretende medir. Esta exigencia evita asumir que una observación directa representa de manera completa el fenómeno. La fuerza de la evidencia depende de la calidad del proceso mediante el cual la información se produce, se transforma en datos y se relaciona con una afirmación científica (Lee et al., 2022).

La distinción entre evidencia directa e indirecta permite comprender mejor cómo se construyen las justificaciones científicas. La primera reduce la distancia entre observación y afirmación, mientras que la segunda amplía la capacidad de investigar fenómenos inaccesibles mediante conexiones inferenciales. Ninguna garantiza por sí sola una conclusión sólida. La valoración debe atender a la calidad metodológica, la transparencia de los supuestos, la consistencia entre fuentes y la capacidad de responder a explicaciones alternativas. Esta perspectiva permite integrar distintos tipos de evidencia sin confundir proximidad empírica con certeza ni distancia inferencial con debilidad necesaria (Gough, 2021).

2.5 Justificación de afirmaciones científicas bajo condiciones de incertidumbre

La justificación de afirmaciones científicas bajo condiciones de incertidumbre exige establecer una relación proporcional entre la evidencia disponible y la fuerza de la conclusión formulada. Una afirmación no necesita estar libre de toda duda para considerarse razonablemente sustentada, pero sí debe mostrar qué datos la respaldan, qué supuestos intervienen y qué limitaciones permanecen abiertas. La calidad de la justificación depende de que puedan distinguirse las razones que apoyan la conclusión de aquellas que solo la hacen plausible. Esta correspondencia evita presentar como conocimiento consolidado aquello que todavía depende de evidencia incompleta o de interpretaciones sujetas a revisión (Gough, 2021).

Cuando la evidencia disponible es limitada, la justificación debe incorporar explícitamente el grado de incertidumbre asociado con la inferencia. Esto implica reconocer si existen datos insuficientes, resultados sensibles a determinados supuestos o alternativas explicativas todavía plausibles. La incertidumbre no invalida automáticamente una afirmación, pero modifica el nivel de seguridad con que puede presentarse. Una conclusión científicamente responsable debe indicar hasta dónde llega su respaldo y qué aspectos permanecen abiertos. Esta práctica permite diferenciar entre una afirmación provisional bien fundamentada y una interpretación que excede la capacidad justificativa de los datos existentes (Schnarr & Mertz, 2022).

La formulación lingüística cumple una función central en este proceso porque el modo de expresar una conclusión comunica implícitamente su nivel de certeza. Verbos y expresiones como “indica”, “sugiere”, “es compatible con” o “probablemente” permiten ajustar el alcance

de una afirmación cuando la evidencia no justifica una formulación categórica. El uso de estas expresiones debe responder a condiciones reales del estudio y no convertirse en una estrategia retórica automática. Una justificación adecuada requiere que la cautela lingüística refleje de manera fiel el grado de respaldo empírico y las limitaciones de la inferencia realizada (Ward & Creel, 2024).

La justificación también depende de la calidad de la evidencia utilizada. Una conclusión basada en datos pertinentes, procedimientos transparentes y métodos adecuados posee mayor sustento que otra construida sobre información incompleta o escasamente relacionada con la pregunta investigada. La evaluación debe considerar si las fuentes utilizadas ofrecen razones suficientes para aceptar provisionalmente la afirmación y si existen factores que reduzcan su capacidad de respaldo. La calidad metodológica por sí sola no garantiza una justificación sólida; también es necesario que la evidencia sea relevante para el problema concreto y que la interpretación permanezca dentro de los límites del diseño (Rickinson et al., 2021).

La existencia de explicaciones alternativas obliga a reforzar la estructura justificativa de una afirmación. Cuando varios mecanismos pueden producir resultados semejantes, no basta con demostrar que una hipótesis es compatible con los datos. Es necesario examinar si existen razones para preferirla frente a otras posibilidades. Esta comparación puede requerir evidencia adicional, análisis de sensibilidad o contrastación entre modelos. En condiciones de incertidumbre, la justificación aumenta cuando la conclusión no solo encuentra apoyo empírico, sino que también resiste la consideración de alternativas plausibles que podrían explicar el mismo patrón observado (Woensdregt et al., 2024).

La probabilidad ofrece una herramienta formal para expresar grados de respaldo cuando las afirmaciones no pueden clasificarse simplemente como verdaderas o falsas. Los enfoques bayesianos permiten actualizar la credibilidad relativa de una hipótesis a medida que se incorpora nueva evidencia, integrando información previa y datos observados. Este procedimiento facilita representar explícitamente la incertidumbre y comparar hipótesis bajo condiciones de conocimiento incompleto. Sin embargo, la fuerza de la justificación depende también de la adecuación del modelo y de los supuestos probabilísticos empleados, por lo que la cuantificación no sustituye la evaluación crítica de las condiciones que sustentan la inferencia (Wei et al., 2022).

La justificación científica debe considerar además la consistencia de los resultados con otras investigaciones relevantes. Una afirmación obtiene mayor respaldo cuando se integra

coherentemente con evidencia independiente, aunque la ausencia de convergencia no implique necesariamente que sea falsa. Las discrepancias pueden revelar diferencias de contexto, población, diseño o procedimiento analítico. Por ello, la consistencia debe examinarse de manera crítica y no utilizarse como criterio mecánico. La comparación entre estudios permite valorar si una conclusión mantiene estabilidad bajo condiciones diversas o si depende excesivamente de circunstancias específicas que limitan su generalización (Pedder et al., 2022).

La transparencia sobre los límites del conocimiento forma parte de una justificación adecuada. Una afirmación resulta más evaluable cuando se explicitan los datos utilizados, las decisiones metodológicas y las condiciones que podrían modificar la interpretación. Esta transparencia favorece una confianza basada en razones verificables y no en la apariencia de certeza. Reconocer incertidumbres relevantes permite que otros investigadores identifiquen qué aspectos están sólidamente sustentados y cuáles requieren nuevas pruebas. La confianza científica se fortalece cuando las conclusiones muestran con claridad tanto sus fundamentos como las condiciones bajo las cuales podrían ser revisadas (Metzen, 2024).

En escenarios con muestras pequeñas o evidencia preliminar, la justificación debe ser especialmente cuidadosa. La escasez de información puede producir estimaciones inestables y amplios márgenes de incertidumbre, por lo que una conclusión inicial no debería presentarse como definitiva. En estos casos, resulta útil considerar cuánta evidencia adicional sería necesaria para modificar sustancialmente la interpretación o aumentar la credibilidad del resultado. Esta perspectiva permite transformar la incertidumbre en una pregunta concreta sobre la suficiencia de los datos y evita que la decisión científica dependa exclusivamente de umbrales estadísticos o de resultados aislados (Sondhi et al., 2021).

La justificación bajo incertidumbre también requiere distinguir entre afirmaciones descriptivas, explicativas y causales. Cada tipo de conclusión exige un nivel diferente de respaldo y no puede sustentarse mediante los mismos procedimientos. Una asociación observada puede justificar una descripción del patrón, pero no necesariamente una explicación causal. Elevar el alcance de la afirmación sin evidencia adicional introduce una distancia injustificada entre datos y conclusión. La solidez del razonamiento depende de mantener correspondencia entre lo que el diseño permite observar y el tipo de conocimiento que se pretende derivar de esos resultados (Gough, 2021).

Justificar afirmaciones científicas en presencia de incertidumbre implica aceptar que el conocimiento puede ser sólido sin ser definitivo. La tarea no consiste en eliminar toda duda,

sino en mostrar de manera explícita qué razones respaldan una conclusión y qué limitaciones condicionan su alcance. Una buena justificación integra evidencia pertinente, análisis de alternativas, transparencia metodológica y un lenguaje proporcional al grado de respaldo disponible. Esta combinación permite formular conclusiones revisables sin reducirlas a opiniones arbitrarias y mantiene una relación coherente entre evidencia, inferencia y confianza dentro del proceso científico (Covitt & Anderson, 2022).



Capítulo 3.



Construcción y evaluación de la evidencia

María Andrea Zambrano Delgado

3.1 Producción de datos en los procesos científicos

La producción de datos constituye una etapa central de los procesos científicos porque determina qué información estará disponible para analizar un fenómeno. Los datos no aparecen de forma espontánea, sino que se generan mediante decisiones sobre qué observar, a quién incluir, qué instrumentos utilizar y bajo qué condiciones registrar la información. Estas elecciones condicionan posteriormente la calidad de las inferencias. Una estrategia de generación de datos adecuada debe guardar relación con la pregunta de investigación y con el tipo de evidencia que se pretende construir, ya que procedimientos mal alineados pueden limitar desde el inicio la capacidad explicativa del estudio (Jack et al., 2023).

La selección de técnicas de producción de datos depende de la naturaleza del objeto estudiado y de los objetivos planteados. Entrevistas, observaciones, experimentos, registros instrumentales, cuestionarios o bases de datos producen información con características distintas y no son intercambiables sin considerar sus implicaciones metodológicas. Cada técnica establece qué aspectos del fenómeno pueden captarse y cuáles permanecen fuera del registro. Por ello, la producción científica de datos exige justificar la elección del procedimiento y explicitar sus límites. Esta relación entre método, objeto y evidencia permite valorar posteriormente si los datos obtenidos resultan pertinentes para sostener las conclusiones formuladas (Rickinson et al., 2021).

La calidad de los datos depende también de la estandarización y consistencia con que se aplican los procedimientos. Cambios en las condiciones de observación, diferencias en los criterios de registro o variaciones en el uso de instrumentos pueden introducir heterogeneidad que dificulte distinguir entre variación real y distorsión metodológica. En investigaciones cuantitativas, estos problemas pueden afectar la precisión de las estimaciones; en estudios cualitativos, pueden modificar la profundidad o comparabilidad de los registros. La producción de datos requiere, por tanto, procedimientos suficientemente claros para que pueda evaluarse cómo se obtuvo la información y qué factores pudieron influir en ella (Lee et al., 2022).

La generación de datos está vinculada con decisiones conceptuales previas. Antes de registrar información, los investigadores deben definir qué características del fenómeno consideran relevantes y cómo serán traducidas en variables, categorías o indicadores. Esta operación transforma conceptos teóricos en criterios observables y condiciona el tipo de información que se producirá. Cuando las definiciones son ambiguas o las categorías representan de manera limitada el objeto de estudio, los datos pueden resultar técnicamente correctos pero

conceptualmente débiles. La evidencia posterior depende, por ello, de que exista coherencia entre los conceptos empleados, los procedimientos de observación y la forma concreta en que se registran los resultados (Duschl et al., 2021).

La producción de datos también puede verse afectada por restricciones de acceso, tamaño muestral, disponibilidad temporal o condiciones del contexto investigado. Estas limitaciones no invalidan necesariamente el estudio, pero deben reconocerse porque pueden reducir la cobertura del fenómeno y aumentar la incertidumbre de las conclusiones. En muestras pequeñas, por ejemplo, la evidencia obtenida puede ser insuficiente para sostener generalizaciones amplias o estimaciones estables. Evaluar la suficiencia de los datos exige considerar cuánto respaldo ofrecen realmente para la pregunta planteada y qué información adicional podría modificar la interpretación inicial de los resultados (Sondhi et al., 2021).

Tabla 7

Componentes de la producción de datos en los procesos científicos

Componente	Decisión principal	Riesgo asociado	Criterio de control
Delimitación del fenómeno	Qué se observará	Exclusión de aspectos relevantes	Coherencia conceptual
Selección de casos	Quiénes o qué unidades se incluirán	Sesgo de cobertura	Adecuación de la muestra
Instrumentación	Cómo se registrará la información	Error de medición	Validez y precisión
Condiciones de registro	Cuándo y dónde se obtendrán los datos	Variabilidad contextual	Estandarización
Codificación	Cómo se organizarán los registros	Pérdida o distorsión de información	Criterios explícitos
Documentación	Cómo se conservará el proceso	Falta de trazabilidad	Registro metodológico completo

Nota. Los componentes muestran que la calidad de los datos depende de decisiones sucesivas que deben mantenerse coherentes con el problema, el diseño y el tipo de evidencia buscada.

La trazabilidad constituye un criterio importante porque permite reconstruir cómo se produjo cada conjunto de datos. Registrar los procedimientos, condiciones, instrumentos y transformaciones aplicadas facilita evaluar si la información conserva correspondencia con el fenómeno estudiado. Esta documentación resulta especialmente relevante cuando los datos atraviesan varias etapas de limpieza, codificación o procesamiento antes de incorporarse al análisis. La posibilidad de revisar estas operaciones contribuye a distinguir entre modificaciones justificadas y alteraciones que podrían afectar la interpretación. La producción de datos adquiere mayor solidez cuando el recorrido desde la observación inicial hasta el registro analizable puede examinarse de manera transparente (Burrows, 2023).

La producción de datos puede fortalecerse mediante estrategias de triangulación cuando un mismo fenómeno se examina con diferentes fuentes, técnicas o perspectivas. La finalidad no consiste en acumular información de manera indiscriminada, sino en contrastar si distintos procedimientos producen resultados compatibles o revelan aspectos complementarios. La convergencia puede aumentar la confianza en determinadas interpretaciones, mientras que las discrepancias pueden señalar limitaciones del método o dimensiones del fenómeno que requieren análisis adicional. Esta estrategia resulta particularmente útil cuando ninguna técnica individual permite captar de manera suficiente la complejidad del objeto estudiado (Arias Valencia, 2022).

En contextos de grandes volúmenes de información, la producción de datos incorpora nuevas fuentes y procedimientos automatizados. Sensores, plataformas digitales, repositorios y sistemas computacionales pueden generar registros continuos y de gran escala, pero la cantidad no sustituye la necesidad de evaluar calidad, contexto y pertinencia. Los datos masivos pueden contener sesgos de selección, problemas de representación o patrones cuya relevancia no es evidente sin conocimiento especializado. La construcción de evidencia exige entonces combinar capacidad técnica para procesar grandes conjuntos con criterios científicos que permitan determinar qué información resulta significativa para la pregunta investigada (Hansen & Quinon, 2023).

La producción de datos debe entenderse como un proceso metodológico que condiciona todo el desarrollo posterior de la investigación. La calidad de las conclusiones depende de decisiones tomadas antes del análisis, desde la definición del fenómeno hasta la forma de documentar cada registro. Datos abundantes pero conceptualmente débiles o metodológicamente inconsistentes pueden ofrecer menor respaldo que conjuntos más limitados producidos bajo condiciones claras y pertinentes. Por ello, evaluar la evidencia exige revisar cómo se generaron los datos, qué restricciones afectaron su obtención y hasta qué punto representan adecuadamente el objeto sobre el cual se formulan las afirmaciones científicas (Jack et al., 2023).

3.2 Calidad y confiabilidad de las fuentes de evidencia

La calidad de una fuente de evidencia depende de las condiciones bajo las cuales se produjo la información y de la transparencia con que pueden examinarse sus procedimientos. Una fuente confiable debe permitir identificar su diseño, criterios de selección, técnicas de análisis y limitaciones, porque estos elementos condicionan la fuerza de las conclusiones que pueden derivarse. La confiabilidad no surge únicamente del prestigio del medio de publicación, sino

de la posibilidad de evaluar cómo se obtuvo y procesó la evidencia. Esta perspectiva permite distinguir entre autoridad editorial y solidez metodológica dentro de la valoración científica (Rickinson et al., 2021).

La pertinencia constituye otro criterio necesario para valorar una fuente. Una investigación puede presentar procedimientos rigurosos y, sin embargo, aportar evidencia limitada para un problema distinto del que originalmente examinó. La población estudiada, el contexto, las variables y el periodo de observación determinan hasta qué punto los resultados pueden utilizarse para sustentar nuevas afirmaciones. Evaluar una fuente exige comprobar la correspondencia entre sus características y la pregunta que se pretende responder. La confiabilidad de la evidencia depende así tanto de su calidad interna como de su adecuación al uso específico que se le atribuye (Gough, 2021).

La reproducibilidad aporta información relevante sobre la confiabilidad porque permite verificar si los resultados pueden obtenerse nuevamente a partir de procedimientos, datos y análisis suficientemente documentados. La posibilidad de reconstruir un resultado facilita detectar errores, inconsistencias o decisiones analíticas que podrían haber influido en las conclusiones. Sin embargo, reproducibilidad y confiabilidad no son conceptos idénticos: un procedimiento puede reproducirse correctamente y conservar limitaciones metodológicas. Por ello, la evaluación debe integrar la reproducibilidad con otros criterios relacionados con la validez de los datos, la pertinencia del diseño y la interpretación de los hallazgos (Helliwell & Massera, 2022).

La apertura de datos, códigos y procedimientos puede mejorar la evaluación de las fuentes al permitir una revisión más detallada de las decisiones que sustentan los resultados. Las prácticas abiertas facilitan comprobar análisis, detectar errores y reutilizar información para nuevas preguntas científicas. No obstante, la simple disponibilidad de materiales no garantiza por sí sola una evidencia de alta calidad. Los datos deben contar con documentación suficiente y los procedimientos analíticos deben ser comprensibles para que la transparencia contribuya realmente a la confiabilidad. La apertura funciona como un mecanismo de evaluación cuando permite examinar de manera efectiva cómo se produjo el resultado (Mathur & Fox, 2023).

La calidad de las fuentes también debe valorarse atendiendo al tipo de evidencia que producen. Estudios cuantitativos, cualitativos y mixtos requieren criterios de evaluación adaptados a sus respectivos diseños y objetivos. Aplicar un único estándar puede llevar a descartar información pertinente o a sobrevalorar resultados que cumplen formalmente ciertos requisitos sin

responder adecuadamente a la pregunta de investigación. La evaluación crítica debe examinar coherencia metodológica, transparencia analítica y relación entre los datos y las interpretaciones. Esta aproximación permite juzgar la confiabilidad de cada fuente según las condiciones específicas de producción del conocimiento (Olaghere et al., 2023).

Tabla 8

Criterios para evaluar la calidad y confiabilidad de las fuentes de evidencia

Criterio	Aspecto evaluado	Indicador de calidad	Señal de precaución
Pertinencia	Correspondencia con la pregunta	Población, variables y contexto adecuados	Aplicación fuera del alcance original
Transparencia	Visibilidad del procedimiento	Métodos y análisis documentados	Información metodológica insuficiente
Reproducibilidad	Posibilidad de reconstruir resultados	Datos, código y pasos disponibles	Procedimientos no verificables
Validez	Correspondencia entre medición y fenómeno	Instrumentos y diseño adecuados	Medidas poco justificadas
Consistencia	Estabilidad de los resultados	Convergencia con análisis comparables	Resultados altamente sensibles
Independencia	Relación entre fuentes	Evidencia obtenida por equipos o métodos diversos	Dependencia de una única línea de evidencia

Nota. La evaluación combina características metodológicas, documentales y contextuales para determinar si una fuente puede sustentar de manera confiable una afirmación científica.

La consistencia de los resultados representa otro componente de la confiabilidad, especialmente cuando una afirmación depende de varias fuentes. La convergencia entre estudios puede aumentar el respaldo disponible, pero debe examinarse si las investigaciones son realmente comparables y si sus resultados proceden de procedimientos independientes. Una aparente consistencia puede ser engañosa cuando distintos trabajos comparten los mismos datos, supuestos o sesgos metodológicos. Por ello, la evaluación debe considerar tanto la similitud de los hallazgos como la diversidad de las condiciones bajo las cuales fueron obtenidos (Pedder et al., 2022).

La confiabilidad de una fuente también puede verse comprometida por problemas de documentación insuficiente. Cuando los procedimientos de análisis no se describen con precisión, resulta difícil determinar si los resultados dependen de decisiones particulares que podrían modificarse bajo otras condiciones. La verificabilidad exige conservar información sobre datos, transformaciones y métodos empleados para que otros investigadores puedan reconstruir el proceso. Esta exigencia adquiere especial importancia en investigaciones

computacionales, donde múltiples etapas de procesamiento pueden influir en los resultados sin ser visibles en la presentación final (Burrows, 2023).

La existencia de sesgos constituye otro factor que debe considerarse al valorar una fuente. Selección de datos, decisiones analíticas, exclusión de resultados o preferencias teóricas pueden modificar la evidencia disponible y producir interpretaciones distorsionadas. La evaluación crítica no consiste en asumir que toda investigación debe estar completamente libre de sesgos, sino en identificar cuáles pueden afectar las conclusiones y hasta qué punto han sido reconocidos o controlados. Una fuente resulta más confiable cuando expone sus limitaciones y permite examinar cómo determinadas decisiones pudieron influir en los resultados presentados (Hudson, 2021).

La confiabilidad de las fuentes de evidencia debe establecerse mediante una valoración conjunta de calidad metodológica, pertinencia, transparencia, reproducibilidad y posibles sesgos. Ninguno de estos criterios garantiza por separado la solidez de una fuente, pero su integración permite determinar con mayor precisión qué grado de respaldo puede atribuirse a sus resultados. Esta evaluación debe mantenerse vinculada con la afirmación que se pretende sostener, porque una misma fuente puede ser adecuada para una conclusión limitada y resultar insuficiente para otra más amplia. La confianza científica requiere, por tanto, correspondencia entre las propiedades de la fuente y el uso evidencial que se realiza de ella (Rickinson et al., 2021).

3.3 Triangulación y convergencia de evidencias

La triangulación se utiliza para examinar un mismo fenómeno mediante diferentes fuentes, métodos, teorías o perspectivas analíticas. Su finalidad no consiste en acumular información de manera indiscriminada, sino en contrastar resultados obtenidos por vías distintas y valorar si convergen hacia una interpretación compatible. Cuando diferentes procedimientos independientes producen hallazgos semejantes, aumenta la confianza en que la conclusión no depende exclusivamente de una única técnica. Sin embargo, la triangulación también puede revelar discrepancias relevantes, por lo que su utilidad incluye identificar tensiones que requieren revisión metodológica o teórica antes de formular una explicación consolidada (Arias Valencia, 2022).

La triangulación metodológica combina procedimientos diferentes dentro de una misma investigación o entre estudios relacionados. Puede integrar, por ejemplo, mediciones cuantitativas con entrevistas, observaciones o análisis documentales. Cada método capta

dimensiones distintas del fenómeno y puede compensar limitaciones presentes en otros procedimientos. La convergencia entre resultados obtenidos por métodos diferentes fortalece la interpretación cuando las técnicas utilizadas son suficientemente independientes y responden de manera coherente a la misma pregunta. La calidad de esta estrategia depende de justificar por qué se combinan los métodos y qué tipo de información aporta cada uno al argumento científico (Arias Valencia, 2022).

La triangulación de fuentes se basa en comparar información procedente de poblaciones, contextos, momentos o registros diferentes. Este procedimiento permite determinar si un patrón se mantiene más allá de una única fuente de datos y ayuda a identificar condiciones que modifican los resultados. La convergencia entre fuentes independientes puede aumentar la confianza en una interpretación, mientras que las discrepancias pueden mostrar heterogeneidad real o problemas de calidad. La comparación debe realizarse considerando las diferencias entre los conjuntos de datos, porque tratar como equivalentes fuentes producidas bajo condiciones distintas puede generar una apariencia artificial de consistencia (Rickinson et al., 2021).

La convergencia de evidencias no implica necesariamente que todos los resultados deban ser idénticos. Diferencias moderadas pueden ser compatibles con una misma explicación cuando responden a variaciones de contexto, población o procedimiento. Lo importante es establecer si los hallazgos mantienen una dirección o estructura coherente después de considerar esas diferencias. En síntesis de estudios, la consistencia se evalúa analizando simultáneamente semejanzas y heterogeneidad. Una conclusión resulta más sólida cuando puede explicar por qué ciertos resultados convergen y por qué otros difieren, en lugar de reducir toda la evidencia a una única estimación agregada (Pedder et al., 2022).

La triangulación también puede utilizarse para examinar explicaciones alternativas. Cuando diferentes tipos de evidencia apuntan hacia una misma interpretación, disminuye la posibilidad de que el resultado dependa de un único supuesto o indicador. Esta lógica adquiere importancia en investigaciones donde la evidencia directa es escasa y las conclusiones requieren varios pasos inferenciales. La convergencia entre líneas independientes puede reforzar una teoría siempre que las fuentes no compartan exactamente las mismas limitaciones. Si varias evidencias derivan del mismo conjunto de supuestos, su coincidencia aporta menos información que la convergencia obtenida mediante procedimientos realmente distintos (Woensdregt et al., 2024).

La independencia entre evidencias constituye una condición importante para valorar la fuerza de la triangulación. Dos estudios pueden producir resultados similares porque utilizan los mismos datos, instrumentos o modelos, lo que reduce el valor adicional de su coincidencia. La convergencia resulta más informativa cuando proviene de equipos, contextos o procedimientos que introducen fuentes de variación diferentes. Esta diversidad permite comprobar si un hallazgo permanece estable pese a cambios razonables en las condiciones de producción de la evidencia. Por ello, la triangulación debe examinar no solo cuántas fuentes coinciden, sino también hasta qué punto esas fuentes representan líneas de investigación realmente independientes (Gough, 2021).

La convergencia de evidencias puede fortalecerse mediante la combinación de hallazgos cuantitativos y cualitativos cuando ambos responden a dimensiones complementarias de un problema. Los datos cuantitativos permiten identificar magnitudes, asociaciones o patrones, mientras que los cualitativos pueden aportar información sobre mecanismos, contextos o significados. Integrar ambos tipos de evidencia exige respetar sus diferencias metodológicas y evitar que uno se utilice únicamente como complemento decorativo del otro. La evaluación conjunta debe considerar qué pregunta responde cada enfoque y cómo sus resultados contribuyen a una interpretación más completa del fenómeno investigado (Olaghere et al., 2023).


La triangulación no elimina automáticamente el sesgo. Diferentes métodos pueden reproducir una misma distorsión si parten de supuestos semejantes, utilizan fuentes relacionadas o comparten decisiones analíticas problemáticas. Por esta razón, la coincidencia entre resultados debe evaluarse junto con la calidad de cada línea de evidencia. La convergencia aporta mayor respaldo cuando las limitaciones de una fuente no se reproducen sistemáticamente en las demás. Este criterio obliga a analizar la estructura metodológica de la evidencia antes de interpretar la coincidencia como confirmación y evita que la repetición de un mismo sesgo sea confundida con estabilidad científica (Hudson, 2021).

La trazabilidad mejora la evaluación de la triangulación porque permite reconstruir cómo se obtuvo cada resultado y qué transformaciones se aplicaron antes de compararlo con otras evidencias. Esta información resulta especialmente importante en investigaciones computacionales o con grandes volúmenes de datos, donde diferentes etapas de procesamiento pueden producir aparentes convergencias derivadas de decisiones compartidas. Documentar los procedimientos facilita determinar si la coincidencia entre resultados refleja un patrón del fenómeno o una consecuencia del método utilizado. La convergencia adquiere mayor valor

cuando las rutas analíticas pueden revisarse y compararse de manera transparente (Burrows, 2023).

Figura 3

Triangulación y convergencia de evidencias en la investigación



Nota. El esquema sintetiza los principales criterios para contrastar evidencias y valorar la solidez de una interpretación científica.

Las discrepancias entre evidencias también poseen valor científico. Cuando dos métodos o fuentes producen resultados diferentes, la respuesta no debería limitarse a seleccionar el resultado considerado más conveniente. La divergencia puede revelar problemas de medición, diferencias de contexto, variables omitidas o mecanismos que solo aparecen bajo determinadas condiciones. Analizar estas discrepancias permite refinar las preguntas de investigación y

formular nuevas hipótesis. En este sentido, la triangulación funciona tanto como estrategia de confirmación como procedimiento para detectar límites de las explicaciones existentes y reconocer dónde la evidencia permanece insuficiente o contradictoria (Arias Valencia, 2022).

La convergencia de evidencias fortalece una conclusión cuando surge de líneas de investigación pertinentes, metodológicamente sólidas y suficientemente independientes. Su valor no depende del simple número de fuentes coincidentes, sino de la calidad de las conexiones entre los datos, los métodos y la afirmación que se pretende justificar. Una triangulación bien diseñada permite identificar patrones estables, reconocer discrepancias y reducir la dependencia de una única perspectiva. Esta combinación contribuye a construir argumentos más robustos, siempre que las diferencias entre evidencias se mantengan visibles y se analicen como parte del proceso de evaluación científica (Gough, 2021).

3.4 Consistencia de resultados entre diferentes estudios

La consistencia de resultados entre diferentes estudios permite valorar hasta qué punto un hallazgo se mantiene cuando cambia el contexto, la muestra, el equipo investigador o el procedimiento utilizado. La coincidencia entre investigaciones independientes puede aumentar la confianza en una conclusión porque reduce la posibilidad de que dependa exclusivamente de condiciones particulares. Sin embargo, la consistencia no exige resultados idénticos. Es necesario analizar si las diferencias observadas pueden explicarse por variaciones metodológicas, poblacionales o contextuales antes de considerar que existe una contradicción real entre estudios que examinan un mismo fenómeno (Pedder et al., 2022).

La comparación entre estudios requiere distinguir entre variabilidad esperable e inconsistencia sustantiva. Dos investigaciones pueden obtener estimaciones diferentes y seguir siendo compatibles si sus intervalos, poblaciones o condiciones experimentales no son equivalentes. La interpretación debe centrarse en determinar si las diferencias modifican la dirección o el significado principal del hallazgo. Una evaluación limitada a comparar cifras aisladas puede generar una percepción exagerada de contradicción. La consistencia debe analizarse considerando la estructura completa de la evidencia y las condiciones bajo las cuales se produjeron los resultados (Omerovic, 2023).

Los resultados contradictorios no implican necesariamente que uno de los estudios sea incorrecto. Diferencias en criterios de inclusión, características de los participantes, intervenciones o procedimientos de análisis pueden producir conclusiones distintas sin que exista un error metodológico evidente. Examinar estas condiciones permite identificar si los

estudios responden realmente a la misma pregunta o si existen diferencias suficientes para justificar resultados divergentes. La comparación crítica evita interpretar toda discrepancia como una falla de la ciencia y permite reconocer que la variabilidad entre investigaciones puede aportar información sobre los límites de generalización de un hallazgo (Omerovic, 2023).

La replicación constituye una estrategia relevante para valorar la estabilidad de los resultados. Repetir una investigación bajo condiciones similares permite comprobar si un hallazgo vuelve a aparecer cuando se aplican procedimientos comparables. Las replications directas buscan conservar elementos esenciales del estudio original, mientras que las conceptuales examinan una misma hipótesis mediante procedimientos diferentes. Ambas aportan información distinta sobre la consistencia del conocimiento. La estabilidad resulta más convincente cuando un resultado puede observarse nuevamente sin depender exclusivamente de una configuración metodológica específica (Derksen & Morawski, 2022).

La reproducibilidad también contribuye a evaluar la consistencia, aunque no debe confundirse con la replicación. Reproducir un resultado implica obtener nuevamente los mismos hallazgos utilizando los datos y procedimientos analíticos disponibles, mientras que replicar supone generar nueva evidencia. La reproducibilidad permite comprobar si las conclusiones originales derivan efectivamente del procedimiento informado y facilita detectar errores en análisis o procesamiento. Esta verificación constituye una condición importante para interpretar posteriormente la coincidencia o divergencia entre estudios independientes, porque un resultado difícil de reconstruir ofrece una base menos sólida para comparaciones acumulativas (Helliwell & Massera, 2022).

La consistencia entre estudios también depende de la transparencia de los procedimientos utilizados. La disponibilidad de datos, códigos y decisiones analíticas permite identificar por qué dos investigaciones aparentemente similares producen resultados distintos. Cuando esta información no está disponible, resulta difícil establecer si la discrepancia refleja una diferencia real del fenómeno o una variación introducida durante el procesamiento. Las prácticas de ciencia abierta facilitan la comparación crítica y permiten revisar la sensibilidad de los resultados ante decisiones metodológicas alternativas, fortaleciendo la evaluación acumulativa de la evidencia científica (Mathur & Fox, 2023).

La colaboración entre equipos puede contribuir a evaluar la consistencia mediante el uso compartido de protocolos, datos y procedimientos de análisis. Los estudios coordinados permiten examinar si un mismo efecto aparece en diferentes laboratorios o contextos y ayudan

a identificar fuentes de variación que permanecerían ocultas en investigaciones individuales. La colaboración también facilita comparar interpretaciones y detectar decisiones metodológicas que influyen en la estabilidad de los resultados. Su utilidad depende de conservar suficiente diversidad entre los equipos para que la convergencia obtenida represente una comprobación efectiva y no una repetición de los mismos supuestos (Leins et al., 2023).

La consistencia puede verse afectada por sesgos compartidos entre estudios. Varias investigaciones pueden producir resultados semejantes porque utilizan instrumentos, bases de datos o decisiones analíticas que introducen la misma distorsión. Por ello, la coincidencia entre hallazgos no constituye una garantía automática de validez. La evaluación debe examinar si las fuentes de evidencia son suficientemente independientes y si existen mecanismos capaces de detectar sesgos recurrentes. Una conclusión obtiene mayor respaldo cuando permanece estable bajo métodos distintos y cuando las posibles fuentes de distorsión han sido identificadas y analizadas de manera explícita (Hudson, 2021).

En investigaciones basadas en aprendizaje automático, la consistencia puede verse comprometida por problemas de fuga de datos entre las etapas de entrenamiento y evaluación. Este tipo de error puede producir resultados excesivamente optimistas que parecen replicarse cuando se repite el mismo procedimiento defectuoso. La presencia de patrones metodológicos compartidos puede generar una falsa impresión de estabilidad en distintos estudios. Por ello, evaluar la consistencia exige revisar no solo los resultados finales, sino también las condiciones técnicas bajo las cuales se produjeron y la independencia entre los datos empleados para desarrollar y validar los modelos (Kapoor & Narayanan, 2023).

La síntesis de resultados debe considerar tanto la convergencia como la heterogeneidad. Cuando múltiples estudios son comparables, los procedimientos de integración permiten estimar tendencias generales y valorar el grado en que los resultados se apartan entre sí. Sin embargo, una estimación conjunta no debe ocultar diferencias relevantes. La heterogeneidad puede indicar que el efecto depende de características específicas del contexto, de la población o del diseño. Interpretar adecuadamente estas variaciones permite formular conclusiones más delimitadas y evita atribuir universalidad a resultados que solo se mantienen bajo determinadas condiciones (Pedder et al., 2022).

La consistencia entre estudios debe entenderse como una propiedad gradual de un cuerpo de evidencia y no como una condición binaria. Un conjunto de investigaciones puede mostrar una tendencia general estable y conservar al mismo tiempo discrepancias importantes que requieren

explicación. La evaluación científica debe identificar qué elementos permanecen constantes, cuáles varían y qué factores podrían explicar esas diferencias. Esta perspectiva permite utilizar la consistencia como criterio de solidez sin convertirla en una exigencia de uniformidad absoluta. La confianza aumenta cuando la convergencia puede justificarse mediante evidencia independiente, procedimientos transparentes y análisis explícitos de las divergencias existentes (Gough, 2021).

3.5 Interpretación crítica de hallazgos científicos

La interpretación crítica de hallazgos científicos exige examinar los resultados más allá de su presentación descriptiva. No basta con identificar asociaciones, diferencias o patrones; es necesario valorar qué tan sólidos son, bajo qué condiciones fueron obtenidos y hasta dónde permiten sostener una conclusión. La interpretación debe considerar el diseño metodológico, la calidad de los datos, la precisión de las estimaciones y las posibles explicaciones alternativas. Este análisis evita convertir resultados estadísticamente destacados en afirmaciones que exceden la evidencia disponible y permite distinguir entre hallazgos descriptivos, explicativos o inferenciales según el alcance real del estudio (Olaghere et al., 2023).

La lectura crítica también requiere atender a la incertidumbre asociada con los resultados. Intervalos amplios, estimaciones inestables o sensibilidad a determinadas decisiones analíticas pueden modificar de forma importante el significado de un hallazgo. La presencia de incertidumbre no invalida automáticamente el resultado, pero obliga a ajustar la fuerza de la interpretación. Una conclusión responsable debe indicar qué aspectos parecen suficientemente respaldados y cuáles permanecen abiertos a revisión. Esta correspondencia entre resultado e interpretación permite evitar tanto la sobreestimación de la evidencia como una cautela excesiva que impida reconocer patrones razonablemente sustentados (Covitt & Anderson, 2022).

Otro criterio fundamental consiste en valorar la consistencia del hallazgo con resultados obtenidos en otros estudios. Una conclusión aislada puede ser relevante, pero adquiere un significado distinto cuando se compara con evidencia previa. La convergencia puede fortalecer una interpretación, mientras que las discrepancias obligan a examinar diferencias en población, contexto, diseño o análisis. Los resultados contradictorios no deben resolverse seleccionando automáticamente el estudio que coincide con la expectativa inicial. La interpretación crítica exige analizar por qué los hallazgos divergen y determinar si esa variación refleja heterogeneidad real o problemas metodológicos específicos (Omerovic, 2023).

La interpretación debe diferenciar además entre significación estadística y relevancia científica. Un resultado puede alcanzar un criterio estadístico convencional y, aun así, presentar una magnitud pequeña o una utilidad limitada para explicar el fenómeno. Del mismo modo, un resultado que no supera un umbral determinado puede contener información relevante si el estudio posee baja potencia o elevada incertidumbre. La valoración requiere integrar magnitud, precisión, contexto y coherencia teórica, evitando reducir la conclusión a una clasificación dicotómica. La evidencia debe juzgarse según el conjunto de razones que respaldan la afirmación y no únicamente mediante un indicador aislado (Gough, 2021).

Los supuestos del análisis también forman parte de la interpretación crítica. Modelos estadísticos o computacionales simplifican la realidad mediante decisiones sobre variables, relaciones y distribuciones, por lo que sus resultados dependen de condiciones que deben hacerse explícitas. Cuando una conclusión cambia sustancialmente ante modificaciones razonables del modelo, su estabilidad es menor y requiere cautela adicional. La revisión crítica debe examinar si los supuestos son compatibles con los datos y si existen formulaciones alternativas capaces de explicar los mismos patrones. Esta evaluación resulta especialmente importante en problemas complejos donde distintas estructuras pueden ajustarse de manera similar a la evidencia (Fajardo-Fontiveros et al., 2023).

Tabla 9
Criterios para la interpretación crítica de hallazgos científicos

Criterio	Pregunta central	Aspecto que debe examinarse	Riesgo de interpretación
Solidez metodológica	¿El resultado deriva de un diseño adecuado?	Coherencia entre objetivo, método y análisis	Atribuir fuerza a resultados débiles
Magnitud	¿Qué tan importante es el efecto observado?	Tamaño y relevancia del resultado	Confundir significación con importancia
Precisión	¿Qué grado de incertidumbre presenta?	Intervalos y variabilidad	Sobreestimar exactitud
Consistencia	¿Coincide con otros estudios?	Convergencias y discrepancias	Ignorar heterogeneidad
Robustez	¿Resiste análisis alternativos?	Sensibilidad a supuestos y modelos	Dependencia de una única especificación
Alcance	¿Hasta dónde puede generalizarse?	Población, contexto y condiciones	Extrapolación injustificada

Nota. Los criterios orientan una lectura que relaciona la magnitud y estabilidad del hallazgo con las condiciones metodológicas y el alcance real de la evidencia.


La interpretación crítica debe considerar también la posibilidad de sesgos que alteren los resultados o su presentación. Las decisiones sobre selección de datos, exclusión de casos,

modelos empleados o resultados comunicados pueden favorecer determinadas conclusiones. El objetivo no consiste en asumir que toda investigación está inevitablemente distorsionada, sino en identificar qué decisiones pudieron influir en el hallazgo y si fueron suficientemente justificadas. Esta revisión permite diferenciar entre resultados robustos y aquellos cuya aparente solidez depende de elecciones analíticas particulares o de supuestos que requieren una evaluación más cuidadosa (Hudson, 2021).

La transparencia facilita una interpretación más rigurosa porque permite revisar cómo se obtuvieron los hallazgos. El acceso a datos, códigos y procedimientos analíticos posibilita comprobar si los resultados publicados se derivan efectivamente de las operaciones descritas y explorar alternativas razonables. Esta verificabilidad es especialmente relevante cuando el análisis incluye múltiples transformaciones computacionales que no pueden reconstruirse únicamente a partir del texto final. Una documentación suficiente permite detectar errores, comprender discrepancias y valorar la estabilidad de las conclusiones, fortaleciendo la relación entre el resultado presentado y el proceso que lo produjo (Burrows, 2023).

La comparación entre métodos y fuentes puede ampliar la interpretación de un hallazgo. Cuando resultados cuantitativos y cualitativos convergen hacia una misma explicación, la conclusión puede adquirir mayor profundidad al integrar magnitudes con información contextual. Si divergen, la discrepancia puede revelar dimensiones que uno de los enfoques no logra captar. La interpretación crítica debe conservar estas diferencias en lugar de forzar una síntesis artificial. La combinación de evidencias resulta útil cuando cada método aporta información pertinente y cuando la integración respeta las particularidades de los datos y de los criterios mediante los cuales fueron producidos (Arias Valencia, 2022).

Interpretar críticamente un hallazgo implica delimitar con precisión qué puede afirmarse a partir de los resultados y qué permanece fuera de su alcance. Una conclusión sólida reconoce la incertidumbre, examina alternativas, considera evidencia comparable y explicita las condiciones bajo las cuales conserva validez. Este procedimiento evita convertir un resultado particular en una generalización automática y permite que la fuerza de la afirmación sea proporcional al respaldo disponible. La interpretación científica adquiere así una función evaluativa: no repite los datos obtenidos, sino que determina qué significado pueden sostener razonablemente dentro del conjunto de evidencia existente (Gough, 2021).



Capítulo 4.



Inferencia científica frente a la incertidumbre

Francisco Javier Espinoza Huaipatin

4.1 Inferencia inductiva y construcción de generalizaciones

La inferencia inductiva permite avanzar desde observaciones particulares hacia afirmaciones de alcance más general. Su función consiste en identificar regularidades, patrones o relaciones que pueden extenderse más allá de los casos directamente observados. A diferencia de una deducción, la conclusión inductiva no queda garantizada por las premisas, porque siempre existe la posibilidad de que nuevos datos modifiquen la generalización. La solidez de este razonamiento depende de la calidad y representatividad de la evidencia, así como de la relación entre los casos estudiados y la población o fenómeno al que pretende aplicarse la conclusión (Williamson, 2023).

La construcción de generalizaciones exige determinar hasta qué punto los datos observados pueden considerarse informativos sobre situaciones no examinadas directamente. Este proceso depende de supuestos acerca de la estabilidad del fenómeno y de la semejanza entre los casos estudiados y aquellos a los que se extiende la conclusión. Cuando estas condiciones no se justifican, una regularidad local puede convertirse indebidamente en una afirmación general. La inferencia inductiva debe evaluar, por tanto, qué elementos permiten trasladar el conocimiento obtenido en una muestra hacia un conjunto más amplio sin ocultar las condiciones que limitan esa extensión (Williamson, 2023).

La calidad de los datos influye directamente en la fuerza de una generalización inductiva. Observaciones obtenidas mediante procedimientos poco consistentes, muestras sesgadas o registros incompletos pueden producir patrones que no representan adecuadamente el fenómeno. Antes de generalizar, es necesario examinar cómo se generó la información y qué limitaciones afectan su interpretación. La evidencia adquiere mayor valor inferencial cuando existe correspondencia entre el diseño metodológico, los datos producidos y la afirmación que se pretende sostener. Esta relación reduce el riesgo de convertir una regularidad circunstancial en una conclusión de alcance injustificadamente amplio (Gough, 2021).

La representatividad constituye un problema central en la inducción porque las conclusiones dependen de la relación entre los casos observados y el conjunto al que se pretende extender el resultado. Una muestra amplia no garantiza por sí sola una generalización adecuada si excluye sistemáticamente determinados casos o condiciones. Del mismo modo, una muestra limitada puede ofrecer información relevante cuando ha sido seleccionada de forma coherente con la pregunta de investigación. La fuerza de la inferencia depende menos del tamaño aislado de la

evidencia que de su capacidad para reflejar las características relevantes del fenómeno estudiado (Rickinson et al., 2021).

La inferencia inductiva también interviene cuando se comparan resultados obtenidos en diferentes investigaciones. La repetición de un patrón en distintos estudios puede fortalecer una generalización, especialmente cuando las investigaciones se desarrollan en contextos, poblaciones o condiciones diversas. Sin embargo, la consistencia debe analizarse junto con la heterogeneidad. Si los resultados cambian sistemáticamente entre contextos, la conclusión general debe incorporar esas diferencias. La acumulación de evidencia permite ampliar el alcance de una inferencia únicamente cuando se examinan las condiciones bajo las cuales los hallazgos convergen y aquellas en las que dejan de hacerlo (Pedder et al., 2022).

La inducción no se limita a contar casos semejantes, porque también requiere interpretar qué características son relevantes para establecer una regularidad. Los datos deben organizarse mediante categorías, variables o modelos que permitan identificar patrones significativos. Estas decisiones condicionan la forma de la generalización, ya que distintas clasificaciones pueden destacar relaciones diferentes dentro del mismo conjunto de observaciones. El paso desde los datos hacia una afirmación general implica, por tanto, operaciones conceptuales además de empíricas. La transparencia sobre estos criterios permite evaluar si la regularidad identificada corresponde al fenómeno o depende excesivamente del marco utilizado para describirlo (Duschl et al., 2021).

La probabilidad proporciona herramientas para representar la fuerza de algunas inferencias inductivas. En lugar de afirmar que una generalización es absolutamente verdadera, puede estimarse qué grado de respaldo recibe según la evidencia disponible. Los enfoques probabilísticos permiten actualizar esta valoración cuando aparecen nuevos datos y distinguir entre hipótesis que reciben niveles diferentes de apoyo. Sin embargo, la probabilidad no elimina los supuestos que sostienen la generalización. La interpretación sigue dependiendo de la calidad de los datos, de la adecuación del modelo y de las condiciones consideradas relevantes para trasladar los resultados más allá de la evidencia observada (Wei et al., 2022).

La evidencia indirecta introduce dificultades adicionales para la generalización inductiva. Cuando el fenómeno no puede observarse directamente, las conclusiones dependen de indicadores, modelos o cadenas inferenciales que conectan los datos con la propiedad que se pretende explicar. Cada paso puede incorporar nuevas fuentes de incertidumbre y ampliar la distancia entre observación y generalización. En estos casos, la fuerza inductiva aumenta

cuando diferentes líneas de evidencia convergen hacia un mismo patrón y cuando los supuestos intermedios son explícitos. La acumulación de observaciones indirectas requiere evaluar su independencia y su capacidad conjunta para descartar explicaciones alternativas (Woensdregt et al., 2024).

Los sistemas complejos plantean límites específicos para la inducción porque los patrones observados pueden depender de interacciones que cambian entre contextos o escalas. Una regularidad identificada en determinadas condiciones no necesariamente se mantiene cuando varían los componentes o relaciones del sistema. Además, distintos modelos pueden ajustarse a los mismos datos y producir predicciones diferentes fuera del rango observado. Estas dificultades obligan a tratar con cautela las generalizaciones derivadas de sistemas altamente interdependientes. La inferencia debe reconocer cuándo la evidencia disponible permite identificar una tendencia y cuándo resulta insuficiente para extenderla hacia escenarios distintos (Fajardo-Fontiveros et al., 2023).

La formulación de una generalización debe reflejar el grado de respaldo alcanzado por la evidencia. Una inferencia inductiva puede justificar expresiones como “tiende a”, “es probable” o “se observa bajo determinadas condiciones” cuando los datos no permiten sostener una regla universal. Esta cautela no disminuye necesariamente el valor científico de la conclusión, sino que delimita su alcance. El lenguaje debe evitar transformar una regularidad probabilística en una afirmación absoluta y debe señalar las condiciones relevantes para su aplicación. La precisión en la formulación contribuye a conservar la correspondencia entre evidencia, incertidumbre y generalización (Ward & Creel, 2024).

La inferencia inductiva constituye una herramienta esencial para construir conocimiento general a partir de evidencia limitada, pero su validez depende de reconocer que toda generalización permanece abierta a revisión. La fuerza de una conclusión aumenta cuando se apoya en datos pertinentes, resultados consistentes y condiciones de aplicación claramente identificadas. La aparición de nueva evidencia puede fortalecer, restringir o modificar la regularidad inicialmente propuesta. Esta revisabilidad distingue la generalización científica de una afirmación definitiva y permite entender la inducción como un procedimiento que amplía el conocimiento sin eliminar la incertidumbre inherente al paso desde lo observado hacia lo todavía no observado (Williamson, 2023).

4.2 Inferencia deductiva y contrastación científica

La inferencia deductiva parte de premisas, teorías o proposiciones generales para derivar consecuencias específicas que pueden someterse a contrastación. A diferencia de la inducción, la validez deductiva depende de la relación lógica entre las premisas y la conclusión: si las premisas son verdaderas y el razonamiento es válido, la conclusión se sigue necesariamente. En investigación científica, esta estructura permite formular predicciones concretas a partir de hipótesis generales. Sin embargo, la contrastación empírica continúa siendo necesaria, porque una deducción lógicamente correcta puede partir de supuestos que no representan adecuadamente el fenómeno estudiado (Casula et al., 2021).

La contrastación científica utiliza predicciones derivadas de una hipótesis para evaluar su compatibilidad con los datos observados. Este procedimiento exige establecer previamente qué resultados serían esperables si la hipótesis fuera adecuada y qué resultados resultarían difíciles de explicar bajo ella. La evidencia obtenida no debe interpretarse como una confirmación absoluta, porque distintas hipótesis pueden producir predicciones semejantes. La fuerza de la contrastación depende de la especificidad de las predicciones, de la calidad de los datos y de la posibilidad de distinguir entre explicaciones alternativas mediante procedimientos metodológicamente adecuados (Gough, 2021).

Las hipótesis de trabajo cumplen una función importante dentro de diseños deductivos porque orientan la selección de variables, la obtención de datos y la formulación de criterios de evaluación. Una hipótesis suficientemente explícita permite derivar consecuencias observables y determinar qué tipo de evidencia sería relevante para ponerla a prueba. Esta función exige evitar formulaciones excesivamente vagas que puedan adaptarse a cualquier resultado. Cuanto más clara sea la relación entre hipótesis y predicción, más informativa será la contrastación y más sencillo resultará identificar si los datos respaldan, debilitan o requieren revisar la explicación propuesta (Casula et al., 2021).

La inferencia deductiva también depende de supuestos auxiliares que conectan la teoría con las condiciones concretas de observación. Una predicción puede fallar no porque la hipótesis principal sea incorrecta, sino porque existan problemas en la medición, en el diseño o en alguno de los supuestos empleados para derivarla. Esta situación dificulta atribuir un resultado negativo a una única causa. La contrastación científica debe examinar la estructura completa del argumento y distinguir entre la hipótesis central, las condiciones iniciales y los procedimientos utilizados para producir la evidencia antes de interpretar una discrepancia como refutación concluyente (Covitt & Anderson, 2022).

La deducción adquiere mayor valor científico cuando sus consecuencias pueden compararse con evidencia independiente y suficientemente precisa. Una predicción formulada después de conocer los resultados ofrece menor capacidad de contrastación que una establecida antes de observarlos, porque aumenta el riesgo de adaptar la explicación a la evidencia disponible. La transparencia sobre las hipótesis, decisiones analíticas y criterios de evaluación facilita determinar si el resultado fue realmente anticipado por el marco teórico. Esta trazabilidad fortalece la distinción entre predicción, ajuste posterior e interpretación exploratoria dentro de los procesos de contrastación científica (Mathur & Fox, 2023).

Tabla 10
Componentes de la inferencia deductiva y la contrastación científica

Componente	Función	Pregunta de evaluación	Riesgo principal
Premisa teórica	Establecer el marco general	¿Está claramente formulada?	Ambigüedad conceptual
Hipótesis	Proponer una relación contrastable	¿Permite derivar consecuencias observables?	Formulación no falsable
Predicción	Anticipar un resultado específico	¿Fue definida antes de observar los datos?	Ajuste posterior
Datos	Proporcionar evidencia empírica	¿Son adecuados para evaluar la predicción?	Medición deficiente
Contrastación	Comparar predicción y resultado	¿La evidencia discrimina entre alternativas?	Confirmación aparente
Revisión	Modificar hipótesis o supuestos	¿La discrepancia está bien localizada?	Atribución incorrecta del fallo

Nota. La secuencia permite distinguir entre la derivación lógica de consecuencias y la evaluación empírica necesaria para determinar el alcance de una hipótesis.

La contrastación puede expresarse mediante procedimientos probabilísticos cuando los datos presentan variabilidad y las predicciones no son deterministas. En estos casos, la hipótesis puede especificar qué resultados son más o menos probables y la evidencia permite evaluar cuánto cambia su respaldo. Los métodos bayesianos ofrecen una forma de comparar hipótesis y actualizar su plausibilidad a partir de nuevos datos. No obstante, esta evaluación depende de las probabilidades iniciales, del modelo utilizado y de la adecuación de los supuestos estadísticos, por lo que el cálculo probabilístico debe interpretarse dentro de la estructura general de la inferencia científica (Wei et al., 2022).

La contrastación deductiva también puede verse afectada por la falta de independencia entre los datos utilizados para desarrollar una hipótesis y aquellos empleados para evaluarla. Este problema resulta particularmente relevante en modelos computacionales y de aprendizaje automático, donde reutilizar información durante entrenamiento y validación puede producir

un rendimiento artificialmente elevado. Una evaluación rigurosa requiere separar las etapas de construcción y comprobación, de modo que la evidencia utilizada para contrastar el modelo proporcione información genuinamente nueva sobre su capacidad explicativa o predictiva (Kapoor & Narayanan, 2023).

Los resultados negativos o contradictorios deben interpretarse considerando las condiciones específicas de la contrastación. Dos estudios pueden evaluar hipótesis aparentemente similares y obtener conclusiones diferentes debido a variaciones en las poblaciones, procedimientos o condiciones experimentales. La deducción permite establecer qué debería ocurrir bajo determinados supuestos, pero la comparación empírica exige comprobar si esos supuestos se mantuvieron de forma equivalente entre investigaciones. Analizar estas diferencias evita convertir cualquier discrepancia en una refutación automática y permite identificar si la contradicción afecta realmente la hipótesis central o deriva de condiciones auxiliares distintas (Omerovic, 2023).

La inferencia deductiva aporta estructura al razonamiento científico al conectar teorías con consecuencias susceptibles de evaluación empírica. Su fuerza no reside únicamente en la corrección lógica, sino en la posibilidad de formular hipótesis suficientemente precisas, derivar predicciones informativas y contrastarlas mediante evidencia pertinente. Cuando los resultados no coinciden con lo esperado, la revisión debe examinar tanto la teoría como los supuestos que permitieron generar la predicción. Esta combinación entre rigor lógico y contrastación empírica permite utilizar la deducción como instrumento para someter explicaciones científicas a pruebas explícitas y revisables (Casula et al., 2021).

4.3 Razonamiento abductivo y formulación de explicaciones

El razonamiento abductivo permite formular explicaciones posibles a partir de observaciones que requieren ser interpretadas. A diferencia de la deducción, que deriva consecuencias desde premisas generales, y de la inducción, que extiende patrones observados, la abducción busca identificar qué hipótesis podría explicar mejor un conjunto de hechos. Su valor científico reside en generar propuestas explicativas que posteriormente deben ser contrastadas. La explicación abductiva no se considera verdadera por el solo hecho de ajustarse a los datos, porque otras hipótesis pueden resultar igualmente compatibles. Su fuerza depende de la calidad del ajuste y de la comparación con alternativas plausibles (Engelschalt et al., 2023).

La abducción comienza cuando existe una observación, regularidad o resultado que no puede explicarse de manera suficiente mediante el conocimiento disponible. El investigador propone

entonces una hipótesis capaz de conectar los datos con un mecanismo o proceso subyacente. Este procedimiento exige seleccionar qué aspectos del fenómeno requieren explicación y qué condiciones podrían producirlos. La formulación de una hipótesis abductiva implica una operación creativa, pero no arbitraria, porque debe mantenerse vinculada con la evidencia disponible y con conocimientos previamente establecidos. La explicación inicial funciona como una propuesta susceptible de revisión y no como una conclusión definitiva (Duschl et al., 2021).

Una característica central de la abducción es la comparación entre explicaciones alternativas. Cuando varios mecanismos pueden producir un mismo resultado, la tarea no consiste únicamente en encontrar una hipótesis compatible con los datos, sino en determinar cuál ofrece la explicación más adecuada. Esta evaluación puede considerar coherencia, alcance, simplicidad, capacidad predictiva y compatibilidad con otras evidencias. Sin embargo, ninguno de estos criterios garantiza por sí solo que una explicación sea correcta. La fuerza abductiva aumenta cuando una hipótesis explica más información con menos supuestos problemáticos y cuando resiste comparaciones con alternativas razonables (Gough, 2021).

El razonamiento abductivo adquiere especial importancia en el estudio de sistemas complejos, donde los fenómenos pueden surgir de múltiples interacciones difíciles de observar directamente. En estos contextos, las explicaciones se construyen mediante modelos que representan relaciones entre componentes y permiten explorar cómo determinados mecanismos podrían generar los patrones observados. La abducción contribuye a formular hipótesis sobre esas relaciones y a identificar qué configuraciones resultan compatibles con la evidencia. Sin embargo, la complejidad del sistema puede hacer que distintas explicaciones reproduzcan resultados similares, lo que obliga a mantener abierta la evaluación de modelos alternativos (Engelschalt et al., 2023).

La evidencia indirecta suele desempeñar un papel importante en la formulación de explicaciones abductivas. Cuando el mecanismo causal no puede observarse directamente, los investigadores recurren a indicadores, consecuencias esperables o patrones secundarios para inferir su existencia. Cada vínculo entre observación y explicación introduce supuestos que deben justificarse. Por ello, una explicación abductiva sustentada en evidencia indirecta requiere examinar cuidadosamente la cadena inferencial y considerar qué otras hipótesis podrían producir los mismos datos. La convergencia entre diferentes líneas de evidencia puede fortalecer la explicación, especialmente cuando proceden de fuentes suficientemente independientes (Woensdregt et al., 2024).

La formulación abductiva también depende del marco conceptual utilizado para interpretar los datos. Una misma observación puede generar explicaciones diferentes cuando se analiza desde teorías o modelos distintos. Esto muestra que la evidencia no determina automáticamente una única explicación, porque los conceptos disponibles influyen en las preguntas formuladas y en los mecanismos considerados plausibles. La tarea científica consiste en hacer explícitos estos marcos y evaluar hasta qué punto permiten organizar los datos de forma coherente. La abducción se fortalece cuando la hipótesis propuesta integra la evidencia sin depender de supuestos innecesariamente restrictivos o insuficientemente fundamentados (Duschl et al., 2021).

Los modelos computacionales pueden ampliar el razonamiento abductivo al permitir explorar múltiples configuraciones explicativas y comparar sus consecuencias con los datos observados. Mediante simulaciones o procedimientos de ajuste, los investigadores pueden identificar qué mecanismos producen patrones semejantes a los registrados empíricamente. Sin embargo, la capacidad de un modelo para reproducir un resultado no demuestra que represente el mecanismo real. Diferentes estructuras pueden ajustarse de manera comparable al mismo conjunto de datos, especialmente cuando existe ruido o información insuficiente. La abducción computacional requiere, por tanto, criterios adicionales para discriminar entre explicaciones matemáticamente compatibles (Fajardo-Fontiveros et al., 2023).


La probabilidad también puede utilizarse para comparar hipótesis abductivas cuando existen varias explicaciones posibles. Los métodos probabilísticos permiten valorar cuánto respaldo recibe cada hipótesis según los datos disponibles y actualizar esa valoración cuando aparece nueva evidencia. Este enfoque resulta útil para evitar decisiones dicotómicas prematuras entre aceptación y rechazo. Sin embargo, la comparación depende de los supuestos del modelo y de la forma en que se asignan probabilidades a las alternativas. La cuantificación puede ordenar explicaciones según su respaldo relativo, pero no elimina la necesidad de examinar su plausibilidad conceptual y la calidad de la evidencia utilizada (Wei et al., 2022).

La triangulación puede fortalecer una explicación abductiva cuando diferentes métodos o fuentes aportan resultados compatibles con el mismo mecanismo. Una hipótesis adquiere mayor respaldo si puede explicar simultáneamente evidencias producidas mediante procedimientos independientes. Sin embargo, la convergencia debe evaluarse con cautela, porque varias fuentes pueden compartir supuestos o sesgos que reproduzcan artificialmente una misma interpretación. La utilidad de la triangulación depende de la diversidad real de las evidencias y de la capacidad de la explicación para integrar sus diferencias. Una abducción

sólida debe explicar tanto las convergencias como las discrepancias relevantes entre los datos disponibles (Arias Valencia, 2022).

Figura 4

Proceso del razonamiento abductivo para la construcción de explicaciones



Nota. El esquema organiza las etapas mediante las cuales una hipótesis se formula, compara y contrasta con distintas evidencias antes de considerarse una explicación provisional.

RAZONAMIENTO ABDUCTIVO

Proceso para generar y evaluar explicaciones



La mejor explicación disponible puede seguir siendo provisional cuando la evidencia es incompleta. La abducción no elimina la incertidumbre, sino que organiza posibles respuestas según el respaldo que reciben. Una explicación puede ser razonable en un momento determinado y posteriormente ser reemplazada si nuevos datos favorecen otra hipótesis. Esta revisabilidad constituye una característica importante del razonamiento científico, porque impide convertir una explicación plausible en una certeza definitiva. La formulación debe reflejar el grado de apoyo alcanzado y distinguir entre una hipótesis bien sustentada y una explicación que permanece abierta debido a evidencia insuficiente o indirecta (Woensdregt et al., 2024).

El razonamiento abductivo permite transformar resultados observados en preguntas sobre los mecanismos capaces de producirlos. Su función no termina con la generación de una explicación, porque las hipótesis propuestas deben orientar nuevas observaciones, predicciones y contrastaciones. La calidad de una abducción depende de su capacidad para integrar evidencia, competir con alternativas y producir consecuencias que puedan evaluarse posteriormente. Este proceso conecta creatividad explicativa con control empírico y permite construir conocimiento sin asumir que la primera explicación plausible es necesariamente correcta. La abducción funciona así como una etapa revisable dentro de la construcción científica de explicaciones (Engelschalt et al., 2023).

4.4 Probabilidad y evaluación de hipótesis

La probabilidad permite representar de manera explícita distintos grados de incertidumbre asociados con hipótesis científicas. En lugar de clasificar una proposición únicamente como verdadera o falsa, los enfoques probabilísticos permiten estimar cuánto respaldo recibe según la evidencia disponible. Esta perspectiva resulta especialmente útil cuando los datos son incompletos, variables o compatibles con más de una explicación. La evaluación probabilística no elimina la incertidumbre, pero facilita organizarla mediante criterios formales y comparables. Su utilidad depende de que los modelos empleados sean adecuados y de que los supuestos utilizados para asignar probabilidades puedan justificarse dentro del problema investigado (Wei et al., 2022).

La evaluación de hipótesis mediante probabilidad exige distinguir entre la probabilidad de los datos bajo una hipótesis y la probabilidad de la hipótesis considerando los datos. Esta diferencia es fundamental porque evita interpretar de manera incorrecta los resultados de una prueba estadística. En enfoques bayesianos, la información previa se combina con la evidencia

observada para actualizar el grado de credibilidad de una hipótesis. El resultado depende tanto de los datos como de las probabilidades previas y del modelo utilizado, por lo que la interpretación debe considerar de manera conjunta estas condiciones y no únicamente el valor final obtenido (Wei et al., 2022).

El factor de Bayes constituye una herramienta para comparar cuánto apoyo reciben dos hipótesis a partir de un mismo conjunto de datos. Su función es contrastar la capacidad relativa de cada propuesta para explicar la evidencia observada. Un resultado favorable a una hipótesis no implica una demostración definitiva, sino un grado mayor de respaldo respecto de la alternativa considerada. La interpretación debe reconocer que el resultado puede cambiar si se modifican las distribuciones previas, los modelos o la información disponible. Por ello, la comparación probabilística debe acompañarse de análisis de sensibilidad que permitan valorar la estabilidad de las conclusiones (Wei et al., 2022).

La probabilidad también interviene en inferencias inductivas, donde la generalización depende de extender patrones observados hacia casos no examinados directamente. En estos contextos, los enfoques probabilísticos permiten expresar con qué grado de confianza una regularidad identificada puede mantenerse bajo nuevas condiciones. La inferencia sigue siendo revisable porque nuevos datos pueden modificar la valoración inicial. La probabilidad no convierte una generalización en una certeza lógica, pero permite cuantificar la fuerza relativa de la evidencia y establecer diferencias entre hipótesis que reciben niveles distintos de apoyo dentro de un marco inferencial explícito (Williamson, 2023).

La evaluación de hipótesis debe considerar además la calidad y pertinencia de los datos utilizados. Un cálculo probabilístico preciso no compensa problemas en la generación de datos, sesgos de selección o mediciones poco adecuadas. La solidez de la inferencia depende de la relación entre la estructura matemática del modelo y las condiciones empíricas que representan los datos. Cuando esta correspondencia es débil, una probabilidad aparentemente exacta puede transmitir una seguridad mayor de la justificada. Por ello, la interpretación probabilística debe integrarse con una evaluación metodológica de la evidencia y de los supuestos que sustentan el análisis (Gough, 2021).

Tabla 11
Criterios probabilísticos para la evaluación de hipótesis

Elemento	Función en la evaluación	Pregunta central	Riesgo principal
Hipótesis	Formular una explicación o relación	¿Está claramente definida?	Ambigüedad conceptual
Probabilidad previa	Representar conocimiento inicial	¿Está suficientemente justificada?	Dependencia de supuestos arbitrarios
Verosimilitud	Relacionar hipótesis y datos	¿El modelo representa adecuadamente la evidencia?	Mala especificación
Probabilidad posterior	Actualizar el respaldo de la hipótesis	¿Cómo cambia la valoración con los datos?	Interpretación como certeza
Factor de Bayes	Comparar hipótesis	¿Cuál explica mejor los datos disponibles?	Dependencia de las alternativas comparadas
Sensibilidad	Examinar estabilidad	¿Cambian las conclusiones ante otros supuestos?	Confianza excesiva en un único modelo

Nota. Los criterios permiten relacionar datos, supuestos y grados de respaldo sin reducir la evaluación de hipótesis a una decisión binaria.

La incertidumbre probabilística puede aumentar cuando las muestras son pequeñas o contienen información insuficiente. En estos casos, las estimaciones pueden presentar alta variabilidad y ser sensibles a la incorporación de nuevos datos. La evaluación debe reconocer esta fragilidad antes de formular conclusiones amplias. Analizar cuánta evidencia adicional sería necesaria para modificar sustancialmente la valoración de una hipótesis permite distinguir entre resultados relativamente estables y otros todavía dependientes de información preliminar. Este enfoque evita que decisiones científicas importantes se basen exclusivamente en resultados probabilísticos poco robustos (Sondhi et al., 2021).

La comparación entre hipótesis también requiere que las alternativas sean suficientemente informativas. Una hipótesis puede recibir apoyo relativo simplemente porque la alternativa considerada es demasiado débil o poco plausible. Por ello, la evaluación debe incluir explicaciones que representen posibilidades científicamente razonables y no únicamente opciones fáciles de descartar. La fuerza del respaldo depende en parte del conjunto de hipótesis que entra en comparación. En situaciones donde varias explicaciones producen predicciones similares, la probabilidad puede no ser suficiente para discriminar claramente entre ellas y será necesario incorporar nueva evidencia o desarrollar pruebas más específicas (Woensdregt et al., 2024).

Los resultados probabilísticos deben comunicarse con un lenguaje proporcional al nivel de respaldo obtenido. Expresiones como “más probable”, “compatible con” o “recibe mayor apoyo” resultan más adecuadas que afirmaciones categóricas cuando la conclusión conserva incertidumbre. La precisión en el lenguaje permite diferenciar entre una hipótesis favorecida por los datos y una proposición definitivamente establecida. La comunicación debe evitar que probabilidades elevadas se interpreten como garantías absolutas y debe señalar los supuestos principales que condicionan el resultado, especialmente cuando distintas elecciones analíticas podrían modificar la evaluación (Ward & Creel, 2024).

La probabilidad contribuye a la evaluación científica de hipótesis al ofrecer procedimientos para ordenar grados de respaldo, actualizar creencias y comparar explicaciones alternativas. Su valor depende de mantener una relación clara entre los datos, el modelo y los supuestos utilizados. Una evaluación rigurosa no se limita al cálculo numérico, sino que examina la sensibilidad de las conclusiones y la calidad de la evidencia que sustenta cada estimación. Bajo estas condiciones, la probabilidad permite trabajar con incertidumbre de manera explícita y revisar las hipótesis conforme se incorpora nueva información al proceso científico (Wei et al., 2022).

4.5 Límites de la inferencia en escenarios complejos

Los escenarios complejos imponen límites particulares a la inferencia científica porque los fenómenos pueden depender de múltiples variables interrelacionadas, retroalimentaciones y cambios contextuales. En estas condiciones, una misma evidencia puede ser compatible con diferentes mecanismos explicativos y dificultar la identificación de una única estructura causal. La inferencia pierde fuerza cuando el modelo representa solo una parte de las interacciones relevantes o cuando pequeñas modificaciones en los supuestos producen resultados distintos. Por ello, analizar sistemas complejos exige reconocer que la capacidad de generalizar, predecir o explicar puede estar restringida por la propia organización del fenómeno (Fajardo-Fontiveros et al., 2023).

Uno de los principales límites aparece cuando distintos modelos logran reproducir de manera similar los datos observados. Esta situación dificulta determinar cuál de ellos representa con mayor fidelidad los mecanismos subyacentes. El ajuste empírico, por sí solo, no garantiza que el modelo identificado sea el correcto, especialmente cuando existe ruido o información insuficiente. Varias estructuras matemáticas pueden ofrecer predicciones comparables dentro del rango observado y divergir al extrapolarse hacia nuevas condiciones. La inferencia requiere

entonces criterios adicionales de discriminación y evidencia independiente para evitar confundir capacidad de ajuste con explicación adecuada del sistema (Fajardo-Fontiveros et al., 2023).

La alta dimensionalidad constituye otra dificultad importante. Cuando un fenómeno depende de numerosas variables, aumenta la cantidad de relaciones potenciales que pueden explorarse y también la posibilidad de identificar patrones espurios. El análisis puede encontrar asociaciones estadísticamente destacadas que no correspondan con mecanismos relevantes. Este problema se intensifica cuando el número de variables es grande en relación con la cantidad de observaciones disponibles. La inferencia debe considerar la estabilidad de los patrones y su replicación bajo datos independientes, porque un resultado obtenido en un conjunto específico puede desaparecer al modificar la muestra o el procedimiento analítico (Kapoor & Narayanan, 2023).

La dependencia entre variables también limita las interpretaciones causales. En sistemas complejos, múltiples factores pueden influirse de manera simultánea, lo que dificulta aislar el efecto de cada componente. Una asociación observada puede ser consecuencia de relaciones indirectas, variables omitidas o estructuras de retroalimentación. La inferencia causal requiere entonces mayor cuidado al identificar qué condiciones son necesarias para atribuir un efecto a una causa específica. Cuando estas condiciones no pueden establecerse con claridad, las conclusiones deben limitarse al nivel de relación que realmente permite sostener la evidencia disponible (Gough, 2021).

La evidencia indirecta adquiere un peso especial cuando los mecanismos del sistema no pueden observarse de forma directa. Los investigadores recurren a indicadores, modelos y patrones secundarios para inferir procesos ocultos, pero cada paso adicional amplía la incertidumbre. La validez de la conclusión depende de la calidad de las conexiones entre los datos observables y el fenómeno que se pretende explicar. En escenarios complejos, esta cadena puede ser extensa y admitir múltiples interpretaciones. La convergencia entre diferentes líneas de evidencia puede reducir parte de la ambigüedad, aunque no elimina necesariamente la existencia de explicaciones alternativas (Woensdregt et al., 2024).

Los modelos computacionales amplían la capacidad de explorar sistemas complejos, pero introducen sus propios límites inferenciales. Toda simulación depende de reglas, parámetros y condiciones iniciales seleccionadas por los investigadores. Un modelo puede generar patrones semejantes a los observados y aun así omitir mecanismos relevantes o depender de supuestos

poco realistas. La utilidad inferencial aumenta cuando las predicciones pueden contrastarse con datos independientes y cuando se evalúa la sensibilidad de los resultados a cambios en la configuración. Sin estas comprobaciones, la simulación puede mostrar posibilidades plausibles sin establecer qué explicación recibe mayor respaldo empírico (Monti et al., 2023).

La incertidumbre también aumenta cuando los sistemas presentan comportamientos emergentes. Algunas propiedades aparecen a partir de interacciones entre múltiples componentes y no pueden anticiparse observando cada elemento por separado. Esta condición dificulta trasladar conclusiones desde niveles simples hacia niveles agregados. Una inferencia válida para componentes individuales puede no mantenerse cuando cambia la organización del conjunto. La explicación requiere considerar cómo las relaciones entre partes modifican el comportamiento global y qué condiciones permiten que determinadas propiedades aparezcan. Los modelos deben reconocer esta dependencia para evitar generalizaciones reduccionistas que ignoren la estructura del sistema (Engelschalt et al., 2023).

La sensibilidad a las condiciones iniciales constituye otro límite en ciertos escenarios complejos. Pequeñas diferencias en el estado de partida pueden producir trayectorias considerablemente distintas, lo que reduce la capacidad predictiva incluso cuando el modelo describe correctamente las reglas generales del sistema. Esta sensibilidad no implica ausencia de conocimiento, pero obliga a diferenciar entre comprender mecanismos y predecir resultados específicos. Una explicación puede ser científicamente válida y, al mismo tiempo, tener capacidad limitada para anticipar con precisión qué ocurrirá en cada caso individual (Villalobos Antúnez et al., 2023).

La generalización desde escenarios complejos debe considerar la dependencia del contexto. Un patrón identificado bajo determinadas condiciones puede modificarse cuando cambian las relaciones entre variables, el entorno o la escala de análisis. La extrapolación exige evidencia que permita establecer qué componentes del resultado son estables y cuáles dependen de circunstancias particulares. Cuando esta información es insuficiente, la inferencia debe formularse de manera restringida. La estabilidad observada dentro de un conjunto de datos no garantiza que el mismo comportamiento se mantenga en sistemas relacionados pero estructuralmente diferentes (Williamson, 2023).

Los límites inferenciales también pueden intensificarse cuando la complejidad del análisis dificulta revisar cómo se obtuvo un resultado. Modelos con numerosas etapas de procesamiento o algoritmos poco transparentes pueden producir conclusiones técnicamente sofisticadas cuya

trazabilidad resulta limitada. La posibilidad de reconstruir el procedimiento es importante para determinar qué decisiones influyeron en el resultado y evaluar su sensibilidad. Una inferencia compleja adquiere mayor confiabilidad cuando los datos, transformaciones y criterios analíticos pueden examinarse, reproducirse y compararse con alternativas razonables (Burrows, 2023).

Reconocer los límites de la inferencia en escenarios complejos permite formular conclusiones ajustadas a la evidencia sin convertir la dificultad analítica en una renuncia al conocimiento. La complejidad exige distinguir entre patrones observados, mecanismos plausibles y explicaciones suficientemente contrastadas. También obliga a evaluar la sensibilidad de los resultados, la existencia de modelos alternativos y la posibilidad de generalizar más allá del contexto estudiado. Una inferencia rigurosa mantiene visibles estas restricciones y delimita qué puede sostenerse con confianza, qué permanece provisional y qué requiere nueva evidencia antes de ampliar el alcance de la conclusión (Fajardo-Fontiveros et al., 2023).



Capítulo 5.



Controversia, reproducibilidad y confianza científica

Ángel Patricio Herrera Carrión

5.1 Resultados contradictorios en la investigación científica

Los resultados contradictorios aparecen cuando investigaciones que examinan preguntas similares producen conclusiones diferentes o incluso opuestas. Esta situación puede deberse a variaciones en las poblaciones estudiadas, los procedimientos aplicados, los criterios de inclusión o las condiciones experimentales. La contradicción no demuestra de manera automática que uno de los estudios sea erróneo, porque resultados distintos pueden reflejar diferencias reales entre contextos. La interpretación exige revisar cuidadosamente la comparabilidad de los diseños y determinar si las investigaciones evaluaron verdaderamente la misma hipótesis bajo condiciones suficientemente semejantes como para esperar resultados equivalentes (Omerovic, 2023).

Las discrepancias entre estudios también pueden originarse en diferencias metodológicas que modifican la forma en que se produce la evidencia. Cambios en instrumentos, variables, procedimientos analíticos o criterios de exclusión pueden generar estimaciones distintas aun cuando el objeto de estudio sea similar. Por esta razón, comparar únicamente las conclusiones finales puede ocultar factores importantes. La evaluación debe reconstruir cómo se obtuvieron los resultados y qué decisiones metodológicas pudieron influir en ellos. Esta revisión permite distinguir entre una contradicción sustantiva y una divergencia explicable por diferencias en el diseño o en las condiciones de análisis (Gough, 2021).

La heterogeneidad entre estudios representa otra fuente frecuente de resultados divergentes. Diferencias en edad, contexto, exposición, intervención o características iniciales de las muestras pueden modificar la magnitud o dirección de un efecto. Los procedimientos de síntesis deben evaluar esta variabilidad antes de combinar resultados en una estimación común. Cuando la heterogeneidad es elevada, una conclusión agregada puede ocultar patrones específicos que solo aparecen bajo determinadas condiciones. La consistencia debe analizarse como un problema empírico y no asumirse automáticamente por el hecho de que varios estudios pertenezcan al mismo campo o investiguen variables semejantes (Pedder et al., 2022).

Los resultados contradictorios también pueden surgir cuando las investigaciones poseen distinta capacidad para detectar un efecto. Estudios con muestras pequeñas o alta variabilidad pueden producir estimaciones inestables que cambian considerablemente ante pequeñas modificaciones de los datos. En estas condiciones, un resultado positivo y otro negativo no necesariamente representan una oposición real. La evaluación debe considerar la precisión de las estimaciones, los intervalos de incertidumbre y la cantidad de evidencia disponible. Esta

perspectiva evita interpretar diferencias estadísticas como contradicciones absolutas cuando ambas investigaciones podrían ser compatibles con un rango común de valores plausibles (Covitt & Anderson, 2022).

La replicación constituye una herramienta importante para comprender resultados contradictorios porque permite comprobar si un hallazgo reaparece bajo condiciones similares o mediante procedimientos alternativos. Las replications directas buscan conservar elementos centrales del estudio original, mientras que las conceptuales modifican el procedimiento para evaluar la misma proposición desde otra aproximación. Si los resultados continúan divergiendo, la comparación puede ayudar a identificar qué condiciones influyen en el efecto. La contradicción se convierte entonces en una fuente de información sobre los límites del hallazgo y sobre las circunstancias en las que una explicación mantiene o pierde estabilidad (Derksen & Morawski, 2022).

La reproducibilidad aporta un criterio complementario para evaluar discrepancias. Antes de interpretar que dos investigaciones se contradicen, resulta necesario comprobar si cada resultado puede reconstruirse a partir de los datos y procedimientos informados. Errores de procesamiento, códigos incompletos o decisiones analíticas no documentadas pueden generar diferencias que no corresponden al fenómeno estudiado. La posibilidad de reproducir los análisis facilita identificar problemas internos antes de atribuir la divergencia a características del objeto científico. Esta distinción permite separar contradicciones empíricas genuinas de inconsistencias originadas durante la producción o procesamiento de los resultados (Helliwell & Massera, 2022).

Las prácticas de ciencia abierta pueden facilitar el análisis de resultados contradictorios mediante el acceso a datos, códigos y protocolos. Esta información permite comparar de forma más precisa cómo se produjeron estimaciones divergentes y evaluar si las diferencias dependen de decisiones metodológicas específicas. También facilita ejecutar análisis alternativos y comprobar la sensibilidad de las conclusiones. Sin embargo, la disponibilidad de materiales debe acompañarse de documentación suficiente para que otros investigadores puedan reconstruir el proceso. La transparencia adquiere así una función crítica en la explicación de por qué investigaciones aparentemente comparables producen resultados diferentes (Mathur & Fox, 2023).

Los sesgos pueden generar contradicciones cuando afectan de manera desigual a distintos estudios. La selección de participantes, la exclusión de observaciones, las preferencias teóricas

o determinadas decisiones analíticas pueden desplazar los resultados en direcciones diferentes. También puede producirse una aparente consistencia si varios estudios comparten el mismo sesgo. Por ello, la evaluación de resultados contradictorios debe examinar no solo las diferencias entre conclusiones, sino también las condiciones que pudieron distorsionar cada línea de evidencia. Reconocer estas influencias permite valorar si la discrepancia representa incertidumbre científica genuina o una consecuencia de decisiones metodológicas particulares (Hudson, 2021).

En investigaciones basadas en aprendizaje automático, algunos resultados contradictorios pueden derivarse de problemas técnicos relacionados con la separación entre datos de entrenamiento y evaluación. La fuga de información puede producir estimaciones artificialmente elevadas de rendimiento y generar diferencias importantes cuando otros estudios utilizan procedimientos de validación más estrictos. En estos casos, la contradicción aparente refleja estándares técnicos distintos y no necesariamente diferencias en el fenómeno estudiado. Revisar la independencia de los conjuntos de datos y la transparencia del procedimiento resulta indispensable para comparar adecuadamente resultados producidos mediante sistemas automatizados (Kapoor & Narayanan, 2023).

La colaboración entre grupos independientes puede ayudar a esclarecer contradicciones mediante protocolos coordinados y análisis comparables. Cuando diferentes equipos estudian una misma pregunta bajo condiciones previamente definidas, resulta más sencillo identificar qué factores explican la variación de los resultados. La colaboración permite además comparar interpretaciones y detectar decisiones metodológicas que podrían pasar inadvertidas en un solo estudio. Su valor aumenta cuando los equipos conservan suficiente independencia para que la convergencia o divergencia observada represente una comprobación real y no la reproducción de las mismas decisiones analíticas o supuestos compartidos (Leins et al., 2023).

Los resultados contradictorios deben interpretarse como una señal para revisar la evidencia disponible, no como una anomalía que deba eliminarse para preservar una conclusión previa. La divergencia puede revelar límites de generalización, diferencias contextuales, problemas metodológicos o mecanismos todavía insuficientemente comprendidos. Una evaluación rigurosa debe mantener visibles las discrepancias y explicar qué condiciones podrían producirlas. La confianza científica aumenta cuando las contradicciones se examinan de manera transparente y se utilizan para delimitar mejor el alcance de las afirmaciones, en lugar de seleccionar únicamente los resultados compatibles con una expectativa determinada (Omerovic, 2023).

5.2 Reproducibilidad como criterio de confiabilidad

La reproducibilidad constituye un criterio relevante de confiabilidad porque permite comprobar si un resultado puede obtenerse nuevamente a partir de los mismos datos, procedimientos y condiciones analíticas descritas en una investigación. Su valor reside en hacer visible la relación entre la evidencia producida y las operaciones que condujeron a ella. Cuando un resultado puede reconstruirse, aumenta la posibilidad de detectar errores, decisiones no documentadas o inconsistencias internas. Sin embargo, la reproducibilidad no demuestra por sí sola que una conclusión sea correcta, ya que un procedimiento reproducible puede conservar supuestos inadecuados o limitaciones metodológicas importantes (Helliwell & Massera, 2022).

La reproducibilidad depende de la transparencia con que se documenten los procesos científicos. La descripción detallada de métodos, criterios de inclusión, transformaciones de datos, modelos y decisiones analíticas permite que otros investigadores examinen cómo se obtuvo el resultado. En estudios computacionales, esta exigencia adquiere especial importancia porque pequeñas modificaciones en códigos, parámetros o secuencias de procesamiento pueden alterar las conclusiones. La documentación completa facilita reconstruir el análisis y distinguir entre diferencias derivadas del fenómeno y aquellas producidas por decisiones técnicas. De este modo, la verificabilidad se convierte en una condición práctica para evaluar la confiabilidad de los resultados (Burrows, 2023).

El acceso a datos y códigos puede fortalecer la reproducibilidad cuando los materiales se encuentran suficientemente organizados y documentados. Las prácticas de ciencia abierta permiten repetir análisis, identificar errores y explorar la sensibilidad de los resultados ante decisiones alternativas. No obstante, publicar archivos sin información contextual no garantiza que la investigación pueda reproducirse. Los materiales deben incluir instrucciones claras, definiciones de variables y procedimientos que permitan reconstruir el flujo analítico. La apertura adquiere valor cuando hace posible revisar el proceso científico y comprobar que la conclusión deriva efectivamente de la evidencia y de los métodos declarados (Mathur & Fox, 2023).

La colaboración entre equipos independientes también puede contribuir a la reproducibilidad al permitir que diferentes grupos reconstruyan procedimientos y comparen resultados. Esta práctica ayuda a detectar supuestos implícitos, dificultades técnicas o decisiones metodológicas que podrían pasar inadvertidas para los autores originales. Cuando varios equipos obtienen resultados semejantes siguiendo la misma documentación, aumenta la confianza en la

estabilidad del procedimiento. Sin embargo, la concordancia debe analizarse junto con la independencia de los grupos y la calidad de los métodos empleados, porque reproducir una misma limitación no convierte automáticamente el resultado en una evidencia científicamente sólida (Leins et al., 2023).

La reproducibilidad resulta especialmente crítica en investigaciones apoyadas en sistemas automatizados. Algoritmos complejos pueden generar resultados difíciles de revisar cuando no se registran adecuadamente sus datos de entrada, configuraciones, criterios de entrenamiento y procedimientos de evaluación. La falta de trazabilidad puede impedir determinar por qué un sistema produjo una determinada salida o si el resultado depende de condiciones específicas. Por ello, la evaluación de sistemas automatizados requiere procedimientos de validación que permitan contrastar su desempeño y examinar sus resultados bajo condiciones explícitas, especialmente cuando no existe una referencia directa disponible para establecer su corrección (Kiyasseh et al., 2024).

Tabla 12
Criterios para evaluar la reproducibilidad de resultados científicos

Criterio	Aspecto que debe comprobarse	Indicador de reproducibilidad	Riesgo si no se cumple
Documentación	Descripción completa del procedimiento	Pasos analíticos identificables	Imposibilidad de reconstrucción
Disponibilidad de datos	Acceso a la evidencia utilizada	Datos accesibles y contextualizados	Resultados no verificables
Código y herramientas	Procedimientos computacionales empleados	Código ejecutable y documentado	Dependencia de procesos opacos
Consistencia analítica	Correspondencia entre método y resultado	Obtención de resultados semejantes	Variación no explicada
Trazabilidad	Registro de transformaciones	Historial claro del procesamiento	Pérdida del origen del resultado
Validación	Comprobación con criterios independientes	Evaluaciones reproducibles	Confianza basada solo en el resultado original

Nota. Los criterios permiten valorar si un resultado puede reconstruirse y examinarse sin asumir que la reproducción del procedimiento garantiza automáticamente su validez científica.

La reproducibilidad debe distinguirse de la replicación. Reproducir implica obtener nuevamente un resultado utilizando los mismos datos y procedimientos, mientras que replicar supone generar nueva evidencia para examinar si el hallazgo se mantiene. Esta diferencia es importante porque ambos procesos responden a preguntas distintas sobre la confiabilidad. La reproducibilidad permite verificar la coherencia interna de un análisis, mientras que la replicación aporta información sobre la estabilidad externa del hallazgo. Una investigación

confiable se beneficia de ambos procesos, aunque ninguno sustituye la evaluación crítica de la calidad metodológica y del alcance de las conclusiones (Derksen & Morawski, 2022).

La ausencia de reproducibilidad puede revelar problemas relevantes, pero requiere un análisis cuidadoso antes de atribuir responsabilidades o descartar una investigación. Diferencias en versiones de software, configuraciones, procesamiento de datos o instrucciones insuficientes pueden impedir reconstruir un resultado sin que necesariamente exista manipulación. El objetivo de la evaluación debe ser localizar el punto donde surge la divergencia y determinar su efecto sobre la conclusión. Esta revisión permite diferenciar entre fallos técnicos corregibles y limitaciones que comprometen de forma más profunda la confiabilidad del estudio (Helliwell & Massera, 2022).

Los problemas de fuga de datos muestran cómo un resultado puede parecer sólido y, sin embargo, depender de procedimientos que comprometen su validez. En aprendizaje automático, utilizar información de evaluación durante el desarrollo del modelo puede inflar artificialmente el rendimiento y producir conclusiones difíciles de reproducir cuando se aplican controles más estrictos. La reproducibilidad exige documentar la separación entre etapas de entrenamiento, validación y prueba, así como las transformaciones aplicadas a cada conjunto. Este control permite identificar si el rendimiento observado refleja capacidad real del modelo o una ventaja derivada de información utilizada de forma inapropiada (Kapoor & Narayanan, 2023).

La reproducibilidad fortalece la confiabilidad cuando permite examinar de manera transparente cómo se produjo un resultado y bajo qué condiciones puede obtenerse nuevamente. Su importancia no reside en convertir la repetición en garantía absoluta de verdad, sino en ofrecer mecanismos de verificación que hagan visibles errores, decisiones analíticas y dependencias técnicas. Integrada con transparencia, calidad metodológica y validación independiente, permite valorar con mayor precisión qué resultados poseen una base suficientemente estable. La confiabilidad científica aumenta cuando los procedimientos pueden ser revisados y reconstruidos sin depender exclusivamente de la autoridad de quienes produjeron originalmente la evidencia (Mathur & Fox, 2023).

5.3 Replicación y estabilidad de los hallazgos

La replicación permite evaluar si un hallazgo vuelve a aparecer cuando una investigación se repite con nueva evidencia. Su función principal es comprobar la estabilidad externa de los resultados, es decir, si estos se mantienen más allá del conjunto de datos y condiciones

originales. Una replicación puede conservar de forma estricta el diseño inicial o introducir variaciones controladas para examinar la misma hipótesis desde otra configuración. La persistencia de un efecto bajo condiciones comparables aumenta la confianza en su estabilidad, mientras que las discrepancias obligan a revisar qué factores pudieron influir en el resultado inicial (Derksen & Morawski, 2022).

La replicación directa busca reproducir de manera cercana las condiciones esenciales del estudio original. Esto implica mantener, en la medida de lo posible, procedimientos, instrumentos, criterios de selección y formas de análisis similares, pero utilizando una nueva muestra o conjunto de datos. Su utilidad radica en comprobar si el hallazgo depende de características particulares de la investigación inicial. Cuando una replicación directa obtiene resultados semejantes, aumenta el respaldo empírico. Si los resultados divergen, la interpretación debe considerar diferencias contextuales, precisión de las estimaciones y posibles limitaciones metodológicas antes de concluir que el efecto original era inestable (Derksen & Morawski, 2022).

La replicación conceptual, en cambio, examina la misma proposición mediante procedimientos diferentes. Puede modificar instrumentos, contextos o formas de operacionalizar una variable con el propósito de comprobar si el fenómeno persiste cuando cambia la manera de observarlo. Este tipo de replicación permite valorar si el hallazgo representa una relación más general o si depende excesivamente de una configuración metodológica específica. La convergencia entre replicaciones directas y conceptuales ofrece un respaldo más amplio, porque combina estabilidad bajo condiciones similares con consistencia frente a variaciones razonables en el diseño (Derksen & Morawski, 2022).

La estabilidad de un hallazgo no debe evaluarse únicamente mediante la repetición de un resultado estadísticamente significativo. También es necesario examinar la magnitud del efecto, su dirección, la precisión de las estimaciones y la coherencia con otras investigaciones. Dos estudios pueden producir valores distintos y, aun así, resultar compatibles dentro de sus respectivos márgenes de incertidumbre. Por ello, la comparación debe considerar el conjunto de la evidencia y no limitarse a clasificar los resultados como positivos o negativos. La estabilidad se interpreta mejor como un grado de consistencia acumulada que como una condición binaria (Pedder et al., 2022).

La replicación adquiere especial importancia cuando un hallazgo inicial procede de una muestra pequeña o de condiciones poco representativas. En estos casos, el resultado puede estar

sujeto a mayor variabilidad y cambiar ante nuevas observaciones. Repetir la investigación con muestras adicionales permite estimar si el patrón persiste o si dependía de fluctuaciones particulares del conjunto original. La estabilidad aumenta cuando los resultados se mantienen a medida que se incorpora nueva evidencia y cuando las estimaciones se vuelven menos sensibles a pequeñas modificaciones en los datos disponibles (Sondhi et al., 2021).

La transparencia metodológica facilita la replicación porque permite que otros investigadores conozcan con precisión cómo se desarrolló el estudio original. La descripción detallada de procedimientos, criterios de inclusión, materiales y decisiones analíticas reduce la ambigüedad y permite identificar qué componentes deben mantenerse o modificarse en una nueva investigación. Sin esta información, una aparente falta de replicación puede deberse a diferencias no documentadas entre estudios. Las prácticas de ciencia abierta contribuyen a mejorar esta trazabilidad al facilitar el acceso a protocolos, datos y materiales relevantes para reconstruir el diseño original (Mathur & Fox, 2023).


La estabilidad también puede fortalecerse mediante proyectos colaborativos que involucren a varios equipos de investigación. Cuando diferentes grupos aplican protocolos comparables en contextos independientes, es posible examinar si el mismo hallazgo aparece bajo condiciones diversas. Esta estrategia permite identificar fuentes de variación relacionadas con el entorno, la población o la implementación del procedimiento. La colaboración resulta especialmente útil cuando los estudios individuales poseen capacidad limitada para evaluar la generalidad de un efecto. La convergencia entre equipos independientes aporta evidencia más convincente que la repetición exclusiva dentro de un mismo entorno investigador (Leins et al., 2023).

Los resultados que no se replican requieren una interpretación cuidadosa. La ausencia de un efecto en un nuevo estudio puede deberse a diferencias reales entre contextos, menor precisión, cambios metodológicos o a que el hallazgo original fue inestable. No debe asumirse automáticamente que la investigación inicial era incorrecta. La comparación debe identificar qué elementos se mantuvieron y cuáles variaron entre ambos diseños. Este análisis permite determinar si la divergencia afecta la hipótesis central o si revela condiciones específicas bajo las cuales el efecto aparece o desaparece (Omerovic, 2023).

Los sesgos pueden influir tanto en el estudio original como en las replications posteriores. Si diferentes investigaciones comparten instrumentos, fuentes de datos o decisiones analíticas similares, pueden reproducir la misma distorsión y generar una falsa impresión de estabilidad. Por ello, la replicación resulta más informativa cuando existe independencia suficiente entre

los procedimientos y equipos. La consistencia obtenida mediante rutas metodológicas diversas aporta mayor respaldo que la repetición de un mismo conjunto de supuestos. Evaluar la estabilidad exige considerar no solo cuántas veces aparece un hallazgo, sino también cómo fue producido en cada ocasión (Hudson, 2021).

Figura 5
Replicación y estabilidad de los hallazgos científicos



Nota. El esquema distingue las formas de replicación y los factores que permiten valorar la persistencia de los resultados ante nuevas evidencias y condiciones.

En investigaciones basadas en modelos computacionales, la estabilidad puede depender de la calidad de los procedimientos de validación. Un resultado puede parecer replicable cuando

diferentes estudios utilizan bases de datos similares o repiten errores técnicos como la fuga de información entre entrenamiento y evaluación. Por esta razón, la replicación debe incluir controles que garanticen la independencia de los datos y la transparencia de las etapas analíticas. La estabilidad de un modelo se demuestra mejor cuando mantiene su rendimiento frente a datos nuevos y bajo procedimientos que reducen el riesgo de sobreajuste o contaminación entre conjuntos (Kapoor & Narayanan, 2023).

La replicación contribuye a construir confianza científica cuando se entiende como un proceso de evaluación acumulativa y no como una prueba definitiva de verdad. Un hallazgo estable es aquel que mantiene respaldo a través de nuevas observaciones, contextos y procedimientos razonablemente comparables. La convergencia fortalece la confianza, mientras que las discrepancias ayudan a delimitar las condiciones de validez del resultado. Este proceso permite distinguir entre efectos robustos y conclusiones sensibles a circunstancias particulares, haciendo que la estabilidad de los hallazgos dependa de evidencia reiterada, transparente y metodológicamente evaluable (Helliwell & Massera, 2022).

5.4 Sesgos y distorsiones en la producción de evidencia

Los sesgos pueden introducirse en distintas etapas de la producción de evidencia y modificar qué datos se obtienen, cómo se analizan y qué resultados reciben mayor atención. La selección de participantes, variables, instrumentos o criterios de exclusión puede favorecer determinadas interpretaciones antes de iniciar el análisis. Esto no significa que toda decisión metodológica constituya un sesgo, sino que debe evaluarse si produce desviaciones sistemáticas respecto del fenómeno estudiado. La identificación de estas influencias exige revisar el diseño completo y determinar qué decisiones podrían afectar la validez, representatividad o alcance de las conclusiones derivadas de la evidencia (Hudson, 2021).

El sesgo de selección aparece cuando los casos incluidos en una investigación difieren sistemáticamente de aquellos sobre los que se pretende formular una conclusión. Una muestra puede ser amplia y, sin embargo, representar de manera insuficiente determinados grupos, condiciones o contextos. Este problema limita la capacidad de generalización y puede producir asociaciones que dependen de la estructura particular de los datos seleccionados. La evaluación crítica debe examinar cómo se definió la población, qué criterios determinaron la inclusión y qué información quedó fuera del análisis. La pertinencia de la evidencia depende directamente de esta correspondencia entre datos y problema investigado (Rickinson et al., 2021).

Las decisiones analíticas también pueden generar distorsiones cuando existen múltiples procedimientos razonables y se seleccionan aquellos que producen resultados más favorables a una hipótesis. Cambios en variables, transformaciones, criterios de exclusión o especificaciones estadísticas pueden modificar las estimaciones finales. La existencia de diferentes alternativas no constituye por sí misma una práctica incorrecta, pero exige transparencia sobre las decisiones adoptadas y sus efectos. Los análisis de sensibilidad permiten comprobar si la conclusión permanece estable ante modificaciones razonables y ayudan a distinguir entre hallazgos robustos y resultados excesivamente dependientes de una única configuración metodológica (Gough, 2021).

En investigaciones computacionales, la fuga de datos constituye una fuente específica de distorsión. Este problema ocurre cuando información que debería permanecer reservada para evaluar un modelo influye directa o indirectamente en su entrenamiento o selección. El rendimiento obtenido puede entonces parecer superior al que realmente alcanzaría con datos independientes. La distorsión puede reproducirse en distintos estudios si se mantienen procedimientos similares, generando una apariencia engañosa de consistencia. La separación rigurosa entre entrenamiento, validación y prueba resulta necesaria para valorar si el desempeño observado representa capacidad real del sistema o contaminación metodológica (Kapoor & Narayanan, 2023).

Los sistemas automatizados introducen además dificultades cuando no existe una referencia suficientemente clara para comprobar la corrección de sus resultados. En estas condiciones, la evaluación puede depender de anotaciones humanas, criterios indirectos o comparaciones entre métodos, cada uno sujeto a sus propias limitaciones. Una validación insuficiente puede transformar errores sistemáticos del sistema en evidencia aparentemente confiable. Por ello, es necesario examinar qué criterio se utiliza como referencia, cómo se mide el desempeño y qué incertidumbre permanece cuando no existe un valor verdadero directamente observable. Estas condiciones son centrales para interpretar resultados generados automáticamente (Kiyasseh et al., 2024).

Tabla 13
Principales sesgos y distorsiones en la producción de evidencia

Tipo de sesgo o distorsión	Etapas donde puede surgir	Efecto sobre la evidencia	Medida de control
Sesgo de selección	Muestreo	Representación limitada del fenómeno	Criterios de inclusión explícitos

Tipo de sesgo o distorsión	Etapas donde puede surgir	Efecto sobre la evidencia	Medida de control
Sesgo de medición	Producción de datos	Registros sistemáticamente desviados	Validación de instrumentos
Sesgo analítico	Procesamiento	Resultados dependientes de decisiones particulares	Análisis de sensibilidad
Sesgo de confirmación	Interpretación	Preferencia por resultados compatibles con expectativas	Evaluación de hipótesis alternativas
Fuga de datos	Modelos automatizados	Rendimiento artificialmente elevado	Separación estricta de conjuntos
Sesgo de publicación	Comunicación	Sobreexposición de ciertos resultados	Registro y reporte transparente

Nota. La clasificación permite localizar las principales fuentes de distorsión y relacionarlas con procedimientos específicos de prevención, detección o evaluación crítica.

El sesgo de confirmación puede afectar la interpretación cuando se concede mayor peso a resultados compatibles con expectativas previas y se minimizan hallazgos discrepantes. Esta tendencia puede manifestarse en la formulación de hipótesis, selección de análisis o discusión de resultados. Reducir su influencia exige considerar explicaciones alternativas y mantener criterios explícitos para valorar evidencia favorable y desfavorable. La objetividad científica no requiere ausencia absoluta de perspectivas previas, pero sí procedimientos que permitan examinar críticamente cómo esas perspectivas pueden influir en las decisiones y en la fuerza atribuida a determinadas conclusiones (Hudson, 2021).

Las distorsiones también pueden aparecer durante la síntesis de evidencia cuando estudios con resultados similares comparten fuentes de datos, instrumentos o supuestos metodológicos. La convergencia aparente puede interpretarse erróneamente como independencia entre evidencias. Por ello, evaluar un cuerpo de resultados requiere determinar si las investigaciones aportan información realmente nueva o reproducen limitaciones comunes. La consistencia adquiere mayor valor cuando procede de diseños independientes y cuando las diferencias entre estudios se analizan explícitamente. Este criterio evita confundir repetición metodológica con confirmación y permite valorar con mayor precisión la estabilidad de los hallazgos acumulados (Pedder et al., 2022).

La transparencia contribuye a detectar distorsiones al permitir revisar datos, procedimientos y decisiones analíticas. El acceso a materiales de investigación facilita reproducir resultados, evaluar alternativas e identificar errores que podrían permanecer ocultos en la publicación final. Sin embargo, la apertura debe acompañarse de documentación suficiente, porque datos o códigos descontextualizados no garantizan una revisión efectiva. La trazabilidad permite

reconstruir el proceso mediante el cual una observación se convirtió en resultado y determinar qué decisiones pudieron modificarlo. Esta posibilidad fortalece la evaluación de la confiabilidad y reduce la dependencia exclusiva de la interpretación presentada por los autores (Mathur & Fox, 2023).

El control de sesgos no consiste en asumir que puede eliminarse toda influencia metodológica o conceptual, sino en identificar las fuentes que podrían distorsionar la evidencia y estimar su efecto. Una investigación sólida hace visibles sus decisiones, examina alternativas y evita presentar resultados sensibles como si fueran conclusiones definitivas. La evaluación debe distinguir entre variación legítima, incertidumbre y desviaciones sistemáticas que alteran la representación del fenómeno. Reconocer estos factores permite ajustar la confianza atribuida a los hallazgos y preservar una relación más precisa entre los datos producidos, los procedimientos empleados y las afirmaciones científicas formuladas (Gough, 2021).

5.5 Confianza científica ante resultados inciertos

La confianza científica ante resultados inciertos depende de la capacidad de distinguir entre incertidumbre reconocida y falta de fundamento. Un resultado puede conservar márgenes de duda y, aun así, ser confiable si procede de métodos adecuados, evidencia pertinente y procesos transparentes. La confianza no exige certeza absoluta, sino razones suficientes para aceptar provisionalmente una conclusión dentro de límites explícitos. Esta distinción resulta importante porque permite evitar dos extremos: considerar que toda incertidumbre invalida el conocimiento o asumir que una conclusión es confiable únicamente porque ha sido presentada como científica. La evaluación debe centrarse en las bases reales que sostienen la afirmación (Metzen, 2024).

La incertidumbre puede afectar la confianza de manera distinta según cómo se comunique. Cuando se explican con precisión las limitaciones, el grado de respaldo y las razones que justifican una conclusión, los lectores pueden comprender mejor qué aspectos permanecen abiertos. Por el contrario, una comunicación ambigua o excesivamente categórica puede generar interpretaciones erróneas sobre el nivel de certeza disponible. La confianza se relaciona, por tanto, con la correspondencia entre evidencia y lenguaje. Comunicar incertidumbre no implica necesariamente reducir credibilidad, siempre que se preserve claridad sobre aquello que está suficientemente sustentado y aquello que todavía requiere nueva evidencia (Schneider et al., 2022).

La confianza también depende de la transparencia metodológica. Resultados inciertos pueden ser evaluados con mayor rigor cuando se conocen los procedimientos de recolección, análisis y tratamiento de datos. La posibilidad de revisar cómo se produjo una conclusión permite distinguir entre incertidumbre inherente al fenómeno y problemas derivados del diseño o del análisis. Esta trazabilidad fortalece la confianza porque permite identificar dónde se concentran las limitaciones y qué aspectos podrían modificarse con nueva evidencia. La ciencia resulta más evaluable cuando explicita las condiciones que sostienen sus conclusiones, en lugar de presentar resultados inciertos como si fueran definitivos (Covitt & Anderson, 2022).

La confianza científica puede reducirse cuando los resultados dependen excesivamente de supuestos, muestras limitadas o decisiones analíticas sensibles. En estos casos, la evaluación debe considerar cuánto podría cambiar la conclusión si se incorporaran nuevos datos o se modificaran determinadas condiciones. La estabilidad del resultado constituye un criterio importante para valorar si la incertidumbre es compatible con una conclusión razonablemente robusta. Un hallazgo puede seguir siendo útil cuando sus límites están bien caracterizados, pero requiere mayor cautela si pequeñas variaciones producen interpretaciones sustancialmente diferentes (Sondhi et al., 2021).

La comunicación de riesgos ofrece un ejemplo claro de cómo la incertidumbre influye en la confianza. Cuando se presentan estimaciones relacionadas con peligros o consecuencias potenciales, es necesario diferenciar entre aquello que se conoce con mayor respaldo y aquello que permanece sujeto a variación. La forma de describir la incertidumbre puede modificar la percepción del riesgo y la valoración de quienes producen la información. Por ello, la confianza no depende únicamente del resultado numérico, sino también de la claridad con que se explican sus límites, su significado y las condiciones bajo las cuales podría cambiar (Wiedemann et al., 2021).

Tabla 14
Factores que influyen en la confianza científica ante resultados inciertos

Factor	Función en la confianza	Condición favorable	Riesgo si se gestiona mal
Transparencia	Permite revisar el proceso	Métodos y límites explícitos	Opacidad metodológica
Consistencia	Muestra estabilidad	Resultados compatibles entre estudios	Dependencia de un único hallazgo
Comunicación	Ajusta expectativas	Lenguaje proporcional a la evidencia	Exceso o defecto de certeza
Reproducibilidad	Facilita verificación	Procedimientos reconstruibles	Resultados difíciles de comprobar

Factor	Función en la confianza	Condición favorable	Riesgo si se gestiona mal
Incertidumbre cuantificada	Delimita el alcance	Rangos y supuestos visibles	Falsa precisión
Revisión continua	Permite actualizar conclusiones	Apertura a nueva evidencia	Rigidez interpretativa


Nota. Los factores muestran que la confianza científica depende de la calidad y trazabilidad de la evidencia, así como de la forma en que se comunican sus límites.

La confianza aumenta cuando los resultados inciertos pueden compararse con evidencia independiente. La convergencia entre estudios, métodos o fuentes distintas permite valorar si un hallazgo se mantiene bajo condiciones diversas. Sin embargo, la consistencia debe interpretarse con cautela cuando las investigaciones comparten los mismos datos, instrumentos o supuestos. La confianza resulta más sólida cuando la evidencia procede de procedimientos suficientemente independientes y cuando las discrepancias también son analizadas. Esta práctica evita que la coincidencia superficial se utilice como argumento automático de confiabilidad y permite distinguir entre estabilidad genuina y repetición de las mismas limitaciones (Pedder et al., 2022).

La confianza científica también requiere reconocer que algunas incertidumbres no pueden eliminarse completamente. En determinados problemas, las limitaciones provienen de la complejidad del fenómeno, de la imposibilidad de observar directamente ciertas variables o de la existencia de varias explicaciones compatibles con los datos. La respuesta adecuada no consiste en ocultar estas restricciones, sino en incorporarlas a la evaluación de la evidencia. Una conclusión puede conservar valor si delimita con claridad qué aspectos están bien sustentados y qué componentes permanecen sujetos a revisión o a explicaciones alternativas (Schnarr & Mertz, 2022).

La toma de decisiones basada en resultados inciertos exige distinguir entre confianza suficiente y certeza inexistente. En algunos contextos, esperar evidencia completa puede ser imposible o incluso contraproducente, especialmente cuando existen riesgos potenciales relevantes. La evaluación debe considerar la gravedad de las consecuencias, la calidad de la evidencia y el grado de incertidumbre disponible. La confianza se vuelve entonces un criterio gradual que orienta la decisión sin pretender eliminar todo margen de duda. Este enfoque permite actuar con base en evidencia razonable y, al mismo tiempo, mantener abiertas las posibilidades de revisión (Aven, 2023).

La confianza científica ante resultados inciertos se construye mediante una relación coherente entre evidencia, transparencia, consistencia y comunicación. No depende de presentar conclusiones como definitivas, sino de mostrar qué razones permiten sostenerlas y bajo qué condiciones podrían cambiar. Una ciencia confiable mantiene visibles sus incertidumbres, distingue entre distintos grados de respaldo y facilita la revisión de sus procedimientos. Esta forma de evaluación permite conservar credibilidad sin transformar la incertidumbre en debilidad, porque la confianza se fundamenta en la calidad de la justificación y en la posibilidad de someter los resultados a contraste continuo (Metzen, 2024).



Capítulo 6.



Nuevas tecnologías en la construcción de evidencia

Mario Fernando Herrera Venegas

6.1 Datos masivos y nuevas fuentes de evidencia

Los datos masivos han ampliado las fuentes de evidencia disponibles para la investigación científica al incorporar registros generados de forma continua por plataformas digitales, sensores, sistemas administrativos, dispositivos conectados y repositorios de gran escala. Esta expansión permite analizar fenómenos con un nivel de detalle y una cobertura antes difíciles de alcanzar. Sin embargo, el volumen por sí mismo no garantiza calidad evidencial. Los datos deben evaluarse según su procedencia, estructura, representatividad y relación con la pregunta científica. Su valor depende de que puedan integrarse en procesos analíticos capaces de distinguir patrones relevantes de asociaciones accidentales o sesgadas (Hansen & Quinon, 2023).

La utilización de datos masivos modifica también la relación entre observación y evidencia. En investigaciones tradicionales, los datos suelen producirse mediante procedimientos diseñados específicamente para una pregunta. En entornos digitales, en cambio, gran parte de la información se genera con otros fines y posteriormente se reutiliza para investigación. Esta diferencia obliga a examinar con mayor atención cómo fueron producidos los registros, qué variables contienen y qué aspectos del fenómeno permanecen fuera de ellos. La reutilización puede ampliar las posibilidades de análisis, pero también introduce incertidumbre sobre la adecuación conceptual de los datos para sostener determinadas afirmaciones científicas (Rickinson et al., 2021).

Otra característica de los datos masivos es su heterogeneidad. Pueden combinar texto, imágenes, secuencias, registros temporales, información geográfica y variables provenientes de múltiples sistemas. Esta diversidad favorece análisis integrados, pero también aumenta la complejidad de limpieza, codificación y estandarización. Las decisiones adoptadas durante estas etapas pueden modificar los patrones finales y, por tanto, la evidencia obtenida. La trazabilidad resulta esencial para conocer qué transformaciones experimentaron los datos antes del análisis y para evaluar si los resultados dependen de decisiones técnicas específicas o de regularidades genuinas presentes en la información (Burrows, 2023).

La escala de los conjuntos de datos puede generar una falsa sensación de precisión. Un número elevado de observaciones reduce ciertos errores muestrales, pero no corrige automáticamente problemas de cobertura, medición o selección. Un conjunto enorme puede representar de manera deficiente a la población de interés si los datos proceden de usuarios, dispositivos o contextos no equivalentes. En estas condiciones, la abundancia puede aumentar la precisión

estadística de una estimación sesgada. La evaluación de evidencia basada en datos masivos debe considerar tanto la cantidad de información como los mecanismos mediante los cuales fue generada y quiénes quedan representados en ella (Gough, 2021).

El conocimiento experto continúa siendo necesario para interpretar patrones detectados en grandes volúmenes de información. Los algoritmos pueden identificar asociaciones complejas, pero no determinan por sí solos cuáles tienen significado científico ni qué mecanismos podrían explicarlas. La selección de variables, la construcción de modelos y la interpretación de resultados requieren criterios conceptuales y disciplinares. La combinación entre capacidad computacional y conocimiento experto permite evitar que correlaciones estadísticamente destacadas sean tratadas como evidencia suficiente de relaciones relevantes. En este contexto, la calidad de la inferencia depende de integrar procesamiento automatizado con evaluación científica explícita (Hansen & Quinon, 2023).

Tabla 15
Características de los datos masivos como fuente de evidencia científica

Característica	Aporte potencial	Riesgo asociado	Criterio de evaluación
Gran volumen	Mayor cobertura de observaciones	Falsa sensación de precisión	Representatividad
Alta velocidad	Seguimiento casi continuo	Cambios en calidad del registro	Consistencia temporal
Heterogeneidad	Integración de múltiples fuentes	Problemas de compatibilidad	Estandarización
Reutilización	Aprovechamiento de datos existentes	Desajuste con la pregunta científica	Pertinencia
Automatización	Procesamiento a gran escala	Opacidad analítica	Trazabilidad
Alta dimensionalidad	Identificación de patrones complejos	Asociaciones espurias	Validación independiente

Nota. La utilidad científica de los datos masivos depende de cómo se controlan su procedencia, representatividad, procesamiento y correspondencia con el problema investigado.

La alta dimensionalidad introduce retos inferenciales porque aumenta la cantidad de relaciones posibles entre variables. En conjuntos extensos es probable encontrar asociaciones que parecen relevantes por azar, especialmente cuando se exploran muchas combinaciones sin criterios previos claros. La validación mediante datos independientes ayuda a distinguir patrones estables de coincidencias particulares del conjunto inicial. Este problema adquiere especial importancia en aprendizaje automático, donde un modelo puede ajustarse con gran precisión a los datos disponibles y fallar cuando se enfrenta a información nueva. La solidez de la evidencia

depende entonces de procedimientos que reduzcan sobreajuste y contaminación analítica (Kapoor & Narayanan, 2023).

Los datos masivos también pueden ampliar la evidencia disponible mediante la integración de fuentes que antes permanecían separadas. La combinación de registros clínicos, administrativos, ambientales o digitales permite estudiar relaciones complejas y formular hipótesis nuevas. Sin embargo, cada fuente posee criterios de producción distintos y puede incorporar sesgos específicos. Integrarlas exige documentar definiciones, escalas y procesos de armonización para evitar que diferencias técnicas sean interpretadas como variaciones reales del fenómeno. La convergencia entre fuentes resulta más informativa cuando sus limitaciones son conocidas y cuando los resultados pueden contrastarse mediante procedimientos independientes (Arias Valencia, 2022).

La apertura y documentación de los datos adquieren especial importancia en investigaciones de gran escala. El acceso a conjuntos utilizados, códigos de procesamiento y decisiones analíticas permite evaluar cómo se construyó la evidencia y qué transformaciones influyeron en el resultado. Estas prácticas facilitan reproducir análisis y detectar errores que serían difíciles de identificar a partir de una publicación resumida. Sin embargo, la apertura debe considerar también restricciones éticas, técnicas y de privacidad cuando los registros contienen información sensible. La reproducibilidad exige equilibrio entre transparencia científica y condiciones responsables de acceso y reutilización (Mathur & Fox, 2023).

Los datos masivos constituyen una fuente de evidencia con gran capacidad analítica, pero su valor científico depende de criterios metodológicos similares a los aplicados a cualquier otra información empírica: calidad, pertinencia, trazabilidad y capacidad de sostener inferencias justificables. La escala no sustituye estos requisitos. Al contrario, puede hacer más difícil detectar sesgos o errores cuando los procesos de producción y transformación son complejos. La investigación basada en grandes conjuntos de datos requiere combinar infraestructura computacional, conocimiento experto y procedimientos de validación que permitan distinguir entre patrones técnicamente detectables y evidencia científicamente significativa (Hansen & Quinon, 2023).

6.2 Modelos computacionales como instrumentos de inferencia

Los modelos computacionales funcionan como instrumentos de inferencia cuando permiten representar relaciones entre variables, explorar mecanismos posibles y derivar consecuencias que pueden compararse con datos observados. Su utilidad científica no reside únicamente en

producir cálculos, sino en organizar supuestos de manera explícita y mostrar cómo determinadas condiciones generan ciertos resultados. Estos modelos pueden ayudar a identificar patrones difíciles de observar directamente y a evaluar hipótesis sobre sistemas complejos. Sin embargo, toda inferencia depende de la correspondencia entre la estructura del modelo y el fenómeno estudiado, por lo que su capacidad explicativa debe evaluarse frente a evidencia independiente (Monti et al., 2023).

La construcción de un modelo exige seleccionar variables, relaciones, parámetros y condiciones iniciales. Estas decisiones simplifican el fenómeno para hacerlo analizable, pero también delimitan qué aspectos pueden inferirse. Un modelo puede representar adecuadamente ciertos patrones y dejar fuera interacciones relevantes que modificarían la interpretación. Por ello, el ajuste entre los datos y la estructura computacional no constituye por sí solo evidencia suficiente de que el modelo reproduzca el mecanismo real. La inferencia requiere examinar qué supuestos sostienen la representación y hasta qué punto las conclusiones cambian cuando se modifican razonablemente esos supuestos (Fajardo-Fontiveros et al., 2023).

Los modelos basados en agentes constituyen un ejemplo de cómo la computación puede utilizarse para inferir propiedades de sistemas formados por múltiples unidades interactivas. Estos modelos representan comportamientos individuales y permiten explorar cómo sus interacciones generan patrones agregados. La comparación entre resultados simulados y datos empíricos ayuda a determinar qué configuraciones resultan compatibles con el fenómeno observado. Sin embargo, diferentes combinaciones de reglas pueden producir patrones semejantes, lo que limita la identificación de un único mecanismo. La inferencia debe entonces incorporar procedimientos de calibración, validación y comparación entre modelos alternativos antes de atribuir capacidad explicativa a una configuración particular (Monti et al., 2023).

La incorporación de grandes volúmenes de datos ha ampliado la capacidad de ajustar y evaluar modelos computacionales. El aprendizaje automático permite identificar relaciones de alta dimensionalidad que resultarían difíciles de detectar mediante procedimientos manuales. No obstante, la disponibilidad de datos no elimina la necesidad de conocimiento experto. Las decisiones sobre qué variables incluir, cómo interpretar los patrones y qué relaciones poseen relevancia científica dependen de criterios conceptuales que no surgen automáticamente del algoritmo. La inferencia computacional adquiere mayor valor cuando integra capacidad de procesamiento con conocimiento disciplinar y procedimientos que permitan examinar críticamente los resultados obtenidos (Hansen & Quinon, 2023).

La trazabilidad constituye una condición importante para evaluar modelos computacionales. Cuando los procedimientos de preprocesamiento, parametrización, ajuste y validación no están suficientemente documentados, resulta difícil identificar qué decisiones influyeron en el resultado. Esta dificultad puede aumentar en modelos complejos que incorporan múltiples etapas de transformación. La posibilidad de reconstruir el proceso permite comprobar si las conclusiones derivan efectivamente de los datos y de los métodos declarados. Documentar código, configuraciones y secuencias analíticas facilita reproducir la inferencia y evaluar si pequeñas modificaciones producen cambios relevantes en las conclusiones (Burrows, 2023).

Tabla 16
Funciones y criterios de evaluación de los modelos computacionales en la inferencia científica

Función del modelo	Aporte inferencial	Condición necesaria	Riesgo principal
Representación	Formalizar relaciones entre variables	Supuestos explícitos	Simplificación excesiva
Exploración	Examinar escenarios posibles	Parámetros justificables	Resultados dependientes de configuraciones
Predicción	Anticipar resultados	Validación con datos independientes	Sobreajuste
Simulación	Reproducir dinámicas posibles	Correspondencia con mecanismos plausibles	Confundir simulación con explicación
Comparación	Contrastar modelos alternativos	Criterios comunes de evaluación	Selección arbitraria
Validación	Examinar desempeño	Evidencia externa o referencia adecuada	Confianza excesiva en resultados internos

Nota. La evaluación de un modelo debe considerar tanto su capacidad de ajuste como la transparencia de sus supuestos, estabilidad y desempeño frente a evidencia independiente.

La validación es central porque permite determinar si un modelo mantiene su capacidad inferencial más allá de los datos utilizados para construirlo. Una evaluación realizada únicamente con la información empleada durante el ajuste puede producir una imagen excesivamente favorable del desempeño. La utilización de datos independientes permite comprobar si los patrones identificados se generalizan hacia nuevas observaciones. En sistemas automatizados, esta exigencia se vuelve especialmente relevante cuando no existe una referencia única o definitiva para establecer la corrección de las salidas, lo que obliga a emplear procedimientos de evaluación capaces de caracterizar también la incertidumbre del resultado (Kiyasseh et al., 2024).

Los análisis de sensibilidad permiten examinar cuánto dependen las conclusiones de parámetros, supuestos o configuraciones específicas. Si pequeñas modificaciones generan cambios importantes en los resultados, la inferencia debe presentarse con mayor cautela. Por el contrario, una conclusión que permanece estable bajo diferentes especificaciones recibe mayor respaldo. Este procedimiento es especialmente útil en sistemas complejos, donde distintas combinaciones de variables pueden ajustarse de manera similar a los datos observados. La estabilidad frente a alternativas razonables ayuda a diferenciar entre resultados robustos y patrones que dependen excesivamente de una única estructura computacional (Fajardo-Fontiveros et al., 2023).

La inferencia computacional también debe distinguir entre capacidad predictiva y capacidad explicativa. Un modelo puede realizar predicciones precisas sin representar adecuadamente los mecanismos causales que producen el fenómeno. Esta diferencia resulta importante cuando se pretende utilizar el resultado para formular explicaciones científicas o intervenir sobre el sistema. La precisión predictiva constituye evidencia sobre el desempeño del modelo, pero no demuestra necesariamente que sus relaciones internas correspondan con procesos reales. La interpretación debe considerar qué tipo de conclusión permite sostener el modelo y evitar convertir automáticamente una asociación predictiva en explicación causal (Hansen & Quinon, 2023).

Los modelos computacionales fortalecen la inferencia cuando funcionan como representaciones transparentes, contrastables y revisables de hipótesis científicas. Su utilidad depende de la calidad de los datos, de la justificación de los supuestos y de la existencia de procedimientos que permitan comparar resultados con evidencia independiente. Un modelo no sustituye la observación ni elimina la incertidumbre, sino que organiza relaciones posibles y ayuda a evaluar sus consecuencias. La confianza en sus conclusiones aumenta cuando la estructura puede examinarse, los resultados son reproducibles y la sensibilidad frente a configuraciones alternativas se mantiene dentro de límites científicamente aceptables (Monti et al., 2023).

6.3 Inteligencia artificial en el análisis de evidencia científica

La inteligencia artificial se ha incorporado al análisis de evidencia científica mediante sistemas capaces de clasificar documentos, extraer información, identificar patrones y apoyar procesos de síntesis. Estas herramientas pueden reducir el tiempo necesario para revisar grandes volúmenes de literatura y facilitar la organización de resultados procedentes de múltiples

fuentes. Sin embargo, su utilidad depende de que los criterios de búsqueda, selección y análisis sean transparentes. La automatización no convierte automáticamente la información procesada en evidencia sólida, porque la calidad final sigue condicionada por la pertinencia de los datos y por las decisiones metodológicas que orientan el sistema (de la Torre-López et al., 2023).

En las revisiones sistemáticas, la inteligencia artificial puede utilizarse para detectar estudios relevantes, clasificar resúmenes y priorizar documentos para su revisión. Los modelos de aprendizaje automático permiten procesar corpus extensos y reducir tareas repetitivas, especialmente cuando existen miles de registros potenciales. No obstante, una clasificación automatizada puede omitir estudios pertinentes o incluir materiales irrelevantes si el modelo fue entrenado con criterios inadecuados. La evaluación humana continúa siendo necesaria para revisar los límites del sistema y comprobar que las decisiones automatizadas se correspondan con los objetivos de la investigación (de la Torre-López et al., 2023).

El análisis automatizado de evidencia también puede apoyar la extracción de datos desde artículos científicos. Los sistemas de procesamiento del lenguaje natural identifican conceptos, variables, relaciones y resultados que posteriormente pueden integrarse en procesos de síntesis. Esta capacidad resulta útil cuando la información está distribuida entre numerosos documentos y presenta formatos heterogéneos. Sin embargo, la extracción depende de cómo el algoritmo interpreta el texto y de la calidad de los patrones con los que fue entrenado. Errores de clasificación o pérdida de contexto pueden transformar información correcta en evidencia mal representada si no existen mecanismos de verificación adecuados (de la Torre-López et al., 2023).

Los modelos de inteligencia artificial pueden identificar regularidades que serían difíciles de detectar mediante revisión manual, especialmente en conjuntos de datos de alta dimensionalidad. Esta capacidad amplía las posibilidades exploratorias y permite formular nuevas hipótesis a partir de asociaciones previamente poco visibles. No obstante, la detección de un patrón no equivale a una explicación científica. Las relaciones identificadas deben evaluarse mediante conocimiento experto y procedimientos capaces de distinguir entre correlaciones relevantes y coincidencias derivadas de la estructura de los datos. La interpretación sigue siendo una etapa central para convertir resultados algorítmicos en evidencia científicamente significativa (Hansen & Quinon, 2023).

La calidad del análisis automatizado depende de la calidad de los datos utilizados para entrenar y evaluar los modelos. Conjuntos sesgados, incompletos o poco representativos pueden

producir resultados que parecen precisos dentro de la muestra original y fallan al aplicarse a nuevos contextos. Este problema puede mantenerse oculto cuando el sistema procesa grandes volúmenes de información, porque la escala no corrige automáticamente defectos de representación. La evaluación crítica debe examinar la procedencia de los datos y la correspondencia entre el conjunto de entrenamiento y las condiciones en que se utilizarán los resultados (Kapoor & Narayanan, 2023).

La fuga de datos constituye un riesgo especialmente importante en sistemas de inteligencia artificial aplicados a investigación. Si información destinada a la evaluación influye durante el entrenamiento o la selección del modelo, el rendimiento obtenido puede quedar artificialmente inflado. Esta distorsión puede conducir a considerar como robusto un sistema que en realidad depende de contaminación entre conjuntos. La separación rigurosa entre entrenamiento, validación y prueba es necesaria para valorar la capacidad real del modelo. También debe documentarse cada transformación aplicada a los datos para que el proceso pueda reconstruirse y evaluarse de manera independiente (Kapoor & Narayanan, 2023).

La inteligencia artificial puede apoyar la evaluación de hipótesis cuando permite comparar patrones observados con predicciones derivadas de diferentes modelos. En estos casos, el sistema contribuye a ordenar grandes cantidades de evidencia y a identificar configuraciones que reciben mayor respaldo. Sin embargo, la inferencia no debe depender exclusivamente del resultado algorítmico. Los supuestos incorporados en el modelo, la selección de variables y los criterios de evaluación condicionan las conclusiones. Una interpretación rigurosa debe considerar qué alternativas fueron comparadas y si la evidencia disponible permite realmente discriminar entre ellas (Wei et al., 2022).

La explicabilidad adquiere relevancia cuando los sistemas automatizados participan en decisiones científicas. Un modelo puede alcanzar alta precisión y, aun así, ofrecer poca información sobre cómo llegó a una determinada conclusión. Esta opacidad dificulta valorar si el resultado se basa en características científicamente pertinentes o en patrones accidentales presentes en los datos. La trazabilidad del proceso analítico permite revisar qué variables influyeron, cómo se transformó la información y qué criterios condujeron al resultado final. Sin estos elementos, la confianza puede depender excesivamente del rendimiento agregado del sistema (Burrows, 2023).

Figura 6

Aplicaciones y criterios de la inteligencia artificial en el análisis de evidencia científica



Nota. El esquema relaciona las principales funciones de la inteligencia artificial con los controles necesarios para sostener la calidad y confiabilidad del análisis científico.

La validación de resultados producidos por inteligencia artificial requiere procedimientos que vayan más allá de la comparación interna con datos utilizados durante el desarrollo. La evaluación frente a conjuntos independientes ayuda a determinar si el sistema mantiene su desempeño en condiciones nuevas. Cuando no existe una referencia definitiva o ground truth, la validación se vuelve más compleja y puede requerir múltiples criterios, comparaciones con expertos o métodos alternativos. Esta situación obliga a caracterizar explícitamente la incertidumbre y a evitar que una única medida de desempeño sea utilizada como garantía suficiente de confiabilidad (Kiyasseh et al., 2024).

La inteligencia artificial también modifica la escala de la síntesis de evidencia al permitir integrar grandes volúmenes de resultados en periodos relativamente cortos. Esta ventaja puede facilitar revisiones más amplias, pero aumenta la necesidad de control metodológico. Si los criterios automatizados de selección, extracción o clasificación contienen errores sistemáticos, estos pueden propagarse a lo largo de todo el proceso y afectar la conclusión final. La eficiencia debe acompañarse de procedimientos de supervisión, validación y documentación que permitan detectar dónde surge una posible distorsión y qué impacto tiene sobre la evidencia producida (de la Torre-López et al., 2023).

La inteligencia artificial puede ampliar la capacidad analítica de la investigación científica, pero su valor depende de que los sistemas permanezcan integrados en procedimientos transparentes y evaluables. Los algoritmos pueden organizar información, identificar patrones y apoyar inferencias, aunque no sustituyen la necesidad de justificar por qué un resultado debe considerarse evidencia. La confiabilidad exige datos adecuados, validación independiente, control de sesgos y revisión de los supuestos que sostienen el modelo. Bajo estas condiciones, la inteligencia artificial funciona como instrumento de análisis y no como fuente autónoma de autoridad científica (Hansen & Quinon, 2023).

6.4 Evidencia generada mediante simulaciones

La evidencia generada mediante simulaciones surge cuando un modelo computacional reproduce procesos, escenarios o dinámicas con el propósito de examinar comportamientos difíciles de observar directamente. Su valor científico depende de la relación entre las reglas del modelo, los datos utilizados y el fenómeno que se pretende representar. Una simulación permite explorar consecuencias posibles bajo condiciones controladas, pero no constituye por sí misma una prueba definitiva. La evidencia adquiere fuerza cuando los resultados simulados pueden compararse con observaciones empíricas, reproducirse bajo parámetros transparentes y mantenerse estables frente a modificaciones razonables de la configuración (Nilsson et al., 2022).

Las simulaciones permiten estudiar sistemas complejos mediante la representación explícita de relaciones entre múltiples componentes. Al modificar parámetros, condiciones iniciales o reglas de interacción, los investigadores pueden observar cómo cambian los resultados y qué mecanismos podrían explicar determinados patrones. Esta capacidad resulta especialmente útil cuando los experimentos reales son costosos, lentos o inviables. Sin embargo, cada simulación simplifica el fenómeno y omite aspectos que pueden resultar relevantes. Por ello, las

conclusiones deben interpretarse como dependientes de una estructura modelada y no como una reproducción completa de la realidad (Monti et al., 2023).

La construcción de evidencia mediante simulaciones exige distinguir entre ajuste y explicación. Un modelo puede reproducir con precisión un patrón observado sin representar necesariamente el mecanismo real que lo produce. Diferentes configuraciones pueden generar resultados semejantes y conducir a interpretaciones distintas. Esta situación se vuelve más importante cuando el sistema contiene ruido, variables no observadas o múltiples relaciones posibles. La comparación entre modelos alternativos y la validación con datos independientes permiten reducir parte de esta ambigüedad, aunque no eliminan completamente la incertidumbre sobre cuál estructura representa mejor el fenómeno (Fajardo-Fontiveros et al., 2023).

Las simulaciones también pueden utilizarse para generar datos sintéticos que amplían la exploración de escenarios. Estos datos permiten analizar situaciones poco frecuentes, examinar límites de un modelo o evaluar cómo respondería un sistema bajo condiciones que todavía no se han observado. Sin embargo, la utilidad de los datos sintéticos depende de la calidad de las reglas mediante las cuales fueron generados. Si el modelo reproduce sesgos o simplificaciones presentes en los datos originales, la simulación puede amplificar esas distorsiones. La evidencia simulada debe, por tanto, mantenerse vinculada con procedimientos de validación empírica y análisis crítico de los supuestos (Nilsson et al., 2022).

La calibración constituye una etapa importante en la construcción de simulaciones. Consiste en ajustar parámetros del modelo para que sus resultados se aproximen a patrones observados en datos reales. Una buena calibración mejora la correspondencia entre el sistema simulado y el fenómeno de interés, pero puede generar sobreajuste si el modelo se adapta excesivamente a un conjunto específico de observaciones. Para reducir este riesgo, es necesario comprobar el desempeño con datos que no hayan intervenido en el ajuste. La separación entre calibración y validación permite evaluar si el modelo conserva capacidad explicativa fuera del escenario utilizado para construirlo (Monti et al., 2023).

La sensibilidad de los resultados frente a cambios en parámetros y condiciones iniciales debe evaluarse de manera sistemática. Cuando pequeñas modificaciones producen resultados muy distintos, la evidencia simulada presenta mayor incertidumbre y requiere una interpretación cautelosa. En cambio, una conclusión que se mantiene bajo diferentes configuraciones recibe mayor respaldo dentro del marco del modelo. Los análisis de sensibilidad permiten identificar qué parámetros ejercen mayor influencia y qué supuestos condicionan las inferencias. Esta

información ayuda a distinguir entre patrones robustos y resultados que dependen excesivamente de una combinación específica de condiciones (Fajardo-Fontiveros et al., 2023).

Las simulaciones pueden contribuir al razonamiento abductivo cuando permiten explorar qué mecanismos generan patrones similares a los observados. Un investigador puede comparar diferentes configuraciones y determinar cuáles producen resultados compatibles con la evidencia empírica. Este procedimiento ayuda a formular explicaciones plausibles, pero no demuestra que el mecanismo simulado sea el único posible. La abducción basada en simulaciones exige comparar alternativas y buscar evidencia adicional que permita discriminar entre ellas. La fuerza de la explicación aumenta cuando diferentes líneas de evidencia convergen hacia mecanismos compatibles y cuando los resultados pueden reproducirse bajo condiciones independientes (Engelschalt et al., 2023).

La transparencia resulta esencial para valorar la evidencia generada por simulaciones. Los modelos deben documentar sus reglas, parámetros, fuentes de datos, supuestos y procedimientos de ejecución. Sin esta información, resulta difícil reconstruir el experimento computacional o determinar por qué se obtuvo un resultado específico. La trazabilidad permite identificar qué decisiones influyeron en la salida y facilita la reproducción por otros investigadores. En investigaciones complejas, la documentación del código y de las versiones utilizadas adquiere especial importancia, porque pequeños cambios técnicos pueden modificar los resultados y afectar la comparabilidad entre estudios (Burrows, 2023).

La validación de simulaciones debe considerar tanto la correspondencia con datos empíricos como la coherencia interna del modelo. Comparar únicamente la salida final puede ocultar compensaciones entre parámetros que producen resultados similares por razones diferentes. Una evaluación rigurosa examina si el modelo reproduce patrones relevantes en varios niveles y si mantiene su desempeño bajo condiciones no utilizadas durante el ajuste. También debe analizarse qué ocurre cuando el modelo falla, porque las discrepancias pueden revelar limitaciones estructurales o variables omitidas que requieren revisión (Kiyasseh et al., 2024).

La evidencia simulada puede adquirir especial valor cuando se integra con observaciones, experimentos y otras fuentes independientes. La convergencia entre resultados simulados y empíricos permite evaluar si el modelo captura relaciones relevantes del fenómeno. Sin embargo, la coincidencia debe interpretarse con cautela si ambas fuentes comparten los mismos datos o supuestos de construcción. La triangulación resulta más informativa cuando las evidencias proceden de rutas metodológicas distintas. Esta combinación ayuda a fortalecer

explicaciones y a delimitar con mayor precisión las condiciones bajo las cuales una simulación puede utilizarse para sostener una inferencia científica (Arias Valencia, 2022).

Las simulaciones constituyen una fuente de evidencia útil cuando se emplean como instrumentos contrastables y no como sustitutos de la observación empírica. Su principal aporte consiste en explorar mecanismos, escenarios y consecuencias dentro de estructuras explícitas que pueden revisarse y modificarse. La confianza en sus resultados depende de la calidad de los datos, la transparencia de los supuestos, la validación externa y la estabilidad frente a configuraciones alternativas. Bajo estas condiciones, la simulación permite ampliar la capacidad inferencial de la ciencia sin ocultar que sus conclusiones permanecen condicionadas por el modelo que las produce (Nilsson et al., 2022).

6.5 Validación de resultados producidos por sistemas automatizados

La validación de resultados producidos por sistemas automatizados exige comprobar que las salidas generadas mantengan una relación justificable con los datos, criterios y objetivos para los que fueron diseñados. Un sistema puede ofrecer resultados consistentes sin que ello garantice su corrección científica. La evaluación debe considerar precisión, estabilidad, sensibilidad y pertinencia, además de revisar si el procedimiento responde adecuadamente al contexto de aplicación. Cuando no existe una referencia directa o ground truth, la validación requiere combinar diferentes criterios y fuentes para estimar hasta qué punto el resultado automatizado puede considerarse confiable (Kiyasseh et al., 2024).

La separación entre datos de entrenamiento, validación y prueba constituye un requisito básico para evaluar sistemas automatizados. Si la información utilizada para medir el desempeño influyó previamente en la construcción del modelo, las estimaciones pueden resultar artificialmente elevadas. Este problema, conocido como fuga de datos, distorsiona la evaluación y puede generar una apariencia de eficacia que desaparece al utilizar información realmente independiente. La validación debe garantizar que cada etapa cumpla una función diferenciada y que las decisiones adoptadas durante el desarrollo no contaminen los conjuntos destinados a comprobar la capacidad de generalización del sistema (Kapoor & Narayanan, 2023).

La validación también debe examinar la estabilidad del sistema frente a cambios razonables en los datos o en las condiciones de uso. Un modelo que produce resultados muy diferentes ante pequeñas modificaciones puede ofrecer baja confiabilidad, aunque alcance un rendimiento elevado en un conjunto específico. Las pruebas de sensibilidad permiten identificar qué

variables o configuraciones influyen de manera más intensa en las salidas. Esta información ayuda a distinguir entre comportamientos robustos y resultados dependientes de condiciones particulares, lo que resulta esencial cuando el sistema automatizado se utiliza para apoyar inferencias científicas o decisiones que requieren evidencia estable (Fajardo-Fontiveros et al., 2023).

La evaluación de sistemas automatizados no debe limitarse a una única métrica. Precisión, sensibilidad, especificidad, error de predicción y otras medidas captan aspectos distintos del desempeño y pueden producir valoraciones diferentes del mismo modelo. La selección de indicadores debe responder al objetivo científico y a las consecuencias de los posibles errores. Cuando los resultados automatizados se utilizan como evidencia, resulta necesario identificar qué tipo de fallo tiene mayor relevancia para la interpretación. Una validación adecuada combina indicadores complementarios y evita concluir que el sistema es confiable únicamente porque alcanza un valor elevado en una medida aislada (Kiyasseh et al., 2024).

La trazabilidad constituye otra condición necesaria para validar resultados automatizados. Debe ser posible reconstruir qué datos recibió el sistema, qué transformaciones aplicó y qué parámetros influyeron en la salida final. Esta transparencia permite identificar errores, comparar configuraciones y evaluar si el resultado depende de decisiones técnicas específicas. En modelos complejos, la ausencia de documentación dificulta distinguir entre un patrón científicamente relevante y una consecuencia accidental del procesamiento. La reproducibilidad del flujo analítico mejora la capacidad de auditar el sistema y facilita que otros investigadores evalúen independientemente la solidez de sus resultados (Burrows, 2023).

Tabla 17
Criterios para validar resultados producidos por sistemas automatizados

Criterio	Aspecto evaluado	Procedimiento de comprobación	Riesgo principal
Independencia de datos	Separación entre desarrollo y prueba	Conjuntos diferenciados	Fuga de información
Robustez	Estabilidad ante cambios	Análisis de sensibilidad	Resultados frágiles
Desempeño	Calidad de las salidas	Métricas complementarias	Dependencia de un solo indicador
Trazabilidad	Reconstrucción del proceso	Registro de datos y parámetros	Opacidad analítica
Generalización	Rendimiento en nuevos contextos	Validación externa	Sobreajuste

Criterio	Aspecto evaluado	Procedimiento de comprobación	Riesgo principal
Referencia	Criterio de comparación	Ground truth o criterios alternativos	Validación circular

Nota. La validación debe integrar independencia de los datos, estabilidad, trazabilidad y capacidad de generalización, especialmente cuando no existe una referencia definitiva para evaluar las salidas.

La validación externa permite comprobar si un sistema mantiene su desempeño cuando se aplica a datos, poblaciones o contextos distintos de aquellos utilizados durante su desarrollo. Esta prueba resulta esencial para valorar la generalización, ya que un modelo puede funcionar correctamente en condiciones internas y perder precisión al enfrentarse a escenarios nuevos. Las diferencias en distribución de datos, instrumentos o características poblacionales pueden modificar de forma importante sus resultados. La evidencia producida por un sistema automatizado adquiere mayor solidez cuando su rendimiento se mantiene bajo condiciones independientes y suficientemente diversas (Kiyasseh et al., 2024).

Los sistemas automatizados también deben evaluarse frente a posibles sesgos derivados de los datos o del diseño del modelo. Si ciertos grupos, condiciones o patrones están insuficientemente representados, el sistema puede producir resultados sistemáticamente menos fiables para esos casos. La validación debe examinar si el desempeño permanece estable entre subgrupos relevantes y si existen diferencias que modifiquen la interpretación de la evidencia. Esta evaluación permite evitar que una medida promedio o global oculte errores concentrados en segmentos específicos y contribuye a delimitar con mayor precisión el ámbito en el que el sistema puede utilizarse con confianza (Hansen & Quinon, 2023).

La comparación con procedimientos alternativos puede fortalecer la validación cuando no existe un criterio único de verdad. Resultados obtenidos por expertos, modelos independientes o métodos distintos pueden utilizarse para examinar la convergencia entre evidencias. Sin embargo, estas comparaciones deben considerar la independencia entre los procedimientos, porque varios sistemas pueden reproducir una misma limitación si utilizan datos o supuestos semejantes. La convergencia adquiere mayor valor cuando procede de fuentes metodológicamente diversas y cuando las discrepancias se analizan explícitamente en lugar de eliminarse para producir una apariencia artificial de acuerdo (Arias Valencia, 2022).

La validación de resultados automatizados debe entenderse como un proceso continuo y no como una comprobación única realizada al finalizar el desarrollo. Cambios en los datos, el entorno o las condiciones de aplicación pueden modificar el rendimiento con el tiempo. Por ello, los sistemas utilizados para producir evidencia requieren reevaluación periódica,


documentación de cambios y controles que permitan detectar degradaciones o desviaciones. La confianza en sus resultados depende de mantener mecanismos de revisión capaces de comprobar que el desempeño observado continúa siendo compatible con los criterios científicos bajo los cuales fue inicialmente validado (Kiyasseh et al., 2024).

Capítulo 7.



Decisión científica en contextos de incertidumbre

Franklin Patricio Vásquez Chicaiza



7.1 Toma de decisiones basada en evidencia incompleta

La toma de decisiones basada en evidencia incompleta ocurre cuando es necesario actuar sin disponer de información suficiente para eliminar todas las dudas relevantes. Esta situación es frecuente en investigación científica, porque los datos pueden ser parciales, las estimaciones presentar amplios márgenes de incertidumbre o las consecuencias futuras depender de condiciones todavía desconocidas. Decidir bajo estas circunstancias exige diferenciar entre falta total de fundamento y evidencia limitada pero útil. La decisión debe apoyarse en la mejor información disponible, explicitar sus restricciones y reconocer que nuevas observaciones pueden modificar la valoración inicial (Botta et al., 2023).

La evidencia incompleta puede afectar la precisión con que se estiman beneficios, riesgos o resultados posibles. Cuando las muestras son pequeñas o los datos presentan alta variabilidad, las conclusiones pueden cambiar de manera considerable al incorporarse nueva información. En estos casos, resulta necesario valorar cuánto depende la decisión de estimaciones todavía inestables. Analizar la evidencia adicional que sería necesaria para modificar sustancialmente una conclusión permite establecer si la decisión puede adoptarse con el respaldo actual o si conviene mantenerla abierta a revisión hasta disponer de información más sólida (Sondhi et al., 2021).

Tomar decisiones bajo incertidumbre también requiere identificar qué aspectos del problema están suficientemente establecidos y cuáles permanecen abiertos. La ausencia de certeza no implica que todas las alternativas tengan el mismo respaldo. Algunas opciones pueden estar mejor justificadas por la evidencia existente, aunque ninguna cuente con garantía absoluta. La evaluación debe considerar la calidad de los datos, la solidez de los procedimientos y la existencia de explicaciones alternativas. Esta diferenciación permite evitar decisiones basadas únicamente en intuiciones y mantiene una relación proporcional entre el nivel de conocimiento disponible y la fuerza de la elección realizada (Gough, 2021).

La probabilidad ofrece herramientas para organizar decisiones cuando existen varios resultados posibles. Los métodos probabilísticos permiten estimar qué escenarios reciben mayor respaldo y actualizar esas valoraciones cuando aparece nueva evidencia. Este enfoque resulta útil porque sustituye decisiones dicotómicas prematuras por comparaciones entre grados de plausibilidad. Sin embargo, la utilidad de la probabilidad depende de los supuestos del modelo y de la calidad de los datos utilizados. Una estimación numérica no elimina la incertidumbre, sino que la

representa dentro de una estructura que debe ser interpretada críticamente antes de orientar una decisión científica (Wei et al., 2022).

La toma de decisiones también debe considerar las consecuencias potenciales de actuar o de posponer una acción. En algunos contextos, esperar evidencia completa puede resultar imposible o generar costos relevantes, mientras que actuar con información insuficiente puede producir efectos difíciles de corregir. Por ello, la decisión exige comparar los riesgos asociados con cada alternativa y establecer qué nivel de evidencia resulta razonable según la gravedad de las consecuencias. Esta evaluación convierte la incertidumbre en un componente explícito del análisis y evita tratar la ausencia de conocimiento completo como una razón automática para actuar o abstenerse (Aven, 2023).

La responsabilidad adquiere especial importancia cuando una decisión científica afecta a sistemas complejos y sus consecuencias no pueden anticiparse por completo. En estas condiciones, identificar qué decisiones tienen mayor influencia sobre los resultados ayuda a concentrar la atención en los puntos donde la incertidumbre puede producir efectos más relevantes. La evaluación debe considerar tanto la información disponible como la capacidad de revisar la decisión si cambian las condiciones. Esta perspectiva favorece opciones adaptables y reduce la dependencia de predicciones excesivamente precisas en situaciones donde el conocimiento sigue siendo parcial (Botta et al., 2023).

La transparencia en la comunicación de incertidumbre es necesaria para que una decisión pueda ser evaluada por otros. Deben explicitarse los datos utilizados, los supuestos asumidos y las razones que justifican preferir una alternativa frente a otra. Cuando estas condiciones permanecen ocultas, resulta difícil determinar si la decisión responde realmente a la evidencia o a preferencias no declaradas. La transparencia permite además identificar qué nueva información podría modificar la elección y facilita revisar el proceso cuando aparecen resultados inesperados. Una decisión científicamente defendible debe ser comprensible, trazable y susceptible de actualización (Metzen, 2024).

La evidencia incompleta puede complementarse mediante diferentes fuentes cuando ninguna resulta suficiente por separado. La triangulación de datos, métodos y perspectivas permite evaluar si distintas líneas de evidencia convergen hacia una misma recomendación o revelan discrepancias importantes. Esta estrategia no elimina la incertidumbre, pero puede reducir la dependencia de una única fuente. La convergencia adquiere mayor valor cuando las evidencias son independientes y sus limitaciones no se repiten de forma sistemática. En decisiones

complejas, combinar información diversa ayuda a construir una base más robusta sin ocultar las diferencias existentes entre los resultados (Arias Valencia, 2022).

La comunicación de la incertidumbre influye también en la forma en que se interpretan las decisiones. Presentar una elección como definitiva cuando depende de evidencia limitada puede generar una falsa sensación de seguridad. Por el contrario, enfatizar únicamente las dudas puede dificultar decisiones razonables aun cuando exista respaldo suficiente. La formulación debe reflejar el grado real de confianza y explicar qué factores podrían modificar la conclusión. Esta correspondencia entre evidencia, incertidumbre y lenguaje facilita que los usuarios comprendan tanto la base de la decisión como sus límites (Wiedemann et al., 2021).

La revisión periódica constituye una condición importante cuando las decisiones se adoptan con información incompleta. A medida que aparecen nuevos datos, pueden cambiar las probabilidades, los riesgos o la valoración de las alternativas. Un proceso rígido puede mantener decisiones que dejaron de ser coherentes con la evidencia disponible. Por ello, conviene establecer criterios que indiquen cuándo revisar una conclusión y qué tipo de información tendría suficiente peso para modificarla. Esta lógica convierte la decisión en un proceso dinámico y permite ajustar la acción a la evolución del conocimiento científico (Botta et al., 2023).

La toma de decisiones basada en evidencia incompleta exige combinar prudencia, justificación y capacidad de revisión. No se trata de esperar una certeza que muchas veces no llegará, sino de determinar qué opción cuenta con mejor respaldo dentro de las condiciones actuales. La decisión debe reconocer incertidumbres, comparar consecuencias, considerar alternativas y mantenerse abierta a cambios cuando nueva evidencia lo justifique. Este enfoque permite actuar de manera razonada sin presentar el conocimiento como más sólido de lo que realmente es y mantiene una relación coherente entre evidencia disponible, responsabilidad y decisión científica (Botta et al., 2023).

7.2 Comunicación científica de riesgos e incertidumbres

La comunicación científica de riesgos e incertidumbres exige presentar de forma comprensible tanto los resultados disponibles como los límites que afectan su interpretación. Comunicar un riesgo no consiste únicamente en informar una probabilidad, porque también debe explicarse qué evidencia sustenta la estimación, qué condiciones podrían modificarla y qué aspectos permanecen inciertos. Cuando estas dimensiones se omiten, el receptor puede interpretar una estimación como una predicción exacta. La comunicación debe mantener una correspondencia

clara entre el grado de respaldo científico y la fuerza con que se presenta la conclusión, evitando generar una certeza mayor que la permitida por los datos (Wiedemann et al., 2021).

La forma en que se expresa la incertidumbre puede influir en la percepción del riesgo y en la confianza otorgada a la información científica. Mensajes que explicitan limitaciones de manera clara pueden facilitar una interpretación más precisa, mientras que formulaciones ambiguas o excesivamente técnicas pueden generar confusión. Comunicar incertidumbre no implica simplemente añadir advertencias, sino proporcionar información que permita comprender por qué existe y cómo afecta la conclusión. La confianza depende en parte de que el lenguaje utilizado sea coherente con la evidencia y permita distinguir entre resultados relativamente estables y estimaciones todavía sujetas a cambios relevantes (Schneider et al., 2022).

Las expresiones verbales utilizadas para comunicar riesgo requieren especial cuidado porque términos como probable, posible o improbable pueden interpretarse de manera distinta según el lector. Su uso resulta más adecuado cuando se acompaña de suficiente contexto sobre el significado asignado y las condiciones de la estimación. La cautela lingüística debe responder al nivel real de evidencia y no convertirse en una fórmula automática. Una afirmación demasiado categórica puede ocultar incertidumbre, mientras que una expresión excesivamente prudente puede debilitar injustificadamente conclusiones que cuentan con respaldo suficiente (Ward & Creel, 2024).

La comunicación numérica también puede generar problemas cuando porcentajes, probabilidades o intervalos se presentan sin explicar su significado. Una cifra precisa puede transmitir una sensación de exactitud que excede la capacidad del modelo o de los datos utilizados para producirla. Por esta razón, las estimaciones deben acompañarse de información sobre su rango de incertidumbre, sus supuestos y el contexto al que corresponden. La representación del riesgo debe facilitar que el receptor comprenda no solo el valor estimado, sino también cuánto puede variar y qué factores condicionan esa variación (Cox & O'Hagan, 2022).

La comunicación del riesgo adquiere mayor relevancia cuando la información debe orientar decisiones bajo consecuencias potencialmente graves. En estos casos, no basta con transmitir qué escenario parece más probable; también deben considerarse eventos menos probables pero con consecuencias significativas. La evaluación científica del riesgo integra probabilidad, gravedad e incertidumbre, por lo que la comunicación debe reflejar estas dimensiones sin reducirlas a una única cifra. Esta presentación permite diferenciar entre situaciones con alta

probabilidad y bajo impacto y aquellas donde existe mayor incertidumbre, pero las consecuencias justifican una atención especial (Aven, 2023).

Tabla 18
Criterios para comunicar riesgos e incertidumbres científicas

Criterio	Función comunicativa	Aplicación recomendable	Riesgo si se omite
Claridad	Facilitar la comprensión	Lenguaje preciso y accesible	Interpretaciones ambiguas
Proporcionalidad	Ajustar la fuerza del mensaje	Relacionar afirmación y evidencia	Exceso de certeza
Contextualización	Explicar el alcance del riesgo	Indicar población, escenario y condiciones	Generalización indebida
Cuantificación	Mostrar magnitud e incertidumbre	Probabilidades, intervalos o rangos	Falsa precisión
Transparencia	Hacer visibles limitaciones	Explicitar supuestos y fuentes de incertidumbre	Confianza injustificada
Comparación	Facilitar interpretación relativa	Contrastar escenarios relevantes	Percepción aislada del riesgo

Nota. Los criterios permiten comunicar tanto la magnitud del riesgo como las condiciones que limitan su estimación, evitando reducir la incertidumbre a una advertencia secundaria.

La transparencia fortalece la comunicación cuando permite conocer cómo se produjo una estimación de riesgo. Explicar la fuente de los datos, el método utilizado y las principales limitaciones ayuda a distinguir entre incertidumbre derivada de falta de información y aquella relacionada con la variabilidad propia del fenómeno. Esta diferenciación facilita una evaluación más razonada y evita que todas las dudas sean interpretadas del mismo modo. La confianza científica se construye mejor cuando el receptor puede identificar qué aspectos están bien respaldados y cuáles podrían cambiar con nueva evidencia (Metzen, 2024).

La comunicación también debe evitar presentar desacuerdos científicos como simples oposiciones entre posiciones equivalentes. Cuando existen resultados diferentes, es necesario explicar qué evidencia respalda cada interpretación y qué condiciones pueden haber producido la discrepancia. Esta contextualización permite comprender que la existencia de controversia no implica ausencia total de conocimiento. Algunos aspectos pueden estar bien establecidos mientras otros continúan abiertos. Mostrar esta estructura ayuda a evitar tanto la exageración del consenso como la sobrerrepresentación de desacuerdos minoritarios o metodológicamente débiles (Omerovic, 2023).

Los formatos visuales pueden facilitar la comprensión de riesgos cuando permiten mostrar simultáneamente estimaciones centrales, rangos y escenarios posibles. Sin embargo, una

representación gráfica puede inducir errores si oculta la variabilidad o utiliza escalas que exageran diferencias pequeñas. La selección del formato debe responder al tipo de incertidumbre y al nivel de conocimiento del público. La comunicación efectiva requiere que la visualización preserve la estructura de la evidencia y permita distinguir entre valor esperado, rango plausible y escenarios menos frecuentes, evitando convertir una representación simplificada en una falsa imagen de exactitud (Schneider et al., 2022).

La comunicación científica de riesgos e incertidumbres debe permitir tomar decisiones informadas sin transformar la complejidad en mensajes engañosamente simples. Esto exige combinar claridad, precisión y transparencia, mostrando qué se conoce, qué permanece incierto y qué consecuencias podrían derivarse de cada escenario. La incertidumbre debe presentarse como parte del contenido científico y no como una nota secundaria añadida al final. Una comunicación adecuada facilita evaluar la fuerza de la evidencia y comprender por qué una recomendación puede ser razonable incluso cuando el conocimiento disponible no permite eliminar todas las dudas (Wiedemann et al., 2021).

7.3 Precaución ante consecuencias científicamente inciertas

La precaución ante consecuencias científicamente inciertas resulta necesaria cuando una decisión puede producir daños relevantes y la evidencia disponible no permite estimar con precisión su probabilidad o magnitud. En estos escenarios, la ausencia de certeza no elimina la posibilidad de riesgo, pero tampoco justifica cualquier restricción. La evaluación debe considerar la gravedad potencial de las consecuencias, la calidad de la evidencia, el nivel de incertidumbre y la reversibilidad de las decisiones. El criterio precautorio adquiere sentido cuando existe una base razonable para anticipar daños y cuando esperar información completa podría aumentar la exposición a consecuencias difíciles de corregir (Aven, 2023).

La precaución no debe confundirse con una política de evitar toda acción ante cualquier incertidumbre. Si se aplicara de forma absoluta, podría bloquear decisiones necesarias incluso cuando la evidencia favorece claramente una alternativa. Su uso requiere proporcionalidad entre el grado de incertidumbre y la magnitud del posible daño. Esto implica diferenciar riesgos especulativos de escenarios respaldados por evidencia suficiente para justificar medidas preventivas. La decisión precautoria debe mostrar por qué determinadas consecuencias merecen atención especial y qué información sostiene esa valoración, evitando convertir la incertidumbre en un argumento genérico para prohibir o retrasar cualquier intervención (Aven, 2023).

La gravedad de las consecuencias constituye un criterio central porque dos escenarios con incertidumbre similar pueden requerir respuestas distintas si sus efectos potenciales no son equivalentes. Una consecuencia limitada y fácilmente reversible no demanda el mismo nivel de precaución que un daño amplio, irreversible o acumulativo. La evaluación debe incorporar tanto la probabilidad estimada como la severidad posible, sin reducir la decisión a uno de estos componentes. Este enfoque permite justificar medidas proporcionales y evita que una probabilidad baja se interprete automáticamente como irrelevante cuando las consecuencias podrían ser particularmente graves (Botta et al., 2023).

La reversibilidad de una decisión también influye en la aplicación de la precaución. Cuando una medida puede corregirse con facilidad, resulta posible aceptar mayores niveles de incertidumbre y revisar posteriormente la estrategia. En cambio, decisiones con efectos irreversibles requieren mayor cuidado porque una nueva evidencia puede llegar demasiado tarde para modificar sus consecuencias. Esta diferencia obliga a considerar no solo qué se sabe en el momento presente, sino también qué margen existe para ajustar la decisión después de observar sus resultados. La flexibilidad y la capacidad de revisión reducen parte del riesgo asociado con actuar bajo información incompleta (Botta et al., 2023).

La precaución también debe considerar el costo de no actuar. Una decisión aparentemente conservadora puede producir consecuencias negativas si retrasa intervenciones necesarias o mantiene una situación de riesgo. Por ello, el análisis debe comparar los posibles daños derivados de actuar con los que podrían resultar de la inacción. Este equilibrio evita interpretar la precaución como simple abstención y permite reconocer que, en ciertos contextos, una respuesta temprana puede ser la opción más prudente. La evaluación debe hacer visibles ambas clases de consecuencias y explicar qué incertidumbres afectan cada alternativa (Aven, 2023).

La calidad de la evidencia disponible condiciona el grado de precaución justificable. Resultados preliminares, muestras pequeñas o estimaciones altamente sensibles ofrecen una base distinta de aquella proporcionada por múltiples estudios convergentes. Cuando la evidencia es débil, puede ser razonable adoptar medidas reversibles y mantener una revisión continua en lugar de establecer decisiones definitivas. La incertidumbre debe incorporarse explícitamente en la valoración para evitar que una señal inicial sea tratada como prueba concluyente. Esta proporcionalidad permite responder a riesgos plausibles sin otorgar a la evidencia más fuerza de la que realmente posee (Sondhi et al., 2021).

La comunicación resulta esencial cuando las decisiones precautorias afectan a terceros. Debe explicarse por qué se considera necesario actuar, qué consecuencias se pretenden evitar y qué incertidumbres permanecen abiertas. Una comunicación excesivamente categórica puede presentar la medida como si respondiera a hechos completamente establecidos, mientras que un mensaje demasiado ambiguo puede dificultar la comprensión de la razón preventiva. La transparencia permite distinguir entre evidencia suficiente para justificar una precaución y evidencia insuficiente para formular una predicción definitiva, manteniendo una relación coherente entre conocimiento disponible y decisión adoptada (Wiedemann et al., 2021).

La precaución también requiere criterios explícitos para revisar las medidas cuando cambia la evidencia. Una decisión tomada bajo incertidumbre no debería mantenerse indefinidamente si nuevos datos modifican la estimación del riesgo. Establecer de antemano qué información podría fortalecer, reducir o eliminar la necesidad de la medida contribuye a evitar decisiones rígidas. Este enfoque convierte la precaución en un proceso adaptativo y permite actualizar la respuesta conforme se acumula conocimiento. La revisión continua también facilita distinguir entre riesgos persistentes y preocupaciones que pierden fundamento a medida que mejora la evidencia disponible (Botta et al., 2023).

En sistemas complejos, la precaución adquiere mayor importancia porque las consecuencias pueden depender de interacciones difíciles de anticipar. Pequeños cambios pueden producir efectos amplificados o aparecer consecuencias emergentes que no eran visibles en el análisis inicial. En estas condiciones, una predicción precisa puede ser imposible, pero todavía es posible identificar escenarios plausibles y evaluar qué decisiones reducen la exposición a daños importantes. La incertidumbre estructural no impide razonar sobre el riesgo, aunque obliga a formular recomendaciones más condicionadas y a mantener mecanismos de seguimiento capaces de detectar desviaciones tempranas (Fajardo-Fontiveros et al., 2023).

La responsabilidad científica exige que la precaución se base en razones verificables y no únicamente en percepciones de temor. Los criterios utilizados deben poder examinarse, compararse con alternativas y relacionarse con la evidencia disponible. Esto permite distinguir entre una decisión preventiva justificable y una respuesta desproporcionada ante escenarios poco plausibles. La transparencia sobre los supuestos, la gravedad potencial y los límites de la evidencia facilita que otros investigadores evalúen la razonabilidad de la medida. La precaución adquiere legitimidad cuando su fundamento puede someterse a revisión y no depende exclusivamente de una autoridad que afirma conocer el riesgo (Metzen, 2024).

Figura 7
Criteria for applying precaution before scientifically uncertain consequences



Nota. El esquema integra los factores que orientan decisiones precautorias proporcionales, revisables y sustentadas en la evidencia disponible.

La precaución ante consecuencias científicamente inciertas debe funcionar como un criterio de decisión proporcional, revisable y sustentado en evidencia. Su finalidad no es eliminar toda incertidumbre antes de actuar, sino gestionar situaciones donde los posibles daños justifican una respuesta aun cuando el conocimiento permanezca incompleto. La evaluación debe integrar gravedad, probabilidad, reversibilidad, costo de la inacción y calidad de la evidencia disponible. Cuando estos elementos se explicitan, la precaución permite actuar sin convertir la incertidumbre en certeza y sin utilizarla como argumento automático para paralizar decisiones razonables (Aven, 2023).

7.4 Responsabilidad en la interpretación y aplicación de evidencia

La responsabilidad en la interpretación de evidencia exige mantener una correspondencia precisa entre los datos disponibles y las conclusiones que se formulan a partir de ellos. Interpretar responsablemente implica reconocer qué aspectos están suficientemente respaldados, cuáles dependen de supuestos y qué incertidumbres podrían modificar el resultado. Una conclusión que amplía injustificadamente el alcance de la evidencia puede conducir a decisiones incorrectas incluso cuando los datos originales sean válidos. Por ello, la responsabilidad científica comienza en la delimitación de las afirmaciones y requiere evitar que asociaciones, estimaciones preliminares o resultados condicionados sean presentados como explicaciones generales o certezas definitivas (Gough, 2021).

La aplicación de evidencia añade una dimensión contextual a esta responsabilidad. Un hallazgo obtenido en una población, entorno o periodo determinado no puede trasladarse automáticamente a condiciones diferentes. La pertinencia debe evaluarse según la similitud entre el contexto original y aquel donde se pretende utilizar el conocimiento. También deben considerarse variaciones en características de los participantes, procedimientos y recursos disponibles. Una fuente metodológicamente sólida puede ofrecer un respaldo limitado cuando se utiliza fuera de su ámbito original. Aplicar evidencia de manera responsable exige, por tanto, examinar tanto su calidad interna como su correspondencia con la situación concreta (Rickinson et al., 2021).

La responsabilidad aumenta cuando las decisiones dependen de evidencia incierta y pueden generar consecuencias importantes. En estas circunstancias, quien interpreta los resultados debe explicitar qué información sostiene la decisión, qué escenarios permanecen abiertos y qué efectos podrían derivarse de una estimación incorrecta. No todas las decisiones poseen el mismo peso ni la misma capacidad de reversión. Identificar aquellas con mayor influencia sobre los resultados permite concentrar la evaluación en los puntos donde el error o la incertidumbre podrían tener consecuencias más relevantes. Esta perspectiva vincula interpretación científica, decisión y responsabilidad por los efectos previsibles de la aplicación (Botta et al., 2023).

La transparencia constituye una condición básica de responsabilidad porque permite que otras personas examinen cómo se llegó a una conclusión. Deben ser visibles los criterios utilizados para seleccionar evidencia, los supuestos adoptados y las limitaciones consideradas durante el análisis. Esta apertura facilita distinguir entre una interpretación sustentada y una preferencia

presentada como resultado científico. También permite revisar decisiones cuando aparece nueva evidencia. La confianza no depende de ocultar las incertidumbres, sino de ofrecer razones suficientemente claras para comprender qué sostiene una conclusión y bajo qué circunstancias debería modificarse (Metzen, 2024).

La comunicación responsable requiere ajustar el lenguaje al nivel real de respaldo. Expresiones categóricas pueden inducir decisiones desproporcionadas cuando la evidencia es preliminar o presenta alta incertidumbre, mientras que una cautela excesiva puede ocultar resultados suficientemente consistentes. La formulación debe indicar si una conclusión describe una asociación, propone una explicación o sustenta una recomendación, porque estos niveles exigen diferentes grados de evidencia. También debe evitarse que términos probabilísticos o expresiones de posibilidad sean interpretados como garantías. Mantener esta proporcionalidad entre evidencia y lenguaje forma parte de la responsabilidad asociada con la interpretación científica (Ward & Creel, 2024).

Tabla 19
Criterios de responsabilidad en la interpretación y aplicación de evidencia

Criterio	Exigencia principal	Aplicación práctica	Riesgo si se incumple
Proporcionalidad	Ajustar conclusión y evidencia	Delimitar la fuerza de las afirmaciones	Sobreinterpretación
Pertinencia	Considerar el contexto	Evaluar población y condiciones de aplicación	Generalización indebida
Transparencia	Explicitar decisiones y supuestos	Documentar criterios de interpretación	Opacidad
Incertidumbre	Reconocer límites	Comunicar rangos y alternativas	Falsa certeza
Consecuencias	Valorar efectos posibles	Comparar impactos de las decisiones	Aplicación irresponsable
Revisabilidad	Admitir actualización	Establecer criterios de revisión	Persistencia de decisiones obsoletas

Nota. Los criterios vinculan la calidad de la interpretación con las condiciones de aplicación y con la posibilidad de revisar decisiones cuando cambia la evidencia disponible.

La responsabilidad también implica examinar explicaciones alternativas antes de aplicar una conclusión. Un resultado compatible con una determinada hipótesis puede admitir mecanismos diferentes, especialmente cuando la evidencia es indirecta o incompleta. Ignorar estas alternativas puede transformar una interpretación plausible en una decisión excesivamente segura. La evaluación debe identificar qué pasos inferenciales conectan los datos con la recomendación y determinar dónde permanecen dudas relevantes. Cuanto mayor sea la distancia entre observación y aplicación, mayor será la necesidad de justificar los supuestos

intermedios y de mantener abiertas explicaciones que todavía no han podido descartarse (Woensdregt et al., 2024).

Los resultados contradictorios plantean una responsabilidad adicional porque obligan a evitar la selección conveniente de estudios. Cuando existen hallazgos divergentes, la interpretación debe considerar las diferencias de diseño, población, contexto y precisión antes de decidir qué evidencia recibe mayor peso. Elegir únicamente resultados compatibles con una posición previa puede distorsionar el cuerpo de conocimiento disponible. La responsabilidad exige mantener visibles las discrepancias y explicar por qué determinadas fuentes resultan más pertinentes o sólidas. De este modo, la controversia se integra en la evaluación en lugar de ser eliminada mediante una selección parcial de resultados (Omerovic, 2023).

La aplicación de evidencia producida por sistemas automatizados exige controles adicionales. Las recomendaciones o predicciones de un modelo pueden depender de datos sesgados, condiciones particulares de entrenamiento o criterios de validación insuficientes. Utilizar estos resultados sin examinar su desempeño fuera del conjunto original puede trasladar errores técnicos hacia decisiones concretas. La responsabilidad requiere comprobar la generalización, analizar posibles diferencias entre grupos y mantener trazabilidad sobre las condiciones que originaron la salida. Un resultado automatizado debe ser evaluado según su evidencia y sus límites, no aceptado únicamente por haber sido producido mediante un procedimiento tecnológicamente sofisticado (Kiyasseh et al., 2024).

La responsabilidad científica continúa después de que una evidencia ha sido aplicada. Cuando aparecen nuevos datos, contradicciones o señales de efectos no previstos, las decisiones deben poder revisarse. Esta revisabilidad resulta especialmente importante en contextos de incertidumbre, donde ninguna conclusión puede considerarse completamente independiente de información futura. Establecer mecanismos de seguimiento permite identificar cuándo una recomendación dejó de estar respaldada o necesita modificarse. La aplicación responsable de evidencia combina así justificación inicial, transparencia sobre sus límites y disposición para corregir decisiones cuando el desarrollo del conocimiento altera las razones que originalmente las sustentaban (Botta et al., 2023).

7.5 Nuevos criterios para gestionar la incertidumbre científica

La gestión contemporánea de la incertidumbre científica requiere criterios capaces de integrar evidencia incompleta, diversidad de expertos, variabilidad de escenarios y decisiones sujetas a revisión. Frente a problemas complejos, no siempre resulta suficiente utilizar una única

estimación o depender de una sola interpretación. Los procedimientos deben permitir identificar distintas fuentes de incertidumbre, hacer explícitos los supuestos y comparar alternativas antes de formular una conclusión. Esta gestión adquiere mayor solidez cuando las decisiones pueden rastrearse y cuando el proceso distingue entre incertidumbre derivada de los datos, del modelo y del juicio utilizado para interpretarlos (Selva et al., 2024).

La participación de múltiples expertos constituye uno de los criterios utilizados para gestionar incertidumbres que no pueden resolverse únicamente mediante datos empíricos. La integración estructurada de juicios permite incorporar conocimientos especializados procedentes de distintas perspectivas y reducir la dependencia de una única valoración. Sin embargo, reunir opiniones no garantiza automáticamente una mejor decisión. Es necesario definir procedimientos para documentar los juicios, comparar discrepancias y establecer cómo se combinan las estimaciones. Los protocolos multiexperto resultan más útiles cuando conservan la trazabilidad de las valoraciones individuales y permiten identificar dónde existe convergencia o desacuerdo significativo (Selva et al., 2024).

Otro criterio relevante consiste en diferenciar las fuentes de incertidumbre antes de intentar reducirlas. Algunas pueden disminuir mediante nuevos datos, mientras que otras dependen de supuestos modelísticos, interpretaciones alternativas o características estructurales del fenómeno. Tratar todas las incertidumbres como si tuvieran el mismo origen puede conducir a estrategias ineficaces. La gestión debe identificar cuáles son reducibles mediante investigación adicional y cuáles requieren procedimientos para trabajar con conocimiento inevitablemente incompleto. Esta distinción permite asignar recursos de manera más coherente y evita asumir que aumentar la cantidad de información resolverá necesariamente todas las limitaciones existentes (Schnarr & Mertz, 2022).

La robustez de las decisiones constituye otro criterio para gestionar incertidumbre. Una decisión resulta más robusta cuando conserva resultados aceptables bajo diferentes supuestos o escenarios plausibles, en lugar de depender de una única predicción considerada exacta. Esta perspectiva resulta especialmente útil cuando los sistemas son complejos y las estimaciones futuras presentan amplios márgenes de variación. Examinar cómo cambia una decisión frente a condiciones alternativas permite identificar opciones excesivamente sensibles y otras con mayor estabilidad. La gestión de incertidumbre se orienta entonces hacia decisiones capaces de funcionar razonablemente aun cuando algunos supuestos iniciales resulten incorrectos (Botta et al., 2023).

La revisabilidad debe formar parte del diseño de las decisiones científicas. Cuando la evidencia cambia, los criterios utilizados para actuar también deben poder actualizarse. Establecer puntos de revisión, indicadores de seguimiento y condiciones que justifiquen modificar una decisión evita que conclusiones provisionales se conviertan en posiciones rígidas. Esta estrategia resulta especialmente importante cuando las decisiones se adoptan con evidencia incompleta o frente a consecuencias difíciles de predecir. Gestionar incertidumbre implica aceptar que una decisión razonable hoy puede requerir ajustes posteriores si aparecen nuevos datos, cambian las condiciones o se identifican errores en los supuestos iniciales (Aven, 2023).

Tabla 20
Criterios contemporáneos para gestionar la incertidumbre científica

Criterio	Función principal	Aplicación	Resultado esperado
Identificación de fuentes	Distinguir tipos de incertidumbre	Separar datos, modelos y juicios	Diagnóstico más preciso
Evaluación multiexperto	Integrar perspectivas especializadas	Comparar y documentar juicios	Menor dependencia individual
Robustez	Examinar estabilidad	Probar escenarios alternativos	Decisiones menos sensibles
Trazabilidad	Reconstruir el proceso	Registrar supuestos y decisiones	Mayor transparencia
Revisabilidad	Actualizar conclusiones	Definir puntos de revisión	Adaptación a nueva evidencia
Comunicación proporcional	Expresar el grado de respaldo	Ajustar lenguaje y rangos	Menor riesgo de falsa certeza

Nota. Los criterios organizan la gestión de la incertidumbre como un proceso de identificación, comparación, seguimiento y revisión, en lugar de reducirla únicamente a una estimación numérica.

La trazabilidad permite gestionar la incertidumbre al mantener visible el recorrido entre datos, supuestos, modelos y decisiones. Cuando cada etapa puede reconstruirse, resulta posible identificar qué elemento produjo una variación en el resultado y evaluar cómo cambiaría la conclusión bajo otras condiciones. Esta práctica adquiere especial importancia en análisis computacionales y procedimientos con múltiples etapas, donde pequeñas decisiones técnicas pueden acumular efectos significativos. La documentación sistemática facilita además la revisión independiente y reduce la posibilidad de que la incertidumbre quede oculta detrás de procedimientos técnicamente complejos pero difíciles de evaluar (Burrows, 2023).

La gestión también requiere representar la incertidumbre de manera comprensible para quienes utilizarán los resultados. Intervalos, escenarios, probabilidades y expresiones cualitativas pueden ser adecuados según el tipo de problema, pero deben seleccionarse de forma coherente con la información disponible. Una representación excesivamente precisa puede generar

confianza injustificada, mientras que una comunicación vaga puede impedir distinguir entre escenarios con diferente respaldo. El objetivo consiste en mostrar qué resultados son más plausibles, qué variaciones permanecen abiertas y qué condiciones podrían modificar la estimación, manteniendo una correspondencia clara entre incertidumbre y forma de presentación (Cox & O'Hagan, 2022).

Los protocolos de múltiples expertos ofrecen una vía para incorporar incertidumbres epistemológicas y elecciones subjetivas dentro de procedimientos formalizados. Su utilidad aumenta cuando las opiniones se recogen de manera estructurada, las diferencias permanecen visibles y los criterios de agregación están definidos antes de observar el resultado final. Este enfoque permite evitar que una sola valoración domine el análisis y facilita evaluar cómo las divergencias entre especialistas afectan las conclusiones. La combinación de juicios debe mantenerse transparente para que pueda revisarse posteriormente y para que la incertidumbre asociada con las decisiones expertas no sea confundida con una estimación objetiva única (Selva et al., 2024).

Gestionar la incertidumbre científica exige combinar identificación de fuentes, robustez, trazabilidad, evaluación multiexperto, comunicación proporcional y capacidad de revisión. Ningún criterio elimina por sí solo las limitaciones del conocimiento, pero su integración permite tomar decisiones mejor justificadas y mantener visibles las condiciones bajo las cuales podrían cambiar. El objetivo no consiste en producir una apariencia de certeza, sino en organizar la incertidumbre de forma que pueda evaluarse, compararse y actualizarse. Esta perspectiva convierte la gestión de la incertidumbre en una práctica continua vinculada con la calidad de la evidencia y con la responsabilidad de decidir bajo conocimiento incompleto (Selva et al., 2024).

Conclusión

La incertidumbre forma parte del conocimiento científico porque toda investigación trabaja con observaciones delimitadas, instrumentos con márgenes de precisión, modelos construidos sobre supuestos y datos que requieren interpretación. Reconocerla permite establecer con mayor rigor qué puede afirmarse y qué permanece abierto a revisión. La ciencia no necesita eliminar toda duda para producir conocimiento confiable, pero sí debe identificar las condiciones que limitan sus conclusiones y evitar presentar como definitivo aquello que depende de evidencia incompleta, variabilidad no resuelta o explicaciones alternativas todavía plausibles.

La construcción de evidencia exige más que la acumulación de datos. Las observaciones adquieren valor científico cuando se integran en procedimientos que permiten relacionarlas con preguntas, hipótesis y explicaciones. La calidad de esta relación depende de la pertinencia de las fuentes, de la coherencia metodológica y de la transparencia con que se documenten las decisiones adoptadas. Por ello, la evidencia debe evaluarse atendiendo tanto a su origen como a la forma en que se transforma, analiza e interpreta. Una conclusión sólida mantiene visible la trayectoria que conecta los datos con la afirmación que pretende sostener.

La evaluación crítica de la evidencia requiere considerar consistencia, robustez, suficiencia y capacidad para resistir explicaciones alternativas. La convergencia entre estudios puede fortalecer una conclusión, pero las discrepancias también aportan información sobre los límites de generalización, la influencia del contexto o posibles diferencias metodológicas. Los resultados contradictorios no deben ocultarse ni resolverse mediante una selección parcial de estudios. Su análisis permite identificar qué aspectos del fenómeno permanecen estables y cuáles dependen de condiciones específicas, contribuyendo a construir interpretaciones más delimitadas y menos vulnerables a afirmaciones excesivamente amplias.

La inferencia permite avanzar desde la evidencia disponible hacia generalizaciones, contrastaciones y explicaciones, pero cada forma de razonamiento incorpora restricciones particulares. La inducción amplía el alcance de patrones observados, la deducción somete consecuencias derivadas de hipótesis a contrastación y la abducción propone mecanismos capaces de explicar los resultados. Ninguno de estos procedimientos elimina por completo la incertidumbre. Su fuerza depende de la calidad de los datos, de la claridad de los supuestos y de la capacidad de comparar alternativas. La probabilidad contribuye a expresar distintos grados de respaldo sin convertirlos en certeza absoluta.

La reproducibilidad y la replicación aportan mecanismos distintos para evaluar la estabilidad del conocimiento. La primera permite comprobar si un resultado puede reconstruirse a partir de los mismos datos y procedimientos; la segunda examina si el hallazgo se mantiene cuando se produce nueva evidencia. Ambas prácticas fortalecen la confiabilidad cuando están acompañadas de documentación suficiente, transparencia metodológica y condiciones de evaluación independientes. También permiten localizar errores, identificar resultados sensibles a decisiones particulares y distinguir entre patrones robustos y conclusiones que dependen excesivamente de configuraciones específicas.

Los sesgos y distorsiones muestran que la evidencia puede alterarse en diferentes momentos del proceso científico. La selección de casos, la medición, el tratamiento de datos, la elección de modelos y la interpretación pueden introducir desviaciones sistemáticas. En contextos computacionales, estos problemas incluyen además sobreajuste, fuga de datos y validaciones insuficientes. La respuesta no consiste en asumir una ciencia completamente libre de influencias, sino en hacer visibles las fuentes potenciales de distorsión, aplicar controles adecuados y evaluar cómo afectan la fuerza de las conclusiones.

Las nuevas tecnologías amplían las posibilidades de producción y análisis de evidencia, pero también modifican los criterios con que debe evaluarse su confiabilidad. Los datos masivos permiten explorar fenómenos a gran escala, los modelos computacionales facilitan el análisis de sistemas complejos, la inteligencia artificial automatiza procesos de clasificación y síntesis, y las simulaciones permiten estudiar escenarios difíciles de observar directamente. Estas capacidades requieren procedimientos de validación, trazabilidad y revisión que permitan distinguir entre resultados técnicamente sofisticados y evidencia científicamente justificada.

La toma de decisiones bajo incertidumbre exige integrar conocimiento parcial con una evaluación explícita de riesgos, consecuencias y posibilidades de revisión. No siempre es posible esperar evidencia completa, especialmente cuando las decisiones tienen efectos inmediatos o potencialmente graves. En estas situaciones, la precaución debe aplicarse de forma proporcional y considerar tanto los daños de actuar como los de no hacerlo. La comunicación científica tiene un papel decisivo porque debe mostrar con claridad el grado de respaldo, las limitaciones y las condiciones que podrían modificar una recomendación.

Gestionar la incertidumbre científica implica, en conjunto, identificar sus fuentes, representar sus márgenes, comparar alternativas, documentar los procesos y revisar las decisiones cuando cambia la evidencia. La incertidumbre no debe ocultarse ni convertirse en una justificación

automática para debilitar el conocimiento. Su tratamiento adecuado permite diferenciar entre resultados sólidos y conclusiones provisionales, establecer grados razonables de confianza y mantener abierta la corrección de errores. La construcción contemporánea de evidencia depende precisamente de esa capacidad para sostener afirmaciones justificadas sin perder de vista los límites que acompañan todo proceso científico.

Bibliografía

- Arias Valencia, M. (2022). Principles, scope, and limitations of the methodological triangulation. *Investigación y Educación en Enfermería*, 40(2), e03. <https://doi.org/10.17533/udea.iee.v40n2e03>
- Aven, T. (2023). A risk and safety science perspective on the precautionary principle. *Safety Science*, 165, 106211. <https://doi.org/10.1016/j.ssci.2023.106211>
- Botta, N., Brede, N., Crucifix, M., Ionescu, C., Jansson, P., Li, Z., . . . Richter, T. (2023). Responsibility under uncertainty: Which climate decisions matter most? *Environmental Modeling & Assessment*, 28, 337-365. <https://doi.org/10.1007/s10666-022-09867-w>
- Burrows, T. (2023). Reproducibility, verifiability, and computational historical research. *International Journal of Digital Humanities*, 5, 283-298. <https://doi.org/10.1007/s42803-023-00068-9>
- Casula, M., Rangarajan, N., & Shields, P. (2021). The potential of working hypotheses for deductive exploratory research. *Quality & Quantity*, 55(5), 1703-1725. <https://doi.org/10.1007/s11135-020-01072-9>
- Chen, Y.-C., Jordan, M., Park, J., & Starrett, E. (2024). Navigating student uncertainty for productive struggle: Establishing the importance for and distinguishing types, sources, and desirability of scientific uncertainties. *Science Education*, 108(4), 1099-1133. <https://doi.org/10.1002/sce.21864>
- Covitt, B., & Anderson, C. (2022). Untangling trustworthiness and uncertainty in science. *Science & Education*, 31(5), 1155-1180. <https://doi.org/10.1007/s11191-022-00322-6>
- Cox, M., & O'Hagan, A. (2022). Meaningful expression of uncertainty in measurement. *Accreditation and Quality Assurance*, 27(1), 19-37. <https://doi.org/10.1007/s00769-021-01485-5>
- de la Torre-López, J., Ramírez, A., & Romero, J. (2023). Artificial intelligence to automate the systematic review of scientific literature. *Computing*, 105, 2171-2194. <https://doi.org/10.1007/s00607-023-01181-x>
- Derksen, M., & Morawski, J. (2022). Kinds of replication: Examining the meanings of “conceptual replication” and “direct replication”. *Perspectives on Psychological Science*, 17(5), 1490-1505. <https://doi.org/10.1177/17456916211041116>

- Duschl, R., Avraamidou, L., & Azevedo, N. (2021). Data-texts in the sciences: The evidence-explanation continuum. *Science & Education*, 30(5), 1159-1181. <https://doi.org/10.1007/s11191-021-00225-y>
- Engelschalt, P., Röske, M., Penzlin, J., Krüger, D., & Upmeyer zu Belzen, A. (2023). Abductive reasoning in modeling biological phenomena as complex systems. *Frontiers in Education*, 8, 1170967. <https://doi.org/10.3389/educ.2023.1170967>
- Fajardo-Fontiveros, O., Reichardt, I., De Los Ríos, H., Duch, J., Sales-Pardo, M., & Guimerà, R. (2023). Fundamental limits to learning closed-form mathematical models from data. *Nature Communications*, 14, 1043. <https://doi.org/10.1038/s41467-023-36657-z>
- Gough, D. (2021). Appraising evidence claims. *Review of Research in Education*, 45(1), 1-26. <https://doi.org/10.3102/0091732X20985072>
- Hansen, J., & Quinon, P. (2023). The importance of expert knowledge in big data and machine learning. *Synthese*, 201, 35. <https://doi.org/10.1007/s11229-023-04041-5>
- Helliwell, J., & Massera, C. (2022). The four Rs and crystal structure analysis: Reliability, reproducibility, replicability and reusability. *Journal of Applied Crystallography*, 55(5), 1351-1358. <https://doi.org/10.1107/S1600576722007208>
- Hudson, R. (2021). Should we strive to make science bias-free? A philosophical assessment of the reproducibility crisis. *Journal for General Philosophy of Science*, 52(3), 389-405. <https://doi.org/10.1007/s10838-020-09548-w>
- Jack, S., Orr, E., Campbell, K., Whitmore, C., & Cammer, A. (2023). A framework for selecting data generation strategies in qualitative health research studies. *Journal of Human Nutrition and Dietetics*, 36(4), 1480-1495. <https://doi.org/10.1111/jhn.13134>
- Kapoor, S., & Narayanan, A. (2023). Leakage and the reproducibility crisis in machine-learning-based science. *Patterns*, 4(9), 100804. <https://doi.org/10.1016/j.patter.2023.100804>
- Kiyasseh, D., Cohen, A., Jiang, C., & Altieri, N. (2024). A framework for evaluating clinical artificial intelligence systems without ground-truth annotations. *Nature Communications*, 15, 1808. <https://doi.org/10.1038/s41467-024-46000-9>
- Lee, J., Hwang, E., & Kacker, R. (2022). True value, error, and measurement uncertainty: Two views. *Accreditation and Quality Assurance*, 27(4), 235-242. <https://doi.org/10.1007/s00769-022-01508-9>

- Leins, D., Haase, S., Eslami, M., Schrier, J., & Freeman, J. (2023). Collaborative methods to enhance reproducibility and accelerate discovery. *Digital Discovery*, 2(1), 12-27. <https://doi.org/10.1039/D2DD00061J>
- Mathur, M., & Fox, M. (2023). Toward open and reproducible epidemiology. *American Journal of Epidemiology*, 192(4), 658-664. <https://doi.org/10.1093/aje/kwad007>
- Metzen, H. (2024). Objectivity, shared values, and trust. *Synthese*, 203, 60. <https://doi.org/10.1007/s11229-024-04493-3>
- Monti, C., Pangallo, M., De Francisci Morales, G., & Bonchi, F. (2023). On learning agent-based models from data. *Scientific Reports*, 13, 9268. <https://doi.org/10.1038/s41598-023-35536-3>
- Nilsson, A., Peters, J., Meimetis, N., Bryson, B., & Lauffenburger, D. (2022). Artificial neural networks enable genome-scale simulations of intracellular signaling. *Nature Communications*, 13, 3069. <https://doi.org/10.1038/s41467-022-30684-y>
- Olaghere, A., Wilson, D., & Kimbrell, C. (2023). Inclusive critical appraisal of qualitative and quantitative findings in evidence synthesis. *Research Synthesis Methods*, 14(6), 847-852. <https://doi.org/10.1002/jrsm.1659>
- Omerovic, E. (2023). Can contradictory results from RCTs that tested the same hypothesis be true simultaneously? Analyses of the VALIDATE-SWEDEHEART and BRIGHT-4 trials. *EuroIntervention*, 19(10), e802-e805. <https://doi.org/10.4244/EIJ-D-23-00151>
- Pedder, H., Dias, S., Boucher, M., Bennetts, M., Mawdsley, D., & Welton, N. (2022). Methods to assess evidence consistency in dose-response model based network meta-analysis. *Statistics in Medicine*, 41(4), 625-644. <https://doi.org/10.1002/sim.9270>
- Queirós, P. (2022). Evidencias científicas y conocimiento disciplinar de enfermería. *Cultura de los Cuidados*, 26(62), 279-293. <https://doi.org/10.14198/cuid.2022.62.19>
- Rickinson, M., Cirkony, C., Walsh, L., Gleeson, J., Salisbury, M., & Boaz, A. (2021). Insights from a cross-sector review on how to conceptualise the quality of use of research evidence. *Humanities and Social Sciences Communications*, 8, 170. <https://doi.org/10.1057/s41599-021-00821-x>
- Schnarr, A., & Mertz, M. (2022). States of uncertainty, risk–benefit assessment and early clinical research: A conceptual investigation. *Science and Engineering Ethics*, 28(6), 68. <https://doi.org/10.1007/s11948-022-00418-w>

- Schneider, C., Freeman, A., Spiegelhalter, D., & van der Linden, S. (2022). The effects of communicating scientific uncertainty on trust and decision making in a public health context. *Judgment and Decision Making*, 17(4), 849-882. <https://doi.org/10.1017/S1930297500008962>
- Selva, J., Argyroudis, S., Cotton, F., Esposito, S., Iqbal, S., Lorito, S., . . . Giardini, D. (2024). A novel multiple-expert protocol to manage uncertainty and subjective choices in probabilistic single and multi-hazard risk analyses. *International Journal of Disaster Risk Reduction*, 110, 104641. <https://doi.org/10.1016/j.ijdr.2024.104641>
- Sondhi, A., Segal, B., Snider, J., Humblet, O., & McCusker, M. (2021). Bayesian additional evidence for decision making under small sample uncertainty. *BMC Medical Research Methodology*, 21, 221. <https://doi.org/10.1186/s12874-021-01432-5>
- Villalobos Antúnez, J., Severino-González, P., Caldera Ynfante, J., & Ramírez-Molina, R. (2023). Epistemología, complejidad y sistema: Una mirada a la incertidumbre en contextos tecnológicos. *Revista Científica Saperes Universitas*, 6(2), 145-160. <https://doi.org/10.53485/rsu.v6i2.346>
- Ward, Z., & Creel, K. (2024). To hedge or not to hedge: Scientific claims and public justification. *Philosophy of Science*, 91(4), 990-1008. <https://doi.org/10.1017/psa.2024.17>
- Wei, Z., Yang, A., Rocha, L., Miranda, M., & Nathoo, F. (2022). A review of Bayesian hypothesis testing and its practical implementations. *Entropy*, 24(2), 161. <https://doi.org/10.3390/e24020161>
- Wiedemann, P., Boerner, F., & Freudenstein, F. (2021). Effects of communicating uncertainty descriptions in hazard identification, risk characterization, and risk protection. *PLOS ONE*, 16(7), e0253762. <https://doi.org/10.1371/journal.pone.0253762>
- Williamson, J. (2023). Direct inference and probabilistic accounts of induction. *Journal for General Philosophy of Science*, 54(3), 451-472. <https://doi.org/10.1007/s10838-021-09584-0>
- Woensdregt, M., Fusaroli, R., Rich, P., Modrák, M., Kolokolova, A., Wright, C., & Warlaumont, A. (2024). Lessons for theory from scientific domains where evidence is sparse or indirect. *Computational Brain & Behavior*, 7(4), 588-607. <https://doi.org/10.1007/s42113-024-00214-8>

ISBN: 978-9907-848-03-8



9 789907 848038