

JMNJE V4. N1. 089

**Inferencia bayesiana, inteligencia artificial y computación cuántica: una
revisión sistemática de la literatura**

*Bayesian inference, artificial intelligence, and quantum computing: a
systematic review of the literature*

Autores:

Carla Pazmiño Naranjo
Universidad Nacional de Chimborazo (UNACH)
Riobamba – Ecuador
carla.pazmino@unach.edu.ec
<https://orcid.org/0009-0000-5276-8810>

Andrés Galvis Correa
Universidad de las Fuerzas Armadas ESPE
Sangolquí – Ecuador
aagalvis@espe.edu.ec
<https://orcid.org/0000-0001-7762-2893>

Autor de correspondencia: *Carla Pazmiño Naranjo*, carla.pazmino@unach.edu.ec

Enviado: 09-05-2026
Aceptado: 25-07-2026

Revisado: 27-06-2026
Publicado: 28-07-2026

Cómo citar este artículo:

Pazmiño Naranjo, C., & Galvis Correa, A. (2026). Inferencia bayesiana, inteligencia artificial y computación cuántica: una revisión sistemática de la literatura. *Journal of Multidisciplinary Novel Journeys & Explorations*, 4(1), 1-49. <https://doi.org/10.63688/qnj40m25>

© 2026; Los autores. Este es un artículo en acceso abierto, distribuido bajo los términos de una licencia Creative Commons (<https://creativecommons.org/licenses/by/4.0>) que permite el uso, distribución y reproducción en cualquier medio, siempre que la obra original sea correctamente citada.



RESUMEN

Esta revisión sistemática examina la integración sustantiva entre inferencia bayesiana, inteligencia artificial/aprendizaje automático y computación cuántica, con énfasis en los avances metodológicos, las estructuras matemáticas, las aplicaciones y la solidez de la evidencia. Se analizaron publicaciones de 2010 a 2025 recuperadas de Scopus y Web of Science. El protocolo siguió PSALSAR; la selección se reportó mediante PRISMA 2020 y la búsqueda se documentó con PRISMA-S. De 390 registros iniciales, 261 permanecieron después de normalización, deduplicación y control temporal; se evaluaron 119 textos completos y 66 artículos integraron la síntesis principal. RQ1-RQ4 identificaron ocho familias de avance y una taxonomía funcional que separa técnica bayesiana, tarea de IA, paradigma cuántico, arquitectura y objeto matemático. Predominaron la optimización bayesiana de modelos, circuitos o controles cuánticos (27 artículos; 40,9 %), las arquitecturas híbridas clásico-cuánticas (49; 74,2 %) y las tareas de optimización (25; 37,9 %). RQ5 encontró solo dos aplicaciones financieras o económicas directas (3,0 %) y ninguna aplicación macroeconómica directa. RQ6 mostró una evidencia dominada por simulaciones (33; 50,0 %); 19 estudios incluyeron hardware, pero únicamente 11 lo utilizaron como validación principal. La madurez fue principalmente intermedia (34; 51,5 %) y la reproducibilidad permaneció limitada: 25 artículos reportaron código y 14 alcanzaron la puntuación superior de reproducibilidad. Los resultados más sólidos corresponden a mejoras locales en fidelidad, presupuesto de mediciones, mezcla de cadenas, representación probabilística o compactación de circuitos; no sustentan una ventaja cuántica general. Como contribución de síntesis, se formaliza un ciclo híbrido común y se proponen criterios de comparación que preservan la naturaleza ordinal de la evidencia y distinguen costo, error, escala y validación de dominio.

Palabras clave: inferencia bayesiana, optimización bayesiana, computación cuántica, aprendizaje automático cuántico, revisión sistemática.

ABSTRACT

This systematic review examines the substantive integration of Bayesian inference, artificial intelligence/machine learning, and quantum computing, emphasizing methodological advances, mathematical structures, applications, and strength of evidence. Publications from 2010 to 2025 were retrieved from Scopus and Web of Science. The protocol followed PSALSAR, study selection was reported according to PRISMA 2020, and the search strategy followed PRISMA-S. Of 390 initial records, 261 remained after normalization, deduplication, and temporal control; 119 full texts were assessed and 66 articles entered the main synthesis. RQ1-RQ4 identified eight families of advances and a functional taxonomy that separates Bayesian technique, AI task, quantum paradigm, architecture, and mathematical object. Bayesian optimization of quantum models, circuits, or controls (27 articles; 40.9%), hybrid quantum-classical architectures (49; 74.2%), and optimization tasks (25; 37.9%) predominated. RQ5 found only two direct financial or economic applications (3.0%) and no direct macroeconomic application. RQ6 showed evidence dominated by simulations (33; 50.0%); 19 studies involved hardware, but only 11 used it as the main validation design. Methodological maturity was mainly intermediate (34; 51.5%), while reproducibility remained limited: 25 articles reported code and 14 achieved the highest reproducibility score. The strongest results concern local improvements in fidelity, measurement budgets, Markov-chain mixing, probabilistic representation, or circuit compactness; they do not establish a general quantum advantage. As a synthesis contribution, the review formalizes a common hybrid cycle and proposes comparison criteria that preserve the ordinal nature of evidence while distinguishing cost, error, scale, and domain validation.

Keywords: Bayesian inference, Bayesian optimization, quantum computing, quantum machine learning, systematic review.



1. INTRODUCCIÓN

La inferencia bayesiana, la inteligencia artificial (IA) y la computación cuántica convergen en problemas donde es necesario aprender, inferir, predecir u optimizar bajo incertidumbre y con evaluaciones costosas. El enfoque bayesiano representa el conocimiento mediante distribuciones previas y posteriores; la IA organiza tareas de aprendizaje y decisión; y el recurso cuántico puede intervenir en la evaluación de funciones, la generación de muestras, la representación de distribuciones o la exploración de espacios combinatorios (Biamonte et al., 2017; Jordan & Mitchell, 2015; van de Schoot et al., 2021). La intersección no constituye un algoritmo único, sino un conjunto de arquitecturas en las que diferentes operaciones matemáticas se distribuyen entre componentes probabilísticos, clásicos y cuánticos.

El interés por estas arquitecturas se ha intensificado durante la etapa NISQ, caracterizada por ruido, conectividad limitada, profundidad restringida y necesidad de múltiples mediciones (Cerezo et al., 2021; Preskill, 2018). En este contexto, la mayoría de las propuestas no sustituye el cálculo clásico: el procesador cuántico estima un observable, construye un kernel, genera una propuesta o explora una función de energía, mientras una rutina clásica actualiza parámetros, procesa mediciones, cuantifica incertidumbre o decide la acción siguiente (Endo et al., 2021; Izawa et al., 2022). Por ello, el desempeño debe atribuirse al flujo híbrido completo y no al circuito de manera aislada.

La literatura disponible es heterogénea. Incluye optimización bayesiana de circuitos y controles, inferencia variacional, procesos gaussianos con kernels cuánticos, redes bayesianas codificadas en circuitos, MCMC con propuestas cuánticas, aprendizaje de Hamiltonianos y formulaciones QUBO/Ising. También combina resultados teóricos, simulaciones ideales, experimentos físicos y pruebas en hardware. Esta diversidad dificulta comparar contribuciones y favorece afirmaciones que confunden formulación matemática, factibilidad experimental y ventaja frente a líneas base clásicas.

Dentro de estas aplicaciones, las máquinas de Ising también se han utilizado para identificar trayectorias óptimas en redes complejas, demostrando su capacidad para representar problemas de búsqueda mediante formulaciones de optimización combinatoria (Mizuno y Komatsuzaki, 2024).



Desde la ingeniería matemática, el interés reside en la articulación de probabilidad, estadística, optimización, álgebra lineal, teoría de grafos, métodos de Monte Carlo, sistemas dinámicos y modelación energética. Las contribuciones pueden expresarse mediante distribuciones posteriores, funciones de adquisición, divergencias, valores esperados, núcleos de transición, Hamiltonianos o funciones cuadráticas binarias. Una integración se consideró sustantiva solo cuando el componente bayesiano representó o actualizó incertidumbre, la IA definió una tarea científica concreta y el componente cuántico cumplió una operación identificable dentro del método, la validación o la aplicación.

El objetivo de este estudio es sintetizar los avances teóricos, metodológicos y aplicados publicados entre 2010 y 2025 en la intersección de la inferencia bayesiana, la IA y la computación cuántica. Las ocho preguntas del protocolo se organizan en cuatro núcleos: i) familias de avance y taxonomía funcional (RQ1-RQ4); ii) aplicaciones financieras, económicas y macroeconómicas (RQ5); iii) implementación, evidencia y validación (RQ6); y iv) madurez, reproducibilidad, vacíos y agenda (RQ7-RQ8). La contribución se desarrolla en tres niveles: una clasificación de los 66 textos completos, una comparación crítica de la evidencia y una síntesis matemática transversal que explicita el flujo de información, el costo, el error, la escala y los criterios necesarios para interpretar una mejora cuántica.

2. METODOLOGÍA

2.1. Diseño, protocolo y preguntas de investigación

La investigación se desarrolló como una revisión sistemática de literatura, entendida como un procedimiento explícito para identificar, evaluar e interpretar evidencia científica y reconocer vacíos de conocimiento (García-Peñalvo, 2022; Snyder, 2019). El proceso se organizó mediante PSALSAR —*Protocol, Search, Appraisal, Synthesis, Analysis and Report*— (Mengist et al., 2020). La selección de estudios se reportó conforme a PRISMA 2020 (Page, McKenzie, et al., 2021; Page, Moher, et al., 2021) y la estrategia de búsqueda siguió PRISMA-S (Rethlefsen et al., 2021).

Las preguntas de revisión se mantuvieron como unidades operativas del análisis:



Tabla 1.*Correspondencia entre preguntas de revisión, variables y función en la síntesis*

Pregunta	Contenido analizado	Función en la síntesis
RQ1	Avances teóricos y metodológicos Bayes-IA-cuánticos	Identificar familias de integración
RQ2	Técnicas bayesianas y función	Establecer cómo se representa o utiliza la incertidumbre
RQ3	Paradigmas y arquitecturas cuánticas	Identificar la operación asignada al recurso cuántico
RQ4	Tareas de IA/aprendizaje automático	Clasificar optimización, inferencia, predicción, clasificación y muestreo
RQ5	Aplicaciones financieras, económicas y macroeconómicas	Distinguir relevancia directa, indirecta y transferibilidad
RQ6	Implementación, evidencia y validación	Separar teoría, simulación, hardware, benchmark y comparación clásica
RQ7	Calidad, madurez y reproducibilidad	Evaluar la solidez y verificabilidad de los resultados
RQ8	Vacíos y agenda	Derivar prioridades matemáticas y aplicadas

Nota. Las preguntas de investigación orientaron la extracción, clasificación y síntesis de la evidencia analizada. RQ = pregunta de investigación. Elaboración propia.

RQ1-RQ4 se integraron en una taxonomía funcional que conserva seis dimensiones: familia de avance, técnica y rol bayesiano, tarea de IA, paradigma cuántico, arquitectura y objeto



matemático. RQ5 se mantuvo como análisis aplicado; RQ6 se vinculó con el tipo de implementación, las líneas base y el alcance de las afirmaciones; y RQ7-RQ8 se sintetizaron mediante calidad, madurez, reproducibilidad y vacíos. La Tabla 1 muestra la trazabilidad entre preguntas, variables y productos de síntesis.

2.2. Fuentes, búsqueda y gestión de registros

La búsqueda se ejecutó el 10 de junio de 2026 en Scopus y Web of Science, con periodo documental 2010-2025. En Scopus se consultaron título, resumen y palabras clave mediante TITLE-ABS-KEY; en Web of Science se utilizó el campo Topic. La estrategia combinó mediante AND tres bloques: términos bayesianos, términos de IA/aprendizaje automático y términos de computación cuántica. Los términos financieros, económicos y macroeconómicos no se utilizaron como filtro obligatorio, porque ello habría excluido formulaciones generales con posible transferibilidad; su relevancia se codificó durante la extracción. Las estrategias completas, límites y fechas forman parte del material reproducible del estudio.


Se exportaron 258 registros de Scopus y 132 de Web of Science. Los metadatos se normalizaron antes de deduplicar. Se conservaron las decisiones de eliminación y sus razones, de modo que la unidad bibliométrica y la unidad de síntesis pudieran distinguirse. La bibliometría se aplicó al corpus deduplicado del periodo; la síntesis matemática, la calidad y la madurez se calcularon únicamente sobre los textos completos incluidos.

2.3. Elegibilidad y selección

Se incluyeron artículos de investigación o revisión en los que los tres componentes cumplieran funciones conectadas dentro del método, algoritmo, arquitectura, experimento, validación o aplicación principal. Se excluyeron menciones marginales, documentos sin uno de los componentes y tipos documentales externos a la síntesis principal. La selección tuvo dos etapas: cribado por título/resumen y evaluación de texto completo.

La búsqueda reunió 390 registros. La deduplicación eliminó 127 y el control temporal retiró dos, de modo que quedaron 261 registros únicos. Después del cribado y del control de tipo documental, se buscaron 143 textos completos. Veinticuatro no pudieron recuperarse y se registraron como limitación de acceso; 119 se evaluaron y 66 cumplieron los criterios de integración sustantiva. Las exclusiones a texto completo se debieron a ausencia o papel marginal de Bayes, IA o computación cuántica.



Figura 1.*Flujo PRISMA 2020 de la revisión sistemática.*

Nota. El diagrama presenta el proceso de identificación, cribado, elegibilidad e inclusión de los estudios. Elaboración propia.

2.4. Extracción, calidad y madurez

La extracción se realizó mediante una matriz estandarizada (Snyder, 2019). Para cada artículo se codificaron identificación bibliográfica, elegibilidad, técnica y función bayesiana, tarea de IA, paradigma cuántico, arquitectura, implementación, tipo de evidencia, dominio de aplicación, línea base, resultado, disponibilidad de código y datos, limitaciones, vacíos, calidad y madurez. Los datos ausentes se distinguieron como no reportado, no verificable y no aplicable; no se imputaron métricas, disponibilidad de materiales ni conclusiones. Esta codificación conservadora fue necesaria para separar la ausencia de reporte de una evidencia negativa.



La calidad se evaluó con diez criterios ordinales de 0 a 2: claridad del objetivo, detalle metodológico, ajuste bayesiano, ajuste de IA, ajuste cuántico, transparencia de datos o simulaciones, fortaleza de validación, tratamiento de incertidumbre, reproducibilidad y coherencia entre conclusiones y limitaciones. La suma se utilizó como indicador de completitud documental y no como escala intervalar. La madurez se clasificó en incipiente, emergente, intermedia y avanzada, considerando conjuntamente formulación, implementación y validación.

2.5. Estrategia de síntesis matemática

La síntesis se desarrolló en cuatro niveles. Primero, la bibliometría describió crecimiento, tipos documentales y estructura temática, sin sustituir la lectura de texto completo (Aria & Cuccurullo, 2017). Segundo, RQ1-RQ4 se integraron mediante una taxonomía multidimensional que separó familia, técnica, tarea, paradigma, arquitectura y objeto matemático. Tercero, RQ5-RQ6 relacionaron las formulaciones con aplicaciones, métricas, hardware y líneas base. Cuarto, RQ7-RQ8 combinaron calidad, reproducibilidad, madurez y vacíos. La heterogeneidad de problemas, métricas e implementaciones impidió realizar un metaanálisis; en su lugar se empleó síntesis estructurada y comparación por mecanismos.

Para fortalecer el componente matemático, cada familia se examinó mediante cinco preguntas: ¿cuál es el objeto desconocido o la función objetivo?, ¿cómo se representa la incertidumbre?, ¿qué operación define la tarea de IA?, ¿qué cálculo se asigna al recurso cuántico?, y ¿qué criterio permite evaluar la mejora? Las formalizaciones presentadas en la sección 3.6 condensan patrones del corpus. No se atribuyen como ecuaciones literales a un artículo ni se presentan como teoremas de ventaja; funcionan como instrumentos analíticos para comparar métodos heterogéneos.

La integración de RQ2-RQ4 se analizó como una relación funcional entre tres dimensiones: el componente bayesiano, la tarea de IA/aprendizaje automático y el paradigma cuántico. Para cada artículo se verificó qué incertidumbre representaba o actualizaba Bayes, cuál era la salida científica de la tarea de IA y qué operación concreta se asignaba al recurso cuántico. La arquitectura y el tipo de implementación se conservaron como dimensiones adicionales para no confundir una formulación híbrida con una ejecución completa en hardware. En RQ5, la relación con finanzas, economía y macroeconomía se codificó en cuatro niveles: aplicación directa, relevancia indirecta, transferibilidad potencial y ausencia de relación verificable.



Las variables ordinales se interpretaron mediante frecuencias y distribuciones por categoría. No se asumió que la distancia entre 0, 1 y 2 fuera constante. Esta decisión es coherente con el propósito de la rúbrica: identificar cobertura y transparencia, no producir una escala cardinal de calidad.

3. RESULTADOS

3.1. Corpus y tendencias generales

La producción recuperada se concentra en el tramo reciente del periodo analizado. De los 261 registros deduplicados, 235 corresponden a 2020-2025; el máximo anual se registró en 2025, con 70 publicaciones. Este crecimiento confirma el interés reciente por la combinación de métodos bayesianos y recursos cuánticos, pero no constituye por sí mismo evidencia de madurez. La madurez se estableció mediante lectura de texto completo, validación y reproducibilidad.

El corpus bibliométrico incluyó 145 artículos, 12 revisiones, 83 artículos de conferencia, 15 revisiones de conferencia, tres libros y tres capítulos. La literatura estuvo distribuida en 169 fuentes, sin una revista dominante. La alta superposición entre Scopus y Web of Science y el conjunto exclusivo aportado por Scopus justificaron la búsqueda en ambas bases. Los términos más frecuentes —*quantum computing*, *optimization*, *machine learning*, *bayesian networks* y *bayesian optimization*— describen el campo recuperado, pero no prueban que los tres componentes estén conectados en cada registro.

Por esa razón, la contribución central se construyó sobre los 66 artículos incluidos después de la revisión de texto completo. La bibliometría se interpreta como contexto: muestra crecimiento y concentración temática; la taxonomía, la evaluación de evidencia y el mapa de vacíos establecen el avance metodológico real.

3.2. Avances matemáticos y taxonomía funcional (RQ1-RQ4)

3.2.1. Distribución de familias, técnicas, tareas y paradigmas

RQ1 identificó ocho familias de avance. La optimización bayesiana de modelos, circuitos o control cuántico fue la más frecuente, con 27 artículos (40,9 %). Le siguieron la inferencia bayesiana cuántica o acelerada, con 12 (18,2 %), y la representación cuántica de modelos probabilísticos, con nueve (13,6 %). El recocido cuántico para aprendizaje u optimización probabilística y los métodos MCMC o Monte Carlo asistidos reunieron cinco artículos cada



uno (7,6 %). Cuatro trabajos se concentraron en aprendizaje bayesiano de modelos o dispositivos (6,1 %), tres en desarrollos metodológicos específicos (4,5 %) y uno en un costo bayesiano aplicado a optimización variacional (1,5 %).

La asignación de la familia principal fue exclusiva para que los conteos sumaran los 66 artículos, aunque un mismo estudio pudiera combinar varias técnicas, tareas o subrutinas. Las relaciones secundarias se conservaron en la taxonomía multidimensional y en el análisis narrativo.

RQ2 mostró que la optimización bayesiana fue la técnica más frecuente (27 artículos), seguida de redes bayesianas (9), MCMC (8), inferencia bayesiana general (6) y procesos gaussianos (6). RQ3 identificó el predominio de algoritmos variacionales y recocido cuántico, con doce estudios cada uno, además de circuitos por compuertas, QAOA, kernels cuánticos, redes y enfoques explícitos de inferencia bayesiana cuántica. RQ4 estableció que la optimización fue la tarea principal (25; 37,9 %), seguida de inferencia (8; 12,1 %), predicción (7; 10,6 %), clasificación (6; 9,1 %) y muestreo (4; 6,1 %).

Estas dimensiones no son equivalentes. La familia expresa el mecanismo principal de integración; la técnica bayesiana indica cómo se modela o utiliza la incertidumbre; la tarea de IA define la operación de aprendizaje; y el paradigma cuántico identifica el recurso computacional. Un estudio de VQE, por ejemplo, puede pertenecer a la familia de optimización bayesiana, usar un proceso gaussiano, desarrollar una tarea de optimización y ejecutar un circuito variacional en una arquitectura híbrida.

La arquitectura híbrida clásico-cuántica apareció en 49 artículos (74,2 %). El patrón dominante consiste en una rutina cuántica que estima, representa o explora una cantidad y un componente clásico que actualiza parámetros, incertidumbre o decisiones. Esta concentración es consistente con las restricciones NISQ y confirma que el beneficio debe evaluarse sobre el sistema completo, no sobre el circuito aislado (Cerezo et al., 2021; Endo et al., 2021). La Tabla 2 resume las ocho familias y explicita el objeto matemático que organiza cada una.

Tabla 2.

Taxonomía funcional de las ocho familias de avance identificadas en RQ1



Familia de avance (RQ1)	n (%)	Rol bayesiano	Tarea de IA	Operación cuántica y objeto matemático
Optimización bayesiana de modelos, circuitos o control	27 (40,9)	Sustituto probabilístico y función de adquisición	Optimización/diseño secuencial	Evaluar una función costosa o ruidosa: VQE, QAOA, circuitos, control o experimento
Inferencia bayesiana cuántica o acelerada	12 (18,2)	Posterior, inferencia variacional, ABC o modelo generativo	Inferencia/predicción	Aproximar posteriores, integrales o características
Representación cuántica de modelos probabilísticos	9 (13,6)	Factorización y condicionamiento en redes bayesianas	Inferencia/clasificación	Codificar distribuciones y consultas mediante circuitos
Recocido cuántico para aprendizaje u optimización probabilística	5 (7,6)	Distribución de Gibbs, Boltzmann o energía probabilística	Optimización/muestreo	Explorar funciones QUBO/Ising mediante recocido
MCMC y otros métodos de Monte Carlo asistidos	5 (7,6)	Distribución objetivo y regla de aceptación	Muestreo	Generar propuestas o dinámica cuántica preservando la distribución estacionaria



Familia de avance (RQ1)	n (%)	Rol bayesiano	Tarea de IA	Operación cuántica y objeto matemático
Aprendizaje bayesiano de modelos o dispositivos cuánticos	4 (6,1)	Posterior sobre parámetros, filtro o MAP	Estimación/control	Aprender Hamiltonianos, parámetros o configuraciones experimentales
Desarrollos metodológicos específicos	3 (4,5)	Selección de modelos, kernels o inferencia aproximada	Predicción/inferencia/selección	Combinar simulación, kernels o rutinas cuánticas con modelos probabilísticos
Costo o criterio bayesiano en optimización variacional	1 (1,5)	Riesgo o costo bayesiano	Estimación/diseño	Optimizar un protocolo variacional con una función de pérdida bayesiana

Nota. Las seis subsecciones 3.2.2-3.2.7 consolidan las ocho familias sin alterar sus conteos; los desarrollos específicos y el costo bayesiano variacional se integran en la subsección 3.2.7 por su menor frecuencia y afinidad con el aprendizaje de sistemas.

3.2.2. Optimización bayesiana de modelos, circuitos y control

La familia predominante aparece cuando la evaluación de una función es costosa, ruidosa o limitada por un presupuesto de mediciones. Sean parámetros $\theta \in \Theta$ y observaciones

$$\mathcal{D}_t = \{(\theta_i, y_i)\}_{i=1}^t, \quad y_i = f(\theta_i) + \varepsilon_i. \quad (1)$$

La optimización bayesiana construye una distribución predictiva para f . Cuando el sustituto es un proceso gaussiano, se obtienen una media $\mu_t(\theta)$ y una varianza $\sigma_t^2(\theta)$. La siguiente evaluación se selecciona mediante

$$\theta_{t+1} = \operatorname{argmax}_{\theta \in \Theta} a_t(\theta; \mu_t(\theta), \sigma_t(\theta), \mathcal{D}_t), \quad \mathcal{D}_{t+1} = \mathcal{D}_t \cup \{(\theta_{t+1}, y_{t+1})\}. \quad (2)$$



La función de adquisición equilibra explotación y exploración: favorece configuraciones con buen desempeño esperado, pero conserva la posibilidad de evaluar regiones inciertas. El componente bayesiano administra la información; la IA organiza la búsqueda secuencial; y el dispositivo cuántico o el experimento devuelve una nueva observación.

Esta descomposición se utilizó en calibración adaptativa de redes cuánticas bajo pérdidas y ruido (Cortes et al., 2022), diseño de cronogramas de recocido (Finžgar et al., 2024), ingeniería de estados cuánticos (Müller et al., 2025), síntesis de programas (Y. Xiao et al., 2021), diseño de circuitos (Pirhooshyaran & Terlaky, 2021) y ajuste de parámetros de QAOA (Kim & Wang, 2023). En circuitos variacionales, SGLBO combina un gradiente estocástico para determinar la dirección y una búsqueda bayesiana unidimensional para seleccionar la magnitud del paso, reduciendo el presupuesto de mediciones en simulaciones con ruido (Tamiya & Yamasaki, 2022). En VQE molecular, la información previa sobre la topología de la superficie permite aprovechar observaciones de pocos shots (Sorourifar et al., 2025). Los modelos sustitutos también se desarrollaron mediante procesos gaussianos dispersos, kernels cuánticos y representaciones de superficies de energía (Kuš et al., 2021; Dai & Krems, 2022; Rapp & Roth, 2024; Farooq et al., 2024; Smith et al., 2023). En QAOA y circuitos parametrizados se propusieron estrategias bayesianas o adaptativas dependientes de la tarea y del hardware (Tibaldi et al., 2023; Cheng et al., 2024; Benítez-Buenache & Portell-Montserrat, 2025).

En algoritmos variacionales, la función evaluada suele ser un valor esperado,

$$C(\theta) = \langle 0 | U^\dagger(\theta) H U(\theta) | 0 \rangle = \sum_y c(y) p_Q(y | \theta). \quad (3)$$

La cantidad se estima con un número finito de mediciones. Por ello, el problema no consiste únicamente en minimizar la función de costo, sino en hacerlo bajo incertidumbre de muestreo y ruido. La optimización bayesiana resulta adecuada porque utiliza explícitamente la incertidumbre predictiva para distribuir las evaluaciones. Sin embargo, una reducción del número de iteraciones no demuestra automáticamente menor costo total: cada iteración puede requerir múltiples circuitos, observables y repeticiones. Además, la expresividad del ansatz, la preparación del estado, la robustez frente al ruido y la posibilidad de entrenar el circuito en hardware condicionan el resultado observado (Ciavarella & Chernyshev, 2022; Du et al., 2020; He et al., 2024; Zhu et al., 2019).

El aporte de esta familia es metodológicamente claro. No pretende acelerar cualquier



problema de optimización, sino reducir el número de evaluaciones de una función costosa. Su madurez relativa se explica por la correspondencia directa entre la incertidumbre del sustituto y una limitación operativa de los dispositivos actuales.

3.2.3. Inferencia bayesiana cuántica y aproximación posterior

La segunda estructura mantiene una distribución posterior como objeto de cálculo. Para un parámetro, estado o modelo θ , datos $\mathcal{D}$, prior π_0 y verosimilitud L ,

$$\pi(\theta | \mathcal{D}) = \frac{L(\mathcal{D}|\theta)\pi_0(\theta)}{Z(\mathcal{D})}, \quad Z(\mathcal{D}) = \int_{\theta} L(\mathcal{D} | \vartheta)\pi_0(\vartheta) d\vartheta. \quad (4)$$

Las aplicaciones buscan aproximar marginales, predicciones o esperanzas posteriores,

$$\mathbb{E}_{\pi(\theta|\mathcal{D})}[g(\theta)] = \int_{\theta} g(\theta)\pi(\theta | \mathcal{D}) d\theta. \quad (5)$$

En inferencia variacional, una distribución tratable $q \in \mathcal{Q}$ aproxima la posterior mediante

$$q^* = \underset{q \in \mathcal{Q}}{\operatorname{argmin}} \operatorname{KL}(q(\theta) \parallel \pi(\theta | \mathcal{D})). \quad (6)$$

La extensión cuántica de variational Bayes incorpora fluctuaciones asociadas al recocido para explorar el paisaje de energía libre y disminuir la dependencia de mínimos locales (Miyahara & Sughiyama, 2018). Miyahara y Roychowdhury (2023) aportan argumentos físico-matemáticos y simulaciones a favor de una ventaja de QAVB bajo la estructura analizada; los propios autores señalan que una demostración matemática rigurosa queda como trabajo futuro. Por ello, el resultado debe interpretarse como evidencia teórica condicionada por el modelo, la codificación y el acceso a las operaciones requeridas, no como una ventaja general empíricamente establecida.

Otros trabajos combinan aprendizaje profundo bayesiano y subrutinas cuánticas para conservar predicciones probabilísticas (Zhao et al., 2019), desarrollan redes neuronales bayesianas cuánticas (Nguyen & Chen, 2022), utilizan modelos generativos cuánticos para estimación de parámetros (Ohno, 2023) o implementan modelos generativos híbridos mediante circuitos por compuertas (van Dam et al., 2020). La simulación cuántica y la inferencia aproximada también se emplearon para recuperar Hamiltonianos a partir de espectros NMR (Sels et al., 2020). En este último caso, la estructura integra reducción de dimensión, problema inverso y propagación de incertidumbre.

La diferencia frente a una optimización puramente puntual es fundamental. La salida no es únicamente $\hat{\theta}$, sino una distribución que permite cuantificar incertidumbre, evaluar funciones



posteriores y diseñar nuevas observaciones. La posible ventaja debe contabilizar el costo de preparar estados, ejecutar circuitos y extraer información suficiente de la posterior; una distribución codificada cuánticamente no es útil si su lectura destruye la ganancia teórica.

3.2.4. Representación cuántica de modelos probabilísticos

Una red bayesiana definida sobre un grafo dirigido acíclico G factoriza la distribución conjunta como

$$P_G(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i \mid \text{Pa}_G(X_i)). \quad (7)$$

Un circuito parametrizado puede representar una distribución discreta mediante

$$q_\phi(x) = |\langle x \mid U_\phi \mid 0 \rangle|^2. \quad (8)$$

La correspondencia entre amplitudes y probabilidades permite codificar marginales mediante rotaciones y probabilidades condicionales mediante compuertas controladas. Borujeni et al. (2021) desarrollaron circuitos para predicción bursátil, riesgo de liquidez y quiebra; las probabilidades simuladas fueron compatibles con las referencias clásicas dentro de los intervalos reportados. Fathallah et al. (2024) analizaron inferencia aproximada en redes cuánticas optimizadas. La misma estructura se extendió a redes ecológicas, pronóstico de demanda de bicicletas y confiabilidad de puentes (Marcot, 2021; Harikrishnakumar & Nannapaneni, 2023; Abdelmalek & Oudah, 2025).

La representación plantea dos problemas matemáticos. El primero es la eficiencia de codificación: las tablas condicionales pueden crecer exponencialmente con el número de padres y requerir compuertas controladas de alta complejidad. El segundo es la consulta: obtener marginales o probabilidades condicionadas puede exigir repeticiones, postselección o circuitos auxiliares. Por ello, reproducir una distribución clásica en un simulador valida la construcción, pero no demuestra que el costo de codificación e inferencia sea menor.

Esta familia es importante porque sitúa el modelo probabilístico dentro del circuito, no únicamente como optimizador externo. La contribución potencial se encuentra en representaciones compactas, inferencia aproximada y consultas donde la estructura del grafo pueda aprovecharse. La evidencia disponible todavía se concentra en redes pequeñas y simulaciones.

3.2.5. Recocido cuántico para aprendizaje y optimización probabilística

El recocido cuántico conecta el aprendizaje probabilístico y la optimización mediante una



función de energía y la exploración de un espacio de estados. En los estudios revisados, una distribución objetivo puede representarse como

$$\pi(x) = \frac{\tilde{\pi}(x)}{Z}, \quad \tilde{\pi}(x) = \exp[-\beta E(x)] \quad \text{o} \quad \tilde{\pi}(x) = L(\mathcal{D} | x)\pi_0(x). \quad (9)$$

La primera forma corresponde a una distribución de Gibbs, donde $E(x)$ es la energía, β es la temperatura inversa y Z es la constante de normalización. La segunda representa una distribución posterior bayesiana sin normalizar, construida a partir de la verosimilitud $L(\mathcal{D} | x)$ y la distribución previa $\pi_0(x)$. En ambos casos, el objeto matemático no es únicamente un mínimo aislado, sino una distribución cuyo peso relativo depende de la energía o de la evidencia aportada por los datos.

Para problemas de recocido, la energía suele escribirse mediante un modelo de Ising:

$$E(s) = \sum_i h_i s_i + \sum_{i < j} J_{ij} s_i s_j, \quad s_i \in \{-1, 1\}. \quad (10)$$

Los coeficientes h_i representan la contribución individual de cada variable y los términos J_{ij} describen las interacciones entre pares de estados. Esta formulación permite traducir problemas de aprendizaje, muestreo u optimización combinatoria a un paisaje energético en el que las configuraciones de menor energía representan soluciones preferentes (Shibukawa et al., 2024).

Desde la perspectiva del proceso físico, el recocido cuántico se describe como una evolución entre un Hamiltoniano conductor H_D y un Hamiltoniano de problema H_P :

$$H(s) = A(s)H_D + B(s)H_P, \quad s \in [0, 1]. \quad (11a)$$

Para problemas binarios, el Hamiltoniano de problema suele escribirse como

$$H_P = \sum_i h_i Z_i + \sum_{i < j} J_{ij} Z_i Z_j. \quad (11b)$$

En (11a), s es el parámetro adimensional de recocido y no debe confundirse con las variables de espín s_i de (10). Las funciones $A(s)$ y $B(s)$ controlan el peso relativo de ambos Hamiltonianos durante la evolución, mientras que Z_i denota el operador de Pauli Z asociado con el qubit i . Después de recodificar las variables binarias, el Hamiltoniano de problema es equivalente a una formulación QUBO. Esta equivalencia permite utilizar recocedores cuánticos para explorar distribuciones energéticas y resolver subproblemas combinatorios (Pelofske et al., 2023).

En la literatura revisada, esta estructura adopta varias funciones. Sato et al. (2013, pp. 2-3) relacionan el recocido cuántico con modelos de mezcla basados en procesos de Dirichlet;



Koshka y Novotny (2020, pp. 1-2) estudian el muestreo de modelos gráficos probabilísticos no dirigidos mediante un recocedor D-Wave; y Dixit et al. (2021) emplean el recocido en el entrenamiento de máquinas de Boltzmann restringidas. En optimización de materiales, Doi et al. (2023, p. 2) formulan como QUBO una función de adquisición y utilizan el recocedor para explorar configuraciones discretas. Miyahara y Sughiyama (2018, pp. 2-3) incorporan fluctuaciones cuánticas a la inferencia variacional, mientras que Finžgar et al. (2024, pp. 2-3) optimizan mediante inferencia bayesiana los parámetros de la propia trayectoria de recocido.

Estos trabajos muestran dos formas de integración. En la primera, el recocedor actúa como solucionador de un problema probabilístico o energético definido por la parte clásica. En la segunda, el propio proceso cuántico constituye el objeto que debe aprenderse o controlarse. En ambos casos, la evaluación no debe limitarse a la energía final: también debe considerar el costo de formular el problema, incorporar restricciones y penalizaciones, recodificar las variables, incrustar el grafo en el hardware y obtener un número suficiente de muestras. Por tanto, la equivalencia matemática entre Ising y QUBO facilita la implementación, pero no demuestra por sí sola una ventaja computacional.

3.2.6. MCMC y Monte Carlo asistidos por recursos cuánticos

Los métodos MCMC construyen una cadena cuya distribución estacionaria es una distribución objetivo π . En Metropolis-Hastings, una propuesta $x' \sim q(x' | x)$ se acepta con probabilidad

$$\alpha(x, x') = \min \left\{ 1, \frac{\pi(x')q(x|x')}{\pi(x)q(x'|x)} \right\}. \quad (12)$$

Los enfoques cuánticamente asistidos modifican principalmente el mecanismo de propuesta o la dinámica entre estados. El procesador cuántico puede generar movimientos no locales, mientras la regla clásica de aceptación preserva la distribución objetivo. Esta separación conserva una garantía probabilística conocida y asigna al recurso cuántico la etapa que puede limitar la mezcla.

Layden et al. (2023) implementaron propuestas cuánticas en un procesador superconductor para distribuciones de Boltzmann asociadas con modelos de Ising. En el experimento, el algoritmo convergió en menos iteraciones que alternativas MCMC clásicas; en simulación, los autores observaron una aceleración empírica polinómica entre cúbica y cuártica. Dado



que la tasa de convergencia no se establece analíticamente para el régimen general, el resultado queda condicionado a las distribuciones, propuestas y escalas estudiadas. Nakano et al. (2024) emplearon un *ansatz* alternante, Holbrook (2023) propuso paralelización, Lockwood et al. (2024) desarrollaron Hamiltonian Monte Carlo cuántico y Patti et al. (2023) utilizaron MCMC para reforzar algoritmos variacionales.

La reducción del número de pasos es una evidencia parcial. El desempeño debe evaluarse mediante tasa de aceptación, autocorrelación integrada, tamaño efectivo de muestra, error Monte Carlo, número de circuitos y tiempo por muestra independiente. Una propuesta puede producir movimientos más globales y, aun así, resultar costosa si requiere circuitos profundos o muchas mediciones. Esta familia ilustra con claridad la diferencia entre mejora geométrica de la cadena y ventaja computacional total.

3.2.7. Aprendizaje bayesiano de sistemas, dispositivos y arquitecturas

En esta familia la incertidumbre recae sobre el propio sistema que se desea identificar, calibrar o controlar. Una actualización secuencial puede escribirse como

$$\pi_t(\theta) \propto \pi_0(\theta) \prod_{i=1}^t p_Q(y_i | \theta, u_i), \quad u_{t+1} = d(\pi_t). \quad (13)$$

con u_i como configuración experimental, y_i como observación y $d(\pi_t)$ como regla de decisión. La calibración se transforma en diseño experimental adaptativo: la acción siguiente se elige a partir de la incertidumbre acumulada.

Teske et al. (2019) aplicaron estimación bayesiana y filtrado a la sintonización automatizada de qubits semiconductores. Duffield et al. (2023) reinterpretaron el aprendizaje de circuitos parametrizados como aproximación posterior e incorporaron una estimación MAP con prior de Laplace; la reducción resultante produjo circuitos más compactos y menos sensibles al ruido en la plataforma evaluada. Wiebe et al. (2015) emplearon aprendizaje bayesiano para identificación de Hamiltonianos. El criterio bayesiano también aparece en diseño metrológico (Kaubruegger et al., 2021), composición de kernels (Torabian & Krems, 2023), búsqueda de arquitecturas (Pirhooshyaran & Terlaky, 2021) y síntesis estocástica de programas (Y. Xiao et al., 2021). Otros desarrollos relacionados abordaron caracterización diferenciable de dispositivos y simulación digital-analógica de Hamiltonianos de dos cuerpos (Craig et al., 2024; Garcia-De-Andoin et al., 2024).

Aunque esta familia es menos numerosa, presenta una integración especialmente fuerte: la posterior describe el estado de conocimiento del dispositivo y determina la acción



experimental siguiente. La frontera entre inferencia, optimización y control se vuelve continua, lo que ofrece un campo natural para la ingeniería matemática y el diseño secuencial bajo incertidumbre.

3.2.8. Integración de las tres dimensiones

La integración entre inferencia bayesiana, inteligencia artificial y computación cuántica no corresponde a una arquitectura única. La taxonomía multidimensional muestra una relación funcional: el componente bayesiano representa incertidumbre, actualiza una distribución o dirige una decisión secuencial; la tarea de IA establece qué debe optimizarse, inferirse, predecirse, clasificarse, generarse o seleccionarse; y el componente cuántico ejecuta, aproxima o representa una operación delimitada. Esta separación evita considerar suficiente la aparición simultánea de vocabulario de las tres áreas y permite identificar la contribución específica de cada componente dentro del método.

La arquitectura híbrida clásico-cuántica concentró 49 de los 66 artículos (74,2 %). Siete trabajos utilizaron una arquitectura clasificada como cuántica (10,6 %), tres se apoyaron principalmente en simulación cuántica (4,5 %) y tres en modelos probabilísticos inspirados en computación cuántica (4,5 %). Los cuatro artículos restantes se distribuyeron entre control clásico de hardware cuántico, optimización clásica de dinámica cuántica, arquitectura clásica inspirada en computación cuántica y simulación clásica de un sistema cuántico. El patrón dominante es, por tanto, una división explícita del cálculo: el recurso cuántico produce una estimación, muestra, kernel, energía o probabilidad, mientras que el componente clásico actualiza parámetros, controla la convergencia y decide la acción siguiente.

En el acoplamiento híbrido más frecuente, el procesador cuántico evalúa una cantidad dependiente de parámetros y el procesador clásico decide la siguiente configuración. Esta estructura aparece en optimización bayesiana de circuitos, VQE, QAOA, calibración y control. En otras configuraciones, el circuito representa directamente una distribución probabilística; genera propuestas para una cadena de Markov; construye un kernel para regresión o clasificación; o explora un paisaje energético QUBO/Ising. En todos los casos, la integración debe describirse por la operación matemática y por la dirección del flujo de información, no solo por el nombre del algoritmo.

Las combinaciones más frecuentes fueron la optimización bayesiana de modelos cuánticos, con doce artículos (18,2 %); la representación cuántica de modelos probabilísticos, con siete



(10,6 %); y la aceleración cuántica de inferencia bayesiana, con seis (9,1 %). Las restantes se distribuyeron entre recocido para aprendizaje probabilístico, MCMC asistido, regresión gaussiana cuántica, aprendizaje bayesiano de dispositivos y aprendizaje de estructura de redes mediante QAOA (Soloviev et al., 2023).. Un conjunto periférico abordó pronóstico ambiental y energético, control predictivo, redes de comunicaciones, optimización estructural y seguridad o desarrollo rural (Hong et al., 2024; Dong & Ding, 2025; Ajagekar & You, 2025; Taghavi & Vahidi, 2025; Mala et al., 2025; Zhang et al., 2025; Kim & Wang, 2025; Vellimalaipattinam Thiruvengkatasamy et al., 2025). Estos trabajos amplían el alcance temático, pero presentan configuraciones heterogéneas y evidencia principalmente simulada; por ello, se interpretan como aplicaciones emergentes y no como una familia consolidada. Desde la perspectiva matemática, la integración de las tres dimensiones puede leerse como una composición de operadores. Bayes define el estado de conocimiento y la regla de actualización; la IA transforma ese estado en una decisión, predicción o búsqueda; y la subrutina cuántica modifica una evaluación, representación o transición. La contribución no reside necesariamente en sustituir todo el cálculo clásico, sino en alterar un cuello de botella bien identificado y conservar una métrica con la cual evaluar su efecto sobre error, costo, incertidumbre o convergencia.

3.2.9. Síntesis transversal de RQ1-RQ4

Las familias muestran que Bayes cumple al menos cinco funciones: selección secuencial de evaluaciones, representación de dependencias, aproximación posterior, construcción de propuestas de muestreo y aprendizaje de parámetros. La IA aporta tareas de optimización, inferencia, predicción, clasificación, generación y decisión; el componente cuántico estima observables, codifica distribuciones, construye kernels, explora energías o genera movimientos. La combinación de estas funciones, y no la presencia aislada de cada término, constituye el criterio de integración sustantiva adoptado por la revisión.

La integración más desarrollada no es aquella donde el mayor número de operaciones es cuántico, sino donde existe una división funcional coherente y una métrica que permite evaluar la interacción. Este resultado explica el predominio híbrido y desplaza la pregunta desde “¿cuánto del algoritmo es cuántico?” hacia “¿qué operación modifica el recurso cuántico y qué mejora puede atribuirse a esa modificación después de considerar el flujo completo?”.



3.3. Aplicaciones financieras, económicas y macroeconómicas (RQ5)

RQ5 examina las aplicaciones financieras, económicas y macroeconómicas sin imponer estos dominios como filtro de inclusión. De los 66 artículos, dos presentan una aplicación directa (3,0 %), siete contienen relevancia indirecta (10,6 %), once muestran transferibilidad potencial (16,7 %) y 46 no aportan una relación financiera o económica verificable (69,7 %). La categoría directa exige que el problema, los datos o la validación pertenezcan al dominio; la relevancia indirecta corresponde a menciones o aplicaciones operativo-económicas próximas; y la categoría potencial identifica métodos que podrían transferirse, pero cuya aplicación financiera o económica no fue evaluada en el artículo.

Tabla 3.

Relevancia financiera, económica y macroeconómica del corpus incluido

Categoría	n	Porcent aje	Criterio de clasificación
Directa	2	3,0 %	Problema, datos o validación del dominio financiero o económico
Indirecta	7	10,6 %	Mención o aplicación operativo-económica próxima
Potencial	11	16,7 %	Estructura transferible sin validación en el dominio
Sin relación verificable	46	69,7 %	No se encontró evidencia financiera o económica suficiente

Nota. La relevancia financiera y económica se clasificó según su aplicación directa, proximidad temática y transferibilidad potencial. Elaboración propia.

3.3.1. Demanda residencial y computación bayesiana cuántica

La primera aplicación directa estudia la demanda residencial de corto plazo mediante registros de visitas a viviendas ofrecidas en Chicago entre 2011 y 2013. Polson et al. (2023, pp. 11-12) combinan una dinámica autorregresiva, covariables y términos de Fourier para representar ciclos de distinta periodicidad. La especificación puede escribirse como

$$y_t = bt + \phi y_{t-1} + \beta^T x_t + \sum_{j=1}^K \left[a_j \sin \left(\frac{2\pi jt}{52.18} \right) + b_j \cos \left(\frac{2\pi jt}{52.18} \right) \right] + \eta_t. \quad (14)$$



Aquí, y_t representa la demanda observada, x_t contiene los predictores externos, ϕ recoge la persistencia temporal y los pares (a_j, b_j) describen las componentes cíclicas. La formulación es matemáticamente relevante porque separa tendencia, memoria, covariables y periodicidad, elementos habituales en el análisis de series económicas de alta frecuencia. El artículo vincula la estimación de los coeficientes de Fourier con la transformada cuántica de Fourier. Para un estado $|x\rangle$ de dimensión N , esta operación se expresa como

$$\text{QFT}_N |x\rangle = \frac{1}{\sqrt{N}} \sum_{k=0}^{N-1} e^{2\pi i x k / N} |k\rangle. \quad (15)$$

La transformada representa las amplitudes del estado en una base de frecuencias y proporciona el puente formal entre el componente espectral del modelo y la subrutina cuántica. La contribución es pertinente para la economía de la vivienda porque el objeto empírico es la actividad del mercado residencial y la salida es un pronóstico de demanda. No obstante, el alcance cuántico debe interpretarse con cautela: el trabajo desarrolla la formulación y la aplica a los datos de vivienda, pero no documenta una ejecución en hardware cuántico para esta aplicación (Polson et al., 2023, pp. 11-13). En consecuencia, el resultado debe entenderse como una demostración matemática y computacional de aplicabilidad, no como evidencia de ventaja operacional frente a modelos econométricos o de aprendizaje clásicos.

3.3.2. Redes bayesianas financieras representadas mediante circuitos

La segunda aplicación directa representa redes bayesianas financieras mediante circuitos cuánticos. Borujeni et al. (2021, pp. 1-5, 31, 35) estudian tres casos: predicción de acciones de una empresa petrolera, evaluación del riesgo de liquidez bancaria y clasificación de quiebra. Para una red dirigida acíclica con variables $X_1, \dots, X_m$, la distribución conjunta conserva la factorización

$$p(x_1, \dots, x_m) = \prod_{i=1}^m p(x_i | x_{\text{pa}(i)}). \quad (16)$$

En esta expresión, $\text{pa}(i)$ identifica los padres de X_i . El circuito no sustituye la estructura probabilística de la red: codifica las probabilidades marginales de los nodos raíz mediante rotaciones y las probabilidades condicionales mediante rotaciones controladas. En el caso de riesgo de liquidez, la red contiene diez nodos y el circuito utiliza doce qubits, incluidos dos qubits auxiliares para nodos con varios padres. En el clasificador de quiebra se consideran razones contables, resultados recientes, capitalización relativa y rentabilidad bursátil



(Borujeni et al., 2021, pp. 31, 35).

Los circuitos se ejecutaron en el simulador Qiskit con 8192 mediciones por repetición y diez repeticiones. Los autores construyeron intervalos de confianza del 95 % para las probabilidades marginales y los compararon con una implementación clásica; las probabilidades clásicas quedaron dentro de los intervalos obtenidos mediante simulación (Borujeni et al., 2021, p. 45). El resultado valida la representación probabilística y la coherencia de las consultas. Sin embargo, no demuestra aceleración, reducción de costo ni desempeño en hardware real. Desde la matemática financiera, el interés reside en conservar las dependencias condicionales y representar escenarios de riesgo bajo incertidumbre; desde la evaluación computacional, permanece abierta la pregunta de si la codificación aporta una ventaja cuando se consideran qubits auxiliares, profundidad y costo de muestreo.

3.3.3. Relevancia indirecta y transferibilidad potencial

Los siete artículos con relevancia indirecta no constituyen aplicaciones financieras del método estudiado. Algunos mencionan las finanzas como posible área de uso de algoritmos cuánticos, mientras que otros trabajan en gestión energética, diseño de baterías, mantenimiento de infraestructura o demanda de transporte. Wang y Zhang (2024, pp. 1, 14), por ejemplo, citan antecedentes sobre predicción bursátil y riesgo de liquidez, pero validan su propuesta con imágenes. Wiebe y Granade (2017, p. 21) mencionan el modelado financiero como un problema temporal, aunque advierten que su procedimiento no se aplica directamente a ese tipo de datos.

Los once artículos clasificados como potenciales ofrecen estructuras transferibles, entre ellas inferencia en redes bayesianas, MCMC, optimización, agrupamiento y decisión bajo incertidumbre. Oliveira y Barbosa (2023, p. 14) formalizan acciones condicionadas por evidencia, y Fathallah et al. (2024, pp. 6-7) estudian consultas aproximadas en redes bayesianas cuánticas. Estas herramientas podrían relacionarse con asignación de cartera, riesgo de crédito, detección de regímenes o inferencia de estados latentes. Sin embargo, esa relación es una inferencia de la síntesis y no un resultado empírico de los artículos. Presentarla como aplicación validada inflaría artificialmente la madurez del campo.

3.3.4. Brecha macroeconómica

No se identificó una aplicación macroeconómica directa. El corpus no contiene ejercicios validados sobre modelos macroeconómicos estructurales, política monetaria, ciclos



económicos, inflación, pronóstico agregado ni inferencia de estados macroeconómicos latentes. El resultado principal de RQ5 es, por tanto, la distancia entre la capacidad metodológica del campo y su validación en finanzas, economía financiera y macroeconomía. Una agenda aplicada coherente con las familias revisadas podría incluir modelos bayesianos de espacio de estados, MCMC para posteriores de alta dimensión, optimización bajo incertidumbre, detección de cambios de régimen y pronóstico probabilístico. Para que una aplicación económica sea verificable debe especificar el objeto incierto, la información disponible, la decisión y la función de pérdida. En términos bayesianos, la decisión óptima puede expresarse como:

$$a^*(\mathcal{D}) = \underset{a \in \mathcal{A}}{\operatorname{argmin}} \int \ell(a, \theta) p(\theta | \mathcal{D}) d\theta. \quad (17)$$

La operación cuántica adquiere relevancia aplicada solo si modifica de forma medible el cálculo de la posterior, la evaluación de la pérdida o la búsqueda de la decisión. La validación debe ser temporal y fuera de muestra, incluir sensibilidad a los priors, estabilidad ante revisiones de datos, comparación con métodos econométricos sólidos y una contabilidad explícita del costo híbrido.

En síntesis, la evidencia aplicada es escasa y está limitada a vivienda, predicción bursátil, riesgo de liquidez y clasificación de quiebra. Los dos estudios directos muestran que las estructuras temporales y las dependencias financieras pueden formularse mediante herramientas Bayes-IA-cuánticas, pero sus resultados se mantienen principalmente en el nivel de representación y simulación. Las aplicaciones financieras, económicas y macroeconómicas deben considerarse una línea emergente de investigación y no un dominio consolidado.

3.4. Evidencia, validación y alcance de las mejoras (RQ6)

De los 66 artículos, 33 correspondieron principalmente a simulaciones (50,0 %), 19 incluyeron experimentos con hardware (28,8 %), siete fueron algoritmos teóricos, tres *benchmarks*, dos modelos matemáticos, uno un prototipo y uno un estudio de caso. La mitad del campo validado se apoya todavía en entornos simulados. La simulación permite verificar coherencia, sensibilidad y convergencia, pero no reproduce por completo decoherencia, errores de compuertas, colas de acceso ni variabilidad temporal del dispositivo.

La evidencia puede ordenarse en tres niveles. El primero es la viabilidad matemática: el



método está definido y produce resultados coherentes en análisis o simulación. El segundo es la viabilidad experimental: el flujo puede ejecutarse en un dispositivo real. El tercero es la mejora comparativa: el método híbrido supera o domina una línea base sólida bajo presupuestos equivalentes. Muchos artículos sostienen el primer nivel; una proporción menor alcanza el segundo; pocos demuestran el tercero de forma generalizable. El uso de hardware no es condición suficiente de ventaja, del mismo modo que una mejora en una instancia reducida no demuestra escalabilidad.

Diecisiete estudios utilizaron líneas base clásicas, doce recurrieron a benchmarks y once emplearon hardware como parte central de la validación. Los resultados más convincentes son específicos: mayor fidelidad de controles, reducción del presupuesto de mediciones, mejora de mezcla en cadenas de Markov, circuitos más compactos, mejor exploración de espacios discretos o desempeño comparable con una representación alternativa. La Tabla 4 resume casos que ilustran la diferencia entre formulación, validación y alcance de la mejora.

Tabla 4.

Estudios representativos, tipo de evidencia y alcance de los resultados

Estudio	Operación matemática	Validación	Resultado reportado	Interpretación de la revisión
Cortes et al. (2022)	Calibración con optimización bayesiana	Experimento fotónico	Convergencia rápida y fiable bajo pérdida y ruido de disparo	Eficiencia muestral operativa; no comparación de complejidad general
Finžgar et al. (2024)	Diseño de cronogramas de recocido	Simulación y procesador de átomos neutros	Fidelidades varios órdenes superiores en el modelo p-spin y mejora en instancias MIS	Mejora local dependiente del modelo y del protocolo



Estudio	Operación matemática	Validación	Resultado reportado	Interpretación de la revisión
Tamiya y Yamasaki (2022)	SGLBO para circuitos parametrizados	Simulación con ruido	Reducción drástica de shots, mayor precisión y robustez	Evidencia numérica; falta validación física directa
Duffield et al. (2023)	Aprendizaje bayesiano de circuitos	Quantinuum H1-2 y simulación	Circuitos reducidos más rápidos y menos ruidosos	Resultado de hardware específico con mecanismo interpretable
Layden et al. (2023)	MCMC con propuestas cuánticas	Procesador superconductor y simulación	Hardware: menos iteraciones; simulación: aceleración empírica entre cúbica y cuártica	Resultado fuerte, pero condicionado por distribución, propuesta y escala
Rapp y Roth (2024)	Proceso gaussiano con kernel cuántico	Benchmark sobre datos reales	Desempeño comparable al proceso gaussiano clásico	Valida funcionalidad y varianza posterior; no superioridad
Borujeni et al. (2021)	Redes bayesianas financieras en circuitos	Qiskit: 8192 shots × 10 repeticiones	Probabilidades clásicas dentro de intervalos del 95 %	Valida representación probabilística en simulación



Estudio	Operación matemática	Validación	Resultado reportado	Interpretación de la revisión
Polson et al. (2023)	Serie económica y transformada cuántica de Fourier	Formulación y caso computacional	Aplicación a demanda residencial de Chicago	Pertinencia económica directa; sin hardware ni ventaja comparativa

Nota. Se presentan estudios representativos según la operación matemática, el tipo de validación, los resultados y su interpretación crítica. MIS = conjunto independiente máximo; SGLBO = optimización bayesiana global-local estocástica. Elaboración propia.

Una comparación adecuada debe considerar el perfil de costo del flujo completo. Como la preparación, el tiempo clásico, las ejecuciones, los shots, la mitigación y el posprocesamiento pueden tener unidades diferentes, la representación más rigurosa es vectorial. Si se requiere un costo escalar, deben declararse las unidades, la normalización y los pesos utilizados (Cerezo et al., 2021; Endo et al., 2021; Preskill, 2018):

$$\mathbf{C} = (C_{\text{prep}}, C_{\text{cl}}, C_{\text{q}}, C_{\text{shots}}, C_{\text{mit}}, C_{\text{post}}), \quad C_{\mathbf{w}} = \mathbf{w}^T \mathbf{C}, \quad \mathbf{w} \geq \mathbf{0}. \quad (18)$$

El vector $\mathbf{C}$ reúne preparación y codificación, procesamiento clásico, ejecución cuántica, mediciones, mitigación y posprocesamiento. Cada componente debe reportarse en su unidad natural. La escalarización $C_{\mathbf{w}}$ solo es interpretable cuando los pesos o conversiones se declaran; en caso contrario, la comparación debe tratarse como un problema multiobjetivo. Un método puede requerir menos iteraciones y, aun así, presentar un costo mayor si cada iteración exige cientos de circuitos o miles de mediciones.

La misma precaución se aplica al error. Cuando las contribuciones pueden expresarse sobre una misma escala de pérdida, una cota conceptual es

$$\mathcal{E}_{\text{total}} \leq \mathcal{E}_{\text{modelo}} + \mathcal{E}_{\text{inferencia}} + \mathcal{E}_{\text{optimización}} + \mathcal{E}_{\text{shots}} + \mathcal{E}_{\text{ruido}} + \mathcal{E}_{\text{transferencia}}. \quad (19)$$

Los términos no siempre son independientes ni estrictamente aditivos, pero la descomposición impide atribuir al recurso cuántico una diferencia que puede originarse en el modelo, el optimizador, el muestreo o el hardware. Una precisión final equivalente puede ser relevante si reduce mediciones o mejora la cuantificación de incertidumbre; no debe



denominarse ventaja general sin analizar costo, error y escalamiento bajo una misma precisión objetivo.

La evidencia actual apoya ventajas locales y descomposiciones híbridas útiles. No permite afirmar una ventaja cuántica general, escalable e independiente del problema. El criterio de evaluación debe desplazarse desde la presencia de un componente cuántico hacia las condiciones bajo las cuales se produce una mejora reproducible en precisión, costo, robustez, incertidumbre o decisión.

3.5. Madurez, reproducibilidad y mapa de vacíos (RQ7-RQ8)

La madurez fue intermedia en 34 artículos (51,5 %), avanzada en 19 (28,8 %), emergente en 11 (16,7 %) e incipiente en dos (3,0 %). Los estudios avanzados combinaron formulación clara con hardware, *benchmarks*, líneas base o casos aplicados; sin embargo, la madurez no eliminó las carencias de reproducibilidad. Solo 20 artículos alcanzaron la puntuación superior en detalle metodológico, 19 en fortaleza de validación y 14 en reproducibilidad.

Veinticinco artículos reportaron código (37,9 %) y 41 no lo hicieron. Treinta y uno ofrecieron datos parciales, 31 no reportaron datos y en cuatro la categoría no aplicaba. La transparencia de parámetros fue media en los 66 artículos; ninguno alcanzó la categoría alta utilizada por la matriz. Estas carencias son importantes porque el desempeño depende de semillas, particiones, número de *shots*, arquitectura, profundidad, optimizador, simulador, dispositivo y mitigación.

La cobertura mínima de comparabilidad también fue limitada: 17 artículos (25,8 %) utilizaron una línea base clásica, 11 (16,7 %) hicieron del hardware el eje principal de validación y 14 (21,2 %) alcanzaron la categoría superior de reproducibilidad. Estas proporciones no son puntuaciones equivalentes, pero muestran que la formulación matemática se reporta con mayor frecuencia que las condiciones necesarias para verificarla. Para el artículo j , la reproducibilidad se representó mediante el perfil

$$\mathbf{r}_j = (c_j, d_j, a_j, p_j). \quad (20)$$

con disponibilidad de código c_j , datos d_j , activos reproducibles a_j y transparencia de parámetros p_j . El perfil evita reducir la reproducibilidad a una única declaración binaria. Un estudio puede publicar código sin datos, describir el dispositivo sin semillas o proporcionar datos sin la configuración necesaria para reproducir la ejecución.



El mapa de vacíos no constituye una medición independiente. Retoma las variables de aplicación, evidencia, validación, madurez y relevancia financiera, junto con las limitaciones extraídas. Para cada artículo j , la síntesis original definió

$$\eta_j = (D_j, E_j, V_j, M_j, F_j), \quad \Gamma_j = g(\eta_j, L_j), \quad \Gamma_j \in \mathcal{G}, \quad A_j \in \mathcal{A}. \quad (21)$$

Aquí, D representa dominio, E tipo de evidencia, V validación, M madurez, F relevancia financiera o económica y L limitaciones. La regla g asigna un vacío principal Γ y A identifica una prioridad de agenda. La asignación fue exclusiva para producir conteos que sumaran los 66 artículos, aunque cada estudio pudiera presentar más de una limitación.

$$N_{\Gamma}(g) = \sum_{j=1}^{66} \mathbf{1}\{\Gamma_j = g\}, \quad N_{\Gamma,A}(g, a) = \sum_{j=1}^{66} \mathbf{1}\{\Gamma_j = g, A_j = a\}. \quad (22)$$

La formalización es descriptiva: localiza la siguiente limitación metodológica que debe resolverse, pero no demuestra que la madurez cause un vacío determinado. La Tabla 5 resume la distribución resultante.

Tabla 5.

Mapa de evidencia y vacíos de investigación (RQ8)

Vacío principal	n	Porcentaje	Perfil de madurez	Siguiente prioridad
Validación externa y reproducibilidad	33	50,0 %	32 intermedios; 1 avanzado	Evaluación externa, comparación homogénea y materiales reproducibles
Escalabilidad y transferibilidad	19	28,8 %	18 avanzados; 1 intermedio	Costo total, crecimiento con dimensión y transferencia de dominio
Hardware y validación de dominio	12	18,2 %	11 emergentes; 1 intermedio	Dispositivo real, benchmark comparable o datos propios del dominio



Vacío principal	n	Porcentaje	Perfil de madurez	Siguiente prioridad
Brecha entre teoría y validación	2	3,0 %	2 incipientes	Implementación o simulación antes de afirmar escala o aplicación

Nota. Los vacíos se clasificaron según su frecuencia, nivel de madurez y prioridad para futuras investigaciones. Elaboración propia.

La mitad del corpus requiere fortalecer la validación externa y la reproducibilidad; cerca de tres décimas partes debe demostrar que la mejora se conserva al aumentar la dimensión o cambiar de dominio; y alrededor de una quinta parte todavía necesita pasar de teoría o simulación a hardware o aplicación. La agenda exclusiva derivada del mapa asignó 39 artículos a validación (59,1 %), 18 a finanzas y economía (27,3 %) y nueve a desarrollo metodológico (13,6 %). Estas prioridades no equivalen a evidencia existente: indican dónde una nueva validación sería más informativa.

La lectura conjunta de RQ7 y RQ8 muestra que el siguiente avance no depende únicamente de proponer un nuevo circuito. Se requieren instancias comunes, líneas base optimizadas, reportes de costo y error, pruebas de escala y materiales reproducibles. En finanzas y economía, la prioridad no es extrapolar resultados de otros dominios, sino construir evidencia aplicada.

4. DISCUSIÓN

4.1. Integración funcional de Bayes, inteligencia artificial y computación cuántica

La síntesis muestra que la intersección entre inferencia bayesiana, inteligencia artificial y computación cuántica no constituye un método único. Se trata de una arquitectura funcional en la que cada componente resuelve una parte distinta del problema: el componente bayesiano representa incertidumbre, actualiza información o dirige una decisión secuencial; la inteligencia artificial y el aprendizaje automático definen la tarea de optimización, inferencia, predicción, clasificación, generación o muestreo; y el componente cuántico ejecuta una operación específica de representación, estimación, búsqueda o dinámica. Esta separación funcional es coherente con el predominio de las arquitecturas híbridas clásico-



cuánticas, presentes en 49 de los 66 artículos (74,2 %), y con la frecuencia de la optimización bayesiana, identificada en 27 estudios (40,9 %).

El acoplamiento más frecuente puede representarse mediante dos operadores. Sea Q la operación cuántica que produce una estimación $\hat{m}_t$ bajo una configuración θ_t , y sea B la actualización bayesiana o regla de decisión clásica. El ciclo adopta la forma

$$\hat{m}_t = Q(\theta_t; S_t, \xi_t), \quad \theta_{t+1} = B(\mathcal{D}_t, \hat{m}_t, \hat{v}_t), \quad \mathcal{D}_{t+1} = \mathcal{D}_t \cup \{(\theta_t, \hat{m}_t, \hat{v}_t)\}.$$

Aquí, S_t es el número de mediciones, ξ_t representa las condiciones de ruido y $\hat{v}_t$ cuantifica la incertidumbre asociada con la evaluación. Esta expresión es una formalización de la síntesis y no una ecuación atribuida literalmente a un artículo individual. Su estructura aparece, por ejemplo, en VQE con optimización bayesiana, donde las mediciones de energía actualizan un modelo sustituto (Sorourifar et al., 2025, pp. 4-5), y en la calibración de redes cuánticas, donde la configuración siguiente depende de observaciones físicas previas (Cortes et al., 2022, pp. 4-6).

La consecuencia metodológica es que el rendimiento depende de la composición $B \circ Q$ y no solamente del circuito. Una estimación basada en pocas mediciones puede presentar una varianza elevada; un modelo sustituto mal especificado puede seleccionar parámetros inadecuados; y una función de adquisición puede distribuir el presupuesto en regiones poco informativas. Por ello, los trabajos de optimización con pocos *shots* muestran que el presupuesto de medición forma parte del problema de aprendizaje (Sorourifar et al., 2025, pp. 1, 4-5), mientras que los procesos gaussianos cuánticos muestran que la utilidad del sustituto depende de conservar información predictiva sobre media y varianza (Rapp & Roth, 2024, pp. 2-4). La contribución no puede atribuirse exclusivamente a Bayes, a la IA o al procesador cuántico cuando el resultado surge de su acoplamiento.

Una segunda arquitectura invierte la dirección del flujo. En lugar de emplear Bayes para controlar una rutina cuántica, utiliza una operación cuántica para representar o aproximar una cantidad bayesiana. Si $p(\theta, \mathcal{D})$ es la distribución conjunta, el objetivo inferencial continúa siendo

$$p(\theta \mid \mathcal{D}) = \frac{p(\theta, \mathcal{D})}{\int p(\vartheta, \mathcal{D}) d\vartheta}, \quad \mathbb{E}[g(\theta) \mid \mathcal{D}] = \int g(\theta) p(\theta \mid \mathcal{D}) d\theta.$$

El componente cuántico modifica la representación o el cálculo de estas cantidades, pero no cambia el significado probabilístico de la posterior. En redes bayesianas cuánticas, las



probabilidades condicionales se codifican mediante rotaciones y las consultas se aproximan por medición (Borujeni et al., 2021, pp. 5-8; Fathallah et al., 2024, pp. 3-7). En MCMC mejorado cuánticamente, la evolución cuántica genera una propuesta y la aceptación clásica conserva la distribución objetivo (Layden et al., 2023, pp. 2-3). Esta continuidad matemática permite comparar los métodos híbridos y clásicos mediante la misma posterior, la misma esperanza o la misma probabilidad marginal.

La integración funcional presenta, por tanto, dos direcciones principales: Bayes puede administrar una operación cuántica costosa, o una rutina cuántica puede aproximar una operación inferencial. La primera predomina en optimización, calibración y control; la segunda aparece en inferencia posterior, representación probabilística y muestreo. Separar ambas direcciones evita tratar como equivalentes procedimientos que requieren garantías matemáticas y criterios de validación diferentes.

4.2. Alcance de la evidencia sobre ventaja cuántica

Los resultados no sustentan una afirmación general de ventaja cuántica. Diecinueve artículos se clasificaron como experimentos con hardware, pero solo once utilizaron la validación en hardware como diseño principal. Treinta y tres implementaciones fueron simulaciones y 22 estudios validaron exclusivamente mediante simulación. Una reducción asintótica de complejidad, una mejora observada en un simulador y un resultado obtenido en un dispositivo físico responden preguntas distintas y no deben presentarse como niveles equivalentes de evidencia.

Una afirmación completa de ventaja exige comparar el costo total bajo una precisión común. Sea $C_C(n, \varepsilon)$ el costo clásico para un problema de tamaño n y error máximo ε . El costo del procedimiento híbrido puede organizarse como

$$C_{HQ}(n, \varepsilon) = C_{\text{prep}} + C_{\text{train}} + N_Q(n, \varepsilon)(C_{\text{exec}} + C_{\text{meas}} + C_{\text{io}}) + C_{\text{post}}.$$

Esta expresión incluye preparación de datos, entrenamiento clásico, número de consultas cuánticas, ejecución, medición, comunicación y posprocesamiento. Una ventaja operacional requiere, para tamaños y condiciones relevantes,

$$C_{HQ}(n, \varepsilon) < C_C(n, \varepsilon),$$



además de conservar la calidad estadística de la salida. La desigualdad funciona como condición de interpretación derivada de la síntesis; no representa un resultado demostrado por el conjunto del corpus.

La precisión también debe compararse bajo el mismo presupuesto. Si m es la cantidad objetivo y $\hat{m}_Q, \hat{m}_C$ son estimadores cuántico y clásico, respectivamente, la comparación debe declarar

$$\text{MSE}(\hat{m}_r) = \text{Bias}(\hat{m}_r)^2 + \text{Var}(\hat{m}_r), \quad r \in \{Q, C\},$$

junto con el número de mediciones, el tiempo, las repeticiones y las condiciones de ruido. El estudio de redes bayesianas financieras satisface parcialmente esta exigencia al repetir diez veces circuitos de 8192 mediciones y contrastar intervalos de confianza del 95 % con probabilidades clásicas (Borujeni et al., 2021, p. 45). Esa validación demuestra concordancia probabilística en simulación, pero no demuestra reducción de costo ni ventaja en hardware real.

Los artículos teóricos aportan mecanismos y condiciones particulares que justifican continuar la investigación. La inferencia variacional cuántica analiza cuándo la dinámica cuántica puede modificar la exploración de la aproximación variacional (Miyahara & Roychowdhury, 2023, pp. 2-4), mientras que el MCMC mejorado cuánticamente estudia propuestas y propiedades de mezcla sobre una distribución objetivo (Layden et al., 2023, pp. 2-3). Estos resultados no deben extrapolarse a una superioridad universal. La evidencia más sólida del corpus corresponde a mejoras locales: reducción del presupuesto de medición, mejor fidelidad en protocolos concretos, convergencia en menos iteraciones o equivalencia con líneas base clásicas bajo representaciones diferentes.

4.3. Implicaciones y límites de la síntesis

La evidencia es suficiente para identificar familias metodológicas, implementaciones y aplicaciones concretas, pero no para declarar una ventaja cuántica general ni una línea macroeconómica consolidada. Esta conclusión se restringe al corpus construido con Scopus y Web of Science para 2010-2025. Veinticuatro textos buscados no pudieron recuperarse y permanecen como limitación de acceso; su ausencia puede afectar la cobertura de métodos o aplicaciones.

La asignación de cada artículo a una familia principal, una tarea de IA o un vacío de



investigación simplifica contribuciones que pueden cumplir varias funciones. Los conteos deben leerse como una distribución de categorías analíticas principales en los 66 artículos, no como el número total de técnicas o limitaciones presentes. De modo similar, la bibliometría describe la estructura del campo recuperado, mientras que las conclusiones sobre integración, evidencia, madurez y vacíos proceden de la lectura de texto completo.

La interpretación más sólida es que la investigación Bayes-IA-cuántica se encuentra en una etapa de integración metodológica con evidencia heterogénea. Sus avances principales se concentran en optimización secuencial, inferencia probabilística, representación de modelos, muestreo y aprendizaje de sistemas cuánticos. Sus restricciones principales se relacionan con costo total, escalabilidad, validación externa, disponibilidad de materiales reproducibles y evaluación sobre dominios económicos explícitos. Estas restricciones enlazan los resultados con la agenda futura.

5. AGENDA FUTURA DE INVESTIGACIÓN

La agenda se deriva de los vacíos asignados en RQ8 y de los límites anteriores. Su objetivo es organizar las condiciones necesarias para avanzar desde formulaciones o demostraciones aisladas hacia evidencia comparable, reproducible y aplicable. La prioridad cuantitativa se concentra en validación, con 39 artículos (59,1 %); finanzas y economía, con 18 (27,3 %); y desarrollo metodológico, con nueve (13,6 %). Estas categorías no describen evidencia ya alcanzada, sino el frente principal de trabajo asignado a cada estudio.

5.1. Validación comparable, costo y escalabilidad

La validación exige que el procedimiento clásico y el híbrido resuelvan el mismo problema bajo condiciones equivalentes. Deben declararse líneas base explícitas, particiones comunes, presupuestos comparables y métricas definidas antes del experimento. Un benchmark reproducible puede representarse mediante

$$B=(D,P,l,M,H,S,\epsilon),$$

donde D es el conjunto de datos o instancias, P el protocolo de partición y preprocesamiento, l la función de pérdida, M las métricas, H el hardware o simulador, S el presupuesto de recursos y ϵ la tolerancia numérica. Esta tupla es una propuesta de la síntesis. Una diferencia puede atribuirse al método solo cuando ambos procedimientos comparten D, P, l y M, y



cuando S registra de forma comparable tiempo, consultas, mediciones, memoria y costo de entrenamiento.

El efecto debe reportarse con incertidumbre. Si $m_Q^{(r)}$ y $m_C^{(r)}$ son las métricas obtenidas en la repetición r , la diferencia media y su error estándar pueden escribirse como $\Delta \approx 1/R \sum_{r=1}^R (m_Q^{(r)} - m_C^{(r)})$, $(SE)(\Delta) = \sqrt{((Var)(m_Q - m_C))/R}$.

El signo favorable depende de la métrica: una pérdida menor y una utilidad mayor requieren convenciones distintas. El reporte debe incluir el número de repeticiones, semillas, intervalos, reglas de detención y todos los intentos ejecutados.

La escalabilidad debe estudiarse al aumentar el tamaño del problema, el número de qubits, la profundidad, las mediciones y el ruido. Para un circuito con q qubits, profundidad d , S mediciones por evaluación y N_Q evaluaciones, el tiempo observado puede desagregarse como

$$T_{HQ} = T_{prep} + T_{train} + N_Q [T_{queue} + T_{exec}(q, d) + T_{meas}(S) + T_{io}] + T_{post}.$$

Esta descomposición evita comparar solamente el tiempo interno del circuito con el tiempo total del algoritmo clásico. El reporte debe incluir número de parámetros, conectividad, descomposición de compuertas, tasas de error y estrategia de mitigación. En optimización bayesiana con VQE, el número de shots y el costo de consultar la energía afectan directamente el aprendizaje (Sorourifar et al., 2025, pp. 1, 4-5). En MCMC mejorado cuánticamente, además deben medirse mezcla, autocorrelación y costo por muestra efectiva (Layden et al., 2023, pp. 2-3).

Para métodos de muestreo, si ρ_k es la autocorrelación en el rezago k , el tamaño efectivo de muestra y el costo por muestra efectiva pueden aproximarse mediante

$$ESS \approx S / (1 + 2 \sum_{k=1}^K \rho_k), \quad C_{efectivo} = T_{HQ} / ESS.$$

Una reducción de autocorrelación no constituye una mejora neta si la preparación, las mediciones o la comunicación eliminan el beneficio.

5.2. Descomposición del error e inferencia bayesiana

En una arquitectura Bayes-IA-cuántica intervienen aproximación estadística, inferencia, optimización, medición, ruido físico y transferencia de dominio. Sin una descomposición, una mejora en un componente puede quedar oculta o ser anulada por otro. Como esquema analítico, el error puede organizarse mediante

$$E_{total} \leq E_{modelo} + E_{inferencia} + E_{optimización} + E_{shots} + E_{ruido} + E_{transferencia}.$$



La desigualdad no se presenta como una cota demostrada por el corpus. Define componentes que deben medirse o acotarse: especificación y representación del modelo, aproximación posterior, convergencia de la optimización, variabilidad por mediciones finitas, desviación del dispositivo y cambio entre el dominio de desarrollo y el de aplicación. Los diseños de ablación deberían modificar un componente a la vez: *ansatz*, optimizador, número de mediciones y ruido en algoritmos variacionales; codificación, consulta y medición en redes bayesianas; y kernel, función de adquisición y presupuesto en optimización bayesiana (Cortes et al., 2022, pp. 4-6; He et al., 2024, pp. 2-4; Sorourifar et al., 2025, pp. 4-5).

La agenda metodológica conserva la relación bidireccional identificada en la revisión. Una dirección utiliza inferencia bayesiana para aprender parámetros de circuitos, Hamiltonianos o dispositivos; la otra emplea operaciones cuánticas para aproximar posteriores, evidencias o expectativas. Para el aprendizaje de sistemas cuánticos, un diseño secuencial puede expresarse como

$$p(\theta|y_{(1:t)}, u_{(1:t)}) \propto p(\theta) \prod_{i=1}^t p(y_i|\theta, u_i), \quad u_{(t+1)} = \arg \max_{u \in U} E[y|u, D_t] [I(\theta; y|u, D_t)].$$

En la segunda expresión, $u_{(t+1)}$ representa la configuración experimental que maximiza la información esperada. Los estudios sobre aprendizaje de Hamiltonianos y ajuste de qubits muestran la utilidad de actualizar parámetros a partir de observaciones del sistema (Teske et al., 2019, pp. 2-3; Wiebe et al., 2015, pp. 2-3).

Para inferencia acelerada, la prioridad es demostrar que la rutina cuántica aproxima la misma distribución objetivo y cuantificar el error introducido. Si p es la posterior exacta y q_Q la aproximación producida por el método, puede reportarse

$$KL(q_Q \| p) = \int q_Q(\theta) \log((q_Q(\theta))/p(\theta)) d\theta,$$

junto con errores sobre expectativas relevantes, calibración, sensibilidad al prior y convergencia. La inferencia variacional cuántica y los modelos generativos para inferencia bayesiana ofrecen estructuras para este programa (Miyahara & Roychowdhury, 2023, pp. 2-4; Ohno, 2023, pp. 3-4).

5.3. Finanzas, economía y macroeconomía

El programa financiero debe comenzar con problemas donde la incertidumbre y la decisión estén definidas de forma explícita. El corpus aporta evidencia directa en vivienda, predicción bursátil, riesgo de liquidez y quiebra, pero no permite ordenar los métodos por desempeño



económico. La agenda debe separar predicción, inferencia, optimización y decisión, porque cada tarea requiere pérdidas y validaciones diferentes.

Para predicción probabilística, el resultado es una distribución

$$p(y_{(t+h)}|D_t),$$

evaluada mediante calibración, cobertura, puntuaciones probabilísticas y desempeño fuera de muestra. Para clasificación de riesgo, debe especificarse una pérdida asimétrica $\lambda(a,y)$ y una regla de decisión

$$a^*(x) = \arg \min_{a \in A} \sum_y \lambda(a,y) p(y|x).$$

Para cartera o asignación de activos, la función objetivo debe incorporar retorno, riesgo, restricciones y costos de transacción. La representación cuántica de redes bayesianas para liquidez y quiebra constituye una aplicación inicial, pero su validación actual se basa en simulación y concordancia con probabilidades clásicas (Borujeni et al., 2021, pp. 31, 35, 45). La transferencia desde materiales, química o control exige una validación financiera propia que considere no estacionariedad, colas, cambios de régimen y filtración temporal.

La ausencia de aplicaciones macroeconómicas directas permite formular una agenda específica, no presentar evidencia inexistente. Como objeto mínimo de estudio, un modelo de espacio de estados puede escribirse como

$$s_t = F(s_{(t-1)}, \varepsilon_t; \theta), \quad y_t = G(s_t; \theta) + \eta_t.$$

$$p(\theta, s_{(1:T)} | y_{(1:T)}) \propto p(\theta) p(s_1 | \theta) \prod_{t=2}^T p(s_t | s_{(t-1)}, \theta) \prod_{t=1}^T p(y_t | s_t, \theta).$$

Esta formulación se propone como marco para la agenda y no procede de una aplicación macroeconómica del corpus. Permite identificar operaciones candidatas: optimización bayesiana para calibración costosa, MCMC para estados y parámetros, modelos sustitutos para funciones de verosimilitud y rutinas cuánticas para álgebra lineal, muestreo o evaluación de objetivos. Cada uso debe justificarse por un cuello de botella medido.

Cuando exista una política a_t , el criterio puede relacionarse con una pérdida económica intertemporal:

$$a_t^* = \arg \min_{a_t \in A} E[\sum_{h=0}^H \beta^h l(s_{(t+h)}, a_{(t+h)}) | D_t].$$

El método híbrido debe compararse con filtros, MCMC, métodos variacionales, optimización y simulación clásicos. Una mejora numérica solo será económicamente pertinente si conserva la inferencia, las restricciones y las decisiones bajo el mismo conjunto de información.

5.4. Reproducibilidad y niveles de avance



La reproducibilidad debe considerarse un requisito de diseño. El paquete reproducible incluye, cuando las licencias lo permiten, código, datos o generadores de instancias, parámetros, semillas, versiones de software, configuración del hardware o simulador, modelo de ruido y resultados por repetición. Para datos restringidos, debería incluir datos sintéticos o procedimientos que permitan verificar la implementación.

El avance puede organizarse en cinco niveles acumulativos:

- Definición: problema, supuestos, distribución objetivo y operación cuántica especificados.
- Verificación computacional: implementación mínima contrastada con casos de solución conocida.
- Comparación reproducible: líneas base, métricas, presupuestos y materiales disponibles.
- Validación física y de escala: hardware, ruido, tamaño creciente y costo total evaluados.
- Validación de dominio: datos reales, pérdida propia del dominio y evaluación externa o temporal.

Estos niveles no sustituyen la rúbrica de madurez utilizada en RQ7. Funcionan como una secuencia de trabajo para nuevas investigaciones. Un estudio debería avanzar solo cuando documenta el nivel anterior; ejecutar hardware sin una comparación reproducible no satisface por sí solo los niveles tercero y cuarto.

6. CONCLUSIÓN

La revisión confirma una integración matemática sustantiva entre inferencia bayesiana, IA y computación cuántica. RQ1-RQ4 muestran que Bayes aporta distribuciones, incertidumbre y reglas de decisión; la IA define tareas de optimización, inferencia, predicción, clasificación o muestreo; y el recurso cuántico interviene en operaciones delimitadas, como estimar observables, construir kernels, codificar distribuciones, generar propuestas o explorar funciones de energía. La arquitectura híbrida, presente en 49 artículos, es el patrón dominante y obliga a evaluar el sistema completo.

La optimización bayesiana es la línea más consolidada porque responde a una restricción concreta: las evaluaciones cuánticas son costosas y ruidosas. Los procesos gaussianos, las funciones de adquisición y las estrategias de pocos shots permiten asignar el presupuesto de medición de forma informada. La inferencia variacional, el MCMC asistido, las redes



bayesianas en circuitos y las formulaciones QUBO/Ising presentan fundamentos coherentes, pero su validación y escalamiento son menos uniformes.

RQ5 evidencia una brecha aplicada: solo dos estudios presentan aplicaciones financieras o económicas directas y ninguno valida una aplicación macroeconómica. Los casos de vivienda, riesgo de liquidez, predicción bursátil y quiebra demuestran que las estructuras pueden formularse sobre problemas del dominio, pero permanecen principalmente en representación, simulación o demostración computacional. La transferibilidad potencial no debe confundirse con evidencia aplicada.

RQ6 no sostiene una ventaja cuántica general. La mitad de las implementaciones son simulaciones; 19 trabajos incluyen hardware y solo 11 lo emplean como validación principal. Los resultados más sólidos son locales: mejores fidelidades, menos mediciones, mejor mezcla, circuitos más compactos o desempeño comparable. Su interpretación requiere líneas base fuertes, presupuestos equivalentes y una contabilidad conjunta de preparación, cálculo clásico, ejecución, muestreo, mitigación y posprocesamiento.

RQ7-RQ8 muestran una madurez principalmente intermedia y una reproducibilidad insuficiente. Los vacíos se concentran en validación externa, materiales reproducibles, escalabilidad, transferencia y validación de dominio. El problema no es la ausencia de formulaciones matemáticas, sino la dificultad para reconstruirlas, compararlas y comprobar que sus beneficios sobreviven al ruido, al crecimiento del problema y al cambio de aplicación.

La contribución matemática de la revisión es una formalización transversal, no un nuevo algoritmo cuántico. El ciclo híbrido explicita la dependencia entre incertidumbre, decisión, operación cuántica y actualización; el perfil ordinal conserva la distribución de la evidencia sin imponer una escala cardinal; y el criterio costo-error distingue mejora local, frontera de Pareto y dominancia bajo escala. Estas herramientas ofrecen una base para delimitar afirmaciones y diseñar comparaciones acumulativas.

REFERENCIAS BIBLIOGRÁFICAS

Abdelmalek, T., & Oudah, F. (2025). Quantum computing for solving Bayesian networks of bridges - method and recommendations. *Cogent Engineering*, 12(1), 2438806. <https://doi.org/10.1080/23311916.2024.2438806>



- Ajagekar, A., & You, F. (2025). Decarbonization of Building Operations with Adaptive Quantum Computing-Based Model Predictive Control. *Engineering*, 53, 90-103. <https://doi.org/10.1016/j.eng.2025.02.002>
- Aria, M., & Cuccurullo, C. (2017). bibliometrix: An R-tool for comprehensive science mapping analysis. *Journal of Informetrics*, 11, 959-975. <https://doi.org/10.1016/j.joi.2017.08.007>
- Benítez-Buenache, A., & Portell-Montserrat, Q. (2025). Bayesian Parameterized Quantum Circuit Optimization (BPQCO): a task and hardware-dependent approach. *Quantum Machine Intelligence*, 7(2), 85. <https://doi.org/10.1007/s42484-025-00308-x>
- Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., & Lloyd, S. (2017). Quantum machine learning. *Nature*, 549, 195-202. <https://doi.org/10.1038/nature23474>
- Borujeni, S. E., Nannapaneni, S., Nguyen, N. H., Behrman, E. C., & Steck, J. E. (2021). Quantum circuit representation of Bayesian networks. *Expert Systems with Applications*, 176, 114768. <https://doi.org/10.1016/j.eswa.2021.114768>
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S., Fujii, K., McClean, J. R., Mitarai, K., Yuan, X., Cincio, L., & Coles, P. J. (2021). Variational quantum algorithms. *Nature Reviews Physics*, 3, 625-644. <https://doi.org/10.1038/s42254-021-00348-9>
- Cheng, L. X., Chen, Y. Q., Zhang, S. X., & Zhang, S. Y. (2024). Quantum approximate optimization via learning-based adaptive optimization. *Communications Physics*, 7(1), 83. <https://doi.org/10.1038/s42005-024-01577-x>
- Ciavarella, A. N., & Chernyshev, I. A. (2022). Preparation of the SU(3) lattice Yang-Mills vacuum with variational quantum methods. *Physical Review D*, 105(7), 074504. <https://doi.org/10.1103/physrevd.105.074504>
- Cortes, C. L., Lefebvre, P., Lauk, N., Davis, M. J., Sinclair, N., Gray, S. K., & Oblak, D. (2022). Sample-Efficient Adaptive Calibration of Quantum Networks Using



- Bayesian Optimization. *Physical Review Applied*, 17(3), 034067. <https://doi.org/10.1103/physrevapplied.17.034067>
- Craig, D. L., Ares, N., & Gauger, E. M. (2024). Differentiable master equation solver for quantum device characterization. *Physical Review Research*, 6(4), 043175. <https://doi.org/10.1103/physrevresearch.6.043175>
- Dai, J., & Krems, R. V. (2022). Quantum Gaussian process model of potential energy surface for a polyatomic molecule. *Journal of Chemical Physics*, 156(18), 184802. <https://doi.org/10.1063/5.0088821>
- Dam, T. J. van, Neumann, N. M. P., Phillipson, F., & Berg, H. van den. (2020). Hybrid Helmholtz machines: a gate-based quantum circuit implementation. *Quantum Information Processing*, 19(6), 174. <https://doi.org/10.1007/s11128-020-02660-2>
- Dixit, V., Selvarajan, R., Alam, M. A., Humble, T. S., & Kais, S. (2021). Training Restricted Boltzmann Machines With a D-Wave Quantum Annealer. *Frontiers in Physics*, 9, 589626. <https://doi.org/10.3389/fphy.2021.589626>
- Doi, M., Nakao, Y., Tanaka, T., Sako, M., & Ohzeki, M. (2023). Exploration of new chemical materials using black-box optimization with the D-wave quantum annealer. *Frontiers in Computer Science*, 5, 1286226. <https://doi.org/10.3389/fcomp.2023.1286226>
- Dong, Y., & Ding, H. (2025). Bayesian optimization of hybrid quantum LSTM in a mixed model for precipitation forecasting. *Machine Learning: Science and Technology*, 6(1), 015065. <https://doi.org/10.1088/2632-2153/adbbad>
- Du, Y., Hsieh, M. H., Liu, T., & Tao, D. (2020). Expressive power of parametrized quantum circuits. *Physical Review Research*, 2(3), 033125. <https://doi.org/10.1103/physrevresearch.2.033125>
- Duffield, S., Benedetti, M., & Rosenkranz, M. (2023). Bayesian learning of parameterised quantum circuits. *Machine Learning: Science and Technology*, 4(2), 025007. <https://doi.org/10.1088/2632-2153/acc8b7>
- Endo, S., Cai, Z., Benjamin, S. C., & Yuan, X. (2021). Hybrid quantum-classical algorithms and quantum error mitigation. *Journal of the Physical Society of Japan*, 90(3), 032001. <https://doi.org/10.7566/JPSJ.90.032001>



- Farooq, A., Galvis-Florez, C. A., & Särkkä, S. (2024). Quantum-assisted Hilbert-space Gaussian process regression. *Physical Review A*, 109(5), 052410. <https://doi.org/10.1103/physreva.109.052410>
- Fathallah, W., Amor, N. B., & Leray, P. (2024). Approximate inference on optimized quantum Bayesian networks. *International Journal of Approximate Reasoning*, 175, 109307. <https://doi.org/10.1016/j.ijar.2024.109307>
- Finžgar, J. R., Schuetz, M. J. A., Brubaker, J. K., Nishimori, H., & Katzgraber, H. G. (2024). Designing quantum annealing schedules using Bayesian optimization. *Physical Review Research*, 6(2), 023063. <https://doi.org/10.1103/physrevresearch.6.023063>
- Garcia-De-Andoin, M., Saiz, Á., Pérez-Fernández, P., Lamata, L., Oregi, I., & Sanz, M. (2024). Digital-analog quantum computation with arbitrary two-body Hamiltonians. *Physical Review Research*, 6(1), 013280. <https://doi.org/10.1103/physrevresearch.6.013280>
- García-Peñalvo, F. J. (2022). Desarrollo de estados de la cuestión robustos: Revisiones Sistemáticas de Literatura. *Education in the Knowledge Society*, 23, e28600. <https://doi.org/10.14201/eks.28600>
- Harikrishnakumar, R., & Nannapaneni, S. (2023). Forecasting Bike Sharing Demand Using Quantum Bayesian Network. *Expert Systems with Applications*, 221, 119749. <https://doi.org/10.1016/j.eswa.2023.119749>
- He, Z., Peng, B., Alexeev, Y., & Zhang, Z. (2024). Distributionally Robust Variational Quantum Algorithms With Shifted Noise. *IEEE Transactions on Quantum Engineering*, 5, 1-12. <https://doi.org/10.1109/tqe.2024.3409309>
- Holbrook, A. J. (2023). A Quantum Parallel Markov Chain Monte Carlo. *Journal of Computational and Graphical Statistics*, 32(4), 1402-1415. <https://doi.org/10.1080/10618600.2023.2195890>
- Hong, Y. Y., Josh Domingo Lopez, D., & Wang, Y. Y. (2024). Solar Irradiance Forecasting Using a Hybrid Quantum Neural Network: A Comparison on GPU-Based Workflow Development Platforms. *IEEE Access*, 12, 145079-145094. <https://doi.org/10.1109/access.2024.3472053>



- Izawa, S., Kitai, K., Tanaka, S., Tamura, R., & Tsuda, K. (2022). Continuous black-box optimization with an Ising machine and random subspace coding. *Physical Review Research*, 4(2), 023062. <https://doi.org/10.1103/physrevresearch.4.023062>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Kaubruegger, R., Vasilyev, D. V., Schulte, M., Hammerer, K., & Zoller, P. (2021). Quantum Variational Optimization of Ramsey Interferometry and Atomic Clocks. *Physical Review X*, 11(4), 041045. <https://doi.org/10.1103/physrevx.11.041045>
- Kim, J. E., & Wang, Y. (2023). Quantum Approximate Bayesian Optimization Algorithms with Two Mixers and Uncertainty Quantification. *IEEE Transactions on Quantum Engineering*, 4, 1-17. <https://doi.org/10.1109/tqe.2023.3327055>
- Kim, J. E., & Wang, Y. (2025). Variational quantum algorithm for constrained topology optimization. *Quantum Science and Technology*, 10(4), 045025. <https://doi.org/10.1088/2058-9565/adfc92>
- Koshka, Y., & Novotny, M. A. (2020). Toward sampling from undirected probabilistic graphical models using a D-Wave quantum annealer. *Quantum Information Processing*, 19(10), 353. <https://doi.org/10.1007/s11128-020-02781-8>
- Kuś, G. I., Zwaag, S. van der, & Bessa, M. A. (2021). Sparse quantum Gaussian processes to counter the curse of dimensionality. *Quantum Machine Intelligence*, 3(1), 6. <https://doi.org/10.1007/s42484-020-00032-8>
- Layden, D., Mazzola, G., Mishmash, R. V., Motta, M., Wocjan, P., Kim, J. S., & Sheldon, S. (2023). Quantum-enhanced Markov chain Monte Carlo. *Nature*, 619(7969), 282-287. <https://doi.org/10.1038/s41586-023-06095-4>
- Lockwood, O., Weiss, P., Aronshtein, F., & Verdon, G. (2024). Quantum dynamical Hamiltonian Monte Carlo. *Physical Review Research*, 6(3), 033142. <https://doi.org/10.1103/physrevresearch.6.033142>
- Mala, D. J., Rastogi, A. K., Raj, A., & Manori, V. (2025). Hybrid KEM-QKD Integration With Parameter Optimization for Secure Underwater Networks via NetSquid Simulations. *IEEE Access*, 13, 157081-157103. <https://doi.org/10.1109/access.2025.3607474>



- Marcot, B. G. (2021). Ecoqbns: First application of ecological modeling with quantum bayesian networks. *Entropy*, 23(4), 441. <https://doi.org/10.3390/e23040441>
- Mengist, W., Soromessa, T., & Legese, G. (2020). Method for conducting systematic literature review and meta-analysis for environmental science research. *MethodsX*, 7, 100777. <https://doi.org/10.1016/j.mex.2019.100777>
- Miyahara, H., & Roychowdhury, V. (2023). Quantum advantage in variational Bayes inference. *Proceedings of the National Academy of Sciences of the United States of America*, 120(31), e2212660120. <https://doi.org/10.1073/pnas.2212660120>
- Miyahara, H., & Sughiyama, Y. (2018). Quantum extension of variational Bayes inference. *Physical Review A*, 98(2), 022330. <https://doi.org/10.1103/physreva.98.022330>
- Mizuno, Y., & Komatsuzaki, T. (2024). Finding optimal pathways in chemical reaction networks using Ising machines. *Physical Review Research*, 6(1), 013115. <https://doi.org/10.1103/physrevresearch.6.013115>
- Müller, G., Martínez-Lahuerta, V. J., Sekulic, I., Burger, S., Schneider, P. I., & Gaaloul, N. (2025). Bayesian optimization for state engineering of quantum gases. *Quantum Science and Technology*, 10(1), 015033. <https://doi.org/10.1088/2058-9565/ad9050>
- Nakano, Y., Hakoshima, H., Mitarai, K., & Fujii, K. (2024). Markov-chain Monte Carlo method enhanced by a quantum alternating operator ansatz. *Physical Review Research*, 6(3), 033105. <https://doi.org/10.1103/physrevresearch.6.033105>
- Nguyen, N., & Chen, K. C. (2022). Bayesian Quantum Neural Networks. *IEEE Access*, 10, 54110-54122. <https://doi.org/10.1109/access.2022.3168675>
- Ohno, H. (2023). Quantum Bayesian inference for parameter estimation using quantum generative model. *Quantum Information Processing*, 22(1), 52. <https://doi.org/10.1007/s11128-022-03809-x>
- Oliveira, M. de, & Barbosa, L. S. (2023). Quantum Bayesian Decision-Making. *Foundations of Science*, 28(1), 21-41. <https://doi.org/10.1007/s10699-021-09781-6>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson,



- E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
- Page, M. J., Moher, D., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... McKenzie, J. E. (2021). PRISMA 2020 explanation and elaboration: updated guidance and exemplars for reporting systematic reviews. *BMJ*, 372, n160. <https://doi.org/10.1136/bmj.n160>
- Patti, T. L., Shehab, O., Najafi, K., & Yelin, S. F. (2023). Markov chain Monte Carlo enhanced variational quantum algorithms. *Quantum Science and Technology*, 8(1), 015019. <https://doi.org/10.1088/2058-9565/aca821>
- Pelofske, E., Hahn, G., & Djidjev, H. (2023). Initial State Encoding via Reverse Quantum Annealing and H-Gain Features. *IEEE Transactions on Quantum Engineering*, 4, 1-21. <https://doi.org/10.1109/tqe.2023.3319586>
- Pirhooshyaran, M., & Terlaky, T. (2021). Quantum circuit design search. *Quantum Machine Intelligence*, 3(2), 25. <https://doi.org/10.1007/s42484-021-00051-z>
- Polson, N., Sokolov, V., & Xu, J. (2023). Quantum Bayesian computation. *Applied Stochastic Models in Business and Industry*, 39(6), 869-883. <https://doi.org/10.1002/asmb.2807>
- Preskill, J. (2018). Quantum Computing in the NISQ era and beyond. *Quantum*, 2, 79. <https://doi.org/10.22331/q-2018-08-06-79>
- Rapp, F., & Roth, M. (2024). Quantum Gaussian process regression for Bayesian optimization. *Quantum Machine Intelligence*, 6(1), 5. <https://doi.org/10.1007/s42484-023-00138-9>
- Rethlefsen, M. L., Kirtley, S., Waffenschmidt, S., Ayala, A. P., Moher, D., Page, M. J., Koffel, J. B., & PRISMA-S Group. (2021). PRISMA-S: an extension to the PRISMA Statement for Reporting Literature Searches in Systematic Reviews. *Systematic Reviews*, 10, 39. <https://doi.org/10.1186/s13643-020-01542-z>



- Sato, I., Tanaka, S., Kurihara, K., Miyashita, S., & Nakagawa, H. (2013). Quantum annealing for Dirichlet process mixture models with applications to network clustering. *Neurocomputing*, 121, 523-531. <https://doi.org/10.1016/j.neucom.2013.05.019>
- Schoot, R. van de, Depaoli, S., King, R., Kramer, B., Märtens, K., Tadesse, M. G., Vannucci, M., Gelman, A., Veen, D., Willemsen, J., & Yau, C. (2021). Bayesian statistics and modelling. *Nature Reviews Methods Primers*, 1, 1. <https://doi.org/10.1038/s43586-020-00001-2>
- Sels, D., Dashti, H., Mora, S., Demler, O., & Demler, E. (2020). Quantum approximate Bayesian computation for NMR model inference. *Nature Machine Intelligence*, 2(7), 396-402. <https://doi.org/10.1038/s42256-020-0198-x>
- Shibukawa, R., Tamura, R., & Tsuda, K. (2024). Boltzmann sampling with quantum annealers via fast Stein correction. *Physical Review Research*, 6(4), 043050. <https://doi.org/10.1103/physrevresearch.6.043050>
- Smith, A. W. R., Paige, A. J., & Kim, M. S. (2023). Faster variational quantum algorithms with quantum kernel-based surrogate models. *Quantum Science and Technology*, 8(4), 045016. <https://doi.org/10.1088/2058-9565/aceb87>
- Snyder, H. (2019). Literature review as a research methodology: An overview and guidelines. *Journal of Business Research*, 104, 333-339. <https://doi.org/10.1016/j.jbusres.2019.07.039>
- Soloviev, V. P., Bielza, C., & Larrañaga, P. (2023). Quantum approximate optimization algorithm for Bayesian network structure learning. *Quantum Information Processing*, 22(1), 19. <https://doi.org/10.1007/s11128-022-03769-2>
- Sorourifar, F., Rouabah, M. T., Belaloui, N. E., Louamri, M. M., Chamaki, D., Gustafson, E. J., Tubman, N. M., Paulson, J. A., & Bernal Neira, D. E. (2025). Toward efficient quantum computation of molecular ground-state energies. *AIChE Journal*, 71(12), e18887. <https://doi.org/10.1002/aic.18887>
- Taghavi, M., & Vahidi, J. (2025). Quantum-inspired multi-agent reinforcement learning for exploration–exploitation optimization in UAV-assisted 6G network deployment. *Quantum Machine Intelligence*, 7(2), 111. <https://doi.org/10.1007/s42484-025-00335-8>



- Tamiya, S., & Yamasaki, H. (2022). Stochastic gradient line Bayesian optimization for efficient noise-robust optimization of parameterized quantum circuits. *npj Quantum Information*, 8(1), 90. <https://doi.org/10.1038/s41534-022-00592-6>
- Teske, J. D., Humpohl, S. S., Otten, R., Bethke, P., Cerfontaine, P., Dedden, J., Ludwig, A., Wieck, A. D., & Bluhm, H. (2019). A machine learning approach for automated fine-tuning of semiconductor spin qubits. *Applied Physics Letters*, 114(13), 133102. <https://doi.org/10.1063/1.5088412>
- Tibaldi, S., Vodola, D., Tignone, E., & Ercolessi, E. (2023). Bayesian Optimization for QAOA. *IEEE Transactions on Quantum Engineering*, 4, 1-11. <https://doi.org/10.1109/tqe.2023.3325167>
- Torabian, E., & Krems, R. V. (2023). Compositional optimization of quantum circuits for quantum kernels of support vector machines. *Physical Review Research*, 5(1), 013211. <https://doi.org/10.1103/physrevresearch.5.013211>
- Vellimalaipattinam Thiruvenkatasamy, K., Ghanimi, H. M. A., Sengan, S., & Alharbi, M. G. (2025). An online tool based on the Internet of Things and intelligent blockchain technology for data privacy and security in rural and agricultural development. *Scientific Reports*, 15(1), 27349. <https://doi.org/10.1038/s41598-025-13231-9>
- Wang, M. M., & Zhang, X. Y. (2024). Quantum Bayes classifiers and their application in image classification. *Physical Review A*, 110(1), 012433. <https://doi.org/10.1103/physreva.110.012433>
- Wiebe, N., & Granade, C. (2017). Can small quantum systems learn. *Quantum Information and Computation*, 17(7-8), 568-594.
- Wiebe, N., Granade, C., & Cory, D. G. (2015). Quantum bootstrapping via compressed quantum Hamiltonian learning. *New Journal of Physics*, 17, 022005. <https://doi.org/10.1088/1367-2630/17/2/022005>
- Xiao, J., Endo, K., Muramatsu, M., Nomura, R., Moriguchi, S., & Terada, K. (2024). Application of factorization machine with quantum annealing to hyperparameter optimization and metamodel-based optimization in granular flow simulations. *International Journal for Numerical and Analytical Methods in Geomechanics*, 48(13), 3432-3451. <https://doi.org/10.1002/nag.3800>



Xiao, Y., Nazarian, S., & Bogdan, P. (2021). A stochastic quantum program synthesis framework based on Bayesian optimization. *Scientific Reports*, 11(1), 13138. <https://doi.org/10.1038/s41598-021-91035-3>

Zhang, S., Zhang, H., & Guo, Y. (2025). Research on Optimization Design of Cold Resistant New Energy Vehicle Battery Pack Structure Based on Quantum Computing. *SPIN*, 15(4), 2540005. <https://doi.org/10.1142/s2010324725400053>

Zhao, Z., Pozas-Kerstjens, A., Rebstroff, P., & Wittek, P. (2019). Bayesian deep learning on a quantum computer. *Quantum Machine Intelligence*, 1(1-2), 41-51. <https://doi.org/10.1007/s42484-019-00004-7>

Zhu, D., Linke, N. M., Benedetti, M., Landsman, K. A., Nguyen, N. H., Alderete, C. H., Perdomo-Ortiz, A., Korda, N., Garfoot, A., Brecque, C., Egan, L., Perdomo, O., & Monroe, C. (2019). Training of quantum circuits on a hybrid quantum computer. *Science Advances*, 5(10), eaaw9918. <https://doi.org/10.1126/sciadv.aaw9918>

CONFLICTO DE INTERESES

No existe.

FINANCIAMIENTO

No aplica.

CONTRIBUCIÓN DE AUTORÍA

Conceptualización: Carla Pazmiño Naranjo y Andrés Galvis Correa.

Curación de datos: Carla Pazmiño Naranjo.

Análisis formal: Carla Pazmiño Naranjo y Andrés Galvis Correa.

Redacción – borrador original: Carla Pazmiño Naranjo y Andrés Galvis Correa.

Redacción – revisión y edición: Carla Pazmiño Naranjo y Andrés Galvis Correa.

