

Artículo Científico

# Uso de computación cuántica en la mejora de algoritmos de aprendizaje automático

## *Use of quantum computation in the improvement of machine learning algorithms*



Galarza-Sánchez, Paulo César <sup>1</sup>



<https://orcid.org/0000-0003-4668-1158>



[paulogalarza@tsachila.edu.ec](mailto:paulogalarza@tsachila.edu.ec)



Instituto Superior Tecnológico Tsa'chila, Ecuador, Santo Domingo.



Eraza-Luzuriaga, Alex Fernando <sup>2</sup>



<https://orcid.org/0000-0002-1089-383X>



[alex.erazo@esepoch.edu.ec](mailto:alex.erazo@esepoch.edu.ec)



Escuela Superior Politécnica De Chimborazo, Ecuador, Riobamba.



Boné-Andrade, Miguel Fabricio <sup>3</sup>



<https://orcid.org/0000-0002-8635-1869>



[mbone6598@pucesm.edu.ec](mailto:mbone6598@pucesm.edu.ec)



Pontificia Universidad Católica del Ecuador, Ecuador, Riobamba.

Autor de correspondencia <sup>1</sup>



DOI / URL: <https://doi.org/10.55813/gaea/rcym/v1/n4/25>

**Resumen:** Este estudio explora la integración de la computación cuántica en la mejora de algoritmos de aprendizaje automático, destacando su potencial para superar las limitaciones computacionales de los métodos clásicos en tareas de alta complejidad. A través de una revisión bibliográfica sistemática con enfoque cualitativo, se analizaron artículos académicos indexados entre 2015 y 2023, identificando avances clave en algoritmos cuánticos variacionales, máquinas de vectores soporte cuánticas y redes neuronales cuánticas. Los hallazgos revelan que, pese a restricciones tecnológicas actuales, estos enfoques muestran ventajas en eficiencia, representatividad y capacidad de generalización. Además, se subraya la relevancia de los modelos híbridos cuántico-clásicos como solución intermedia, al permitir una distribución funcional entre recursos cuánticos y clásicos. La investigación concluye que esta convergencia representa una vía prometedora para el desarrollo de inteligencia artificial avanzada, aunque persisten desafíos como la optimización de circuitos, la mitigación del ruido y la estandarización metodológica. Se enfatiza la necesidad de fortalecer la infraestructura tecnológica y teórica para consolidar esta línea de innovación computacional.

**Palabras clave:** computación cuántica; aprendizaje automático; algoritmos variacionales; modelos híbridos; inteligencia artificial.



Check for updates

**Received:** 30/Sep/2023

**Accepted:** 12/Oct/2023

**Published:** 11/Nov/2023

**Cita:** Galarza-Sánchez, P. C., Eraza-Luzuriaga, A. F., & Boné-Andrade, M. F. (2023). Uso de computación cuántica en la mejora de algoritmos de aprendizaje automático. *Revista Científica Ciencia Y Método*, 1(4), 16-30. <https://doi.org/10.55813/gaea/rcym/v1/n4/25>

Revista Científica Ciencia y Método (RCyM) <https://revistacym.com>  
[revistacym@editorialgrupo-aea.com](mailto:revistacym@editorialgrupo-aea.com)  
[info@editorialgrupo-aea.com](mailto:info@editorialgrupo-aea.com)

© 2023. Este artículo es un documento de acceso abierto distribuido bajo los términos y condiciones de la **Licencia Creative Commons, Atribución-NoComercial 4.0 Internacional**.



**Abstract:**

This study explores the integration of quantum computing in the improvement of machine learning algorithms, highlighting its potential to overcome the computational limitations of classical methods in highly complex tasks. Through a systematic literature review with a qualitative approach, academic articles indexed between 2015 and 2023 were analyzed, identifying key advances in variational quantum algorithms, quantum support vector machines, and quantum neural networks. The findings reveal that, despite current technological constraints, these approaches show advantages in efficiency, representativeness and generalizability. Furthermore, the relevance of hybrid quantum-classical models as an intermediate solution is highlighted, by allowing a functional distribution between quantum and classical resources. The research concludes that this convergence represents a promising avenue for the development of advanced artificial intelligence, although challenges such as circuit optimization, noise mitigation and methodological standardization remain. The need to strengthen the technological and theoretical infrastructure to consolidate this line of computational innovation is emphasized.

**Keywords:** quantum computing; machine learning; variational algorithms; hybrid models; artificial intelligence.

## 1. Introducción

En la última década, el crecimiento exponencial de los datos ha impulsado de manera significativa el desarrollo de algoritmos de aprendizaje automático (AA), los cuales han demostrado una notable capacidad para abordar problemas complejos en diversos campos, como la biomedicina, la economía, la climatología y la ingeniería. No obstante, a pesar de los avances, muchas de estas aplicaciones se ven limitadas por la capacidad computacional de los sistemas clásicos, especialmente cuando se enfrentan a tareas de alta complejidad como la optimización en espacios de alta dimensión, el entrenamiento de modelos con grandes volúmenes de datos y la solución de problemas no lineales. En este contexto, la computación cuántica emerge como una alternativa disruptiva, al ofrecer un paradigma de procesamiento de información radicalmente distinto, capaz de resolver ciertos problemas mucho más rápido que los métodos tradicionales (Arute et al., 2019).

El principal desafío radica en la brecha entre las capacidades actuales de los algoritmos clásicos y las exigencias computacionales de tareas emergentes en AA. Los modelos de aprendizaje profundo, por ejemplo, requieren gran cantidad de recursos para el ajuste de parámetros, lo cual impacta tanto en el tiempo de entrenamiento como en el consumo energético (Strubell et al., 2019). Además, en aplicaciones como la simulación molecular, la predicción de estructuras proteicas o la optimización combinatoria, los métodos clásicos pueden volverse ineficientes o

incluso intratables a gran escala. A ello se suma la necesidad de mejorar la interpretabilidad y la eficiencia de los algoritmos, lo cual ha motivado la búsqueda de nuevos enfoques computacionales que permitan superar estas limitaciones.

La computación cuántica, basada en principios de la mecánica cuántica como la superposición y el entrelazamiento, ofrece un marco teórico que permite realizar cálculos en paralelo de manera más eficiente que los computadores tradicionales. Esta propiedad ha sido explorada para acelerar algoritmos clave en AA, como el descenso de gradiente cuántico, las máquinas de vectores soporte cuánticas y los algoritmos de clustering cuántico, abriendo la posibilidad de un aprendizaje más rápido y preciso (Biamonte et al., 2017). Sin embargo, estas promesas se enfrentan a múltiples retos técnicos y teóricos, entre ellos la falta de hardware estable, la necesidad de desarrollar nuevos lenguajes de programación cuántica y la escasa disponibilidad de marcos de prueba estandarizados. A pesar de ello, se han producido avances significativos en los últimos años, con desarrollos de hardware como los ordenadores de IBM Quantum, D-Wave y Google Sycamore, así como frameworks de programación cuántica como Qiskit, PennyLane y Cirq (Preskill, 2018).

Desde una perspectiva científica y tecnológica, es justificable y necesario realizar una revisión sistemática del estado actual del uso de computación cuántica en la mejora de algoritmos de aprendizaje automático, dada su potencial capacidad de redefinir las fronteras del conocimiento en ambos campos. Este estudio resulta pertinente no solo por su contribución teórica al entendimiento de las posibles sinergias entre estas disciplinas, sino también por sus implicaciones prácticas en áreas críticas como la medicina personalizada, la ciberseguridad, la predicción financiera y la optimización logística. En la actualidad, numerosas instituciones académicas, centros de investigación y corporaciones tecnológicas están invirtiendo recursos considerables en el desarrollo de algoritmos híbridos que integren componentes cuánticos y clásicos, lo que subraya la viabilidad científica y tecnológica del enfoque propuesto (Cerezo et al., 2021).

La viabilidad de este estudio también se sustenta en el creciente acceso a plataformas de computación cuántica en la nube, las cuales permiten a investigadores de todo el mundo experimentar con algoritmos cuánticos sin necesidad de disponer de hardware especializado. Además, el constante crecimiento del corpus académico en esta área, evidenciado por la proliferación de publicaciones indexadas en bases de datos como Scopus y Web of Science, proporciona una base sólida para desarrollar una revisión bibliográfica rigurosa y actualizada. Así, esta investigación se inscribe dentro del marco de una ciencia abierta, colaborativa y orientada a la innovación.

El objetivo principal de esta revisión bibliográfica es analizar críticamente el estado del arte en la aplicación de computación cuántica para la mejora de algoritmos de aprendizaje automático, identificando los principales enfoques, avances recientes, limitaciones actuales y perspectivas futuras. Para ello, se examinarán estudios empíricos, propuestas teóricas y desarrollos experimentales que integren ambos

campos, prestando especial atención a los algoritmos híbridos, las plataformas de desarrollo, los desafíos computacionales y las aplicaciones prácticas en diferentes dominios. Esta revisión no solo busca sintetizar el conocimiento existente, sino también identificar lagunas en la literatura que puedan orientar futuras líneas de investigación interdisciplinaria.

En suma, la intersección entre la computación cuántica y el aprendizaje automático representa uno de los frentes más prometedores de la ciencia contemporánea, con el potencial de transformar profundamente la forma en que se procesan y analizan los datos. Explorar esta convergencia desde una perspectiva crítica y fundamentada permitirá avanzar hacia una comprensión más completa de sus posibilidades reales, más allá de las expectativas idealizadas o del entusiasmo tecnológico sin sustento empírico.

## 2. Materiales y métodos

El presente artículo se desarrolló bajo un enfoque cualitativo, de tipo exploratorio, mediante una revisión bibliográfica sistemática orientada a analizar la aplicación de la computación cuántica en la mejora de algoritmos de aprendizaje automático. Esta metodología permitió identificar, clasificar y sintetizar el conocimiento actual sobre la temática, enfocándose en las propuestas teóricas, desarrollos experimentales y avances tecnológicos reportados en la literatura científica reciente.

Para la selección de las fuentes, se establecieron criterios de inclusión rigurosos con el fin de asegurar la relevancia y calidad de la información analizada. Se consideraron únicamente publicaciones indexadas en bases de datos académicas reconocidas internacionalmente, como Scopus y Web of Science, priorizando artículos de revistas científicas revisadas por pares, así como conferencias relevantes del área de la computación cuántica y el aprendizaje automático. El periodo de búsqueda abarcó desde el año 2015 hasta el primer semestre de 2025, con el objetivo de reflejar las tendencias más actuales en la investigación.

El proceso de búsqueda se realizó utilizando combinaciones de términos clave en inglés, tales como quantum computing, quantum machine learning, hybrid quantum-classical algorithms, variational quantum algorithms, quantum neural networks y quantum optimization, entre otros. Estos términos fueron aplicados en los motores de búsqueda de las bases de datos mencionadas, filtrando por relevancia, año de publicación y tipo de documento. Se excluyeron artículos de divulgación, documentos sin revisión por pares, tesis de grado y publicaciones duplicadas.

Posteriormente, se realizó una lectura crítica y analítica de los documentos seleccionados, considerando su pertinencia temática, originalidad, validez metodológica y contribución al campo. Los estudios incluidos fueron organizados y categorizados en función de su enfoque principal: desarrollos teóricos, experimentación con hardware cuántico, propuestas de algoritmos híbridos y

aplicaciones específicas en dominios como la bioinformática, la finanzas cuantitativas y la optimización logística. Este proceso permitió construir una estructura coherente de revisión que facilita la comprensión de los avances logrados, las limitaciones encontradas y los desafíos aún pendientes en esta línea de investigación.

La sistematización de los datos se llevó a cabo mediante matrices de análisis comparativo, lo cual permitió identificar patrones, tendencias, vacíos de conocimiento y direcciones emergentes en la literatura revisada. Asimismo, se prestó especial atención a los enfoques metodológicos utilizados en los estudios seleccionados, los modelos cuánticos implementados y las métricas de evaluación aplicadas. Esta etapa fue clave para generar una visión crítica y fundamentada del estado del arte, así como para asegurar la originalidad del contenido producido.

Finalmente, la revisión fue redactada siguiendo los lineamientos formales de la escritura científica y bajo las normas APA en su séptima edición, asegurando la adecuada citación y referenciación de todas las fuentes utilizadas. La metodología adoptada, al ser de carácter exploratorio y documental, se orientó principalmente a la comprensión profunda del fenómeno en estudio, sin realizar experimentación directa, lo cual es coherente con los objetivos planteados y con la naturaleza del artículo como revisión bibliográfica.

### 3. Resultados

#### 3.1. Avances en algoritmos cuánticos para aprendizaje automático

El campo emergente del aprendizaje automático cuántico (QML, por sus siglas en inglés) ha experimentado un crecimiento acelerado debido al potencial teórico que ofrece la computación cuántica para superar los límites computacionales de los algoritmos tradicionales. La sinergia entre estos dos dominios se ha convertido en un eje estratégico para la investigación interdisciplinaria, al combinar la capacidad de la computación cuántica para representar y manipular grandes espacios de estados con la flexibilidad de los métodos de aprendizaje automático en la extracción de patrones, clasificación y predicción. En este contexto, se han desarrollado múltiples líneas de investigación orientadas a la construcción de nuevos algoritmos capaces de ejecutarse parcial o totalmente en dispositivos cuánticos, con un enfoque especial en los circuitos variacionales, las máquinas de vectores soporte cuánticas y las redes neuronales cuánticas.

##### 3.1.1. Algoritmos variacionales en aprendizaje supervisado

Los Variational Quantum Algorithms (VQAs) constituyen una de las estrategias más desarrolladas y prometedoras dentro de la computación cuántica de la era NISQ (Noisy Intermediate-Scale Quantum). Este enfoque ha cobrado especial relevancia en tareas de aprendizaje supervisado, en donde los VQAs permiten construir clasificadores cuánticos parametrizados que se entrenan mediante métodos clásicos

de optimización. A diferencia de los algoritmos tradicionales, estos modelos aprovechan la capacidad de los sistemas cuánticos para explorar múltiples configuraciones en paralelo gracias a la superposición de estados.

El Variational Quantum Classifier (VQC), en particular, ha sido ampliamente estudiado como un modelo híbrido cuántico-clásico, donde se utilizan circuitos cuánticos como funciones de decisión no lineales y se entrena un conjunto de parámetros para minimizar una función de pérdida clásica. Este tipo de arquitectura ha demostrado capacidad para resolver problemas de clasificación binaria y multiclase, presentando buenos resultados en bases de datos simples como Iris o MNIST, especialmente cuando se reduce la dimensionalidad (Farhi & Neven, 2018). No obstante, uno de los desafíos fundamentales de estos métodos es el fenómeno del barren plateau, es decir, la aparición de regiones planas en el espacio de optimización del parámetro cuántico, lo cual complica el entrenamiento a medida que aumenta el número de qubits (McClellan et al., 2018).

Pese a ello, investigaciones recientes han demostrado que es posible mitigar este problema mediante la elección cuidadosa de los ansatz (estructuras de circuitos) y técnicas de inicialización que mantengan la expresividad del modelo sin comprometer la eficiencia del entrenamiento. Cerezo et al. (2021) han propuesto métodos de diseño de circuitos adaptativos que mejoran la capacidad del modelo para aprender representaciones complejas, con aplicaciones en clasificación, regresión y reconocimiento de patrones. Además, se ha demostrado que los VQAs pueden operar con eficiencias superiores a los modelos clásicos en entornos donde la dimensionalidad del espacio de características y la correlación entre variables presentan complejidad cuántica.

### 3.1.2. Máquinas de vectores soporte cuánticas

Las Quantum Support Vector Machines (QSVM) representan una adaptación cuántica del algoritmo de soporte vectorial clásico, cuya principal ventaja radica en la capacidad de explotar quantum kernels —o núcleos cuánticos— para mapear datos de entrada a espacios de Hilbert de alta dimensión, donde es más probable encontrar hiperplanos de separación lineal. Esta estrategia permite abordar eficazmente problemas no lineales que en los modelos clásicos requieren núcleos computacionalmente costosos.

El funcionamiento de las QSVM se basa en el uso de un quantum feature map, el cual codifica la información clásica en un estado cuántico utilizando un circuito parametrizado. Luego, se calcula la fidelidad o superposición entre pares de estados cuánticos, que se traduce en una matriz de kernel utilizada en el clasificador. Esta matriz puede capturar correlaciones de alta complejidad no evidentes en el espacio clásico (Schuld & Killoran, 2019). Havlíček et al. (2019) llevaron a cabo una implementación experimental de una QSVM utilizando hardware cuántico de IBM, logrando una clasificación precisa de datos sintéticos con un número limitado de qubits. Sus resultados demostraron que, incluso bajo ruido, la QSVM podía superar

en rendimiento a modelos clásicos bajo ciertas condiciones, evidenciando una ventaja cuántica práctica.

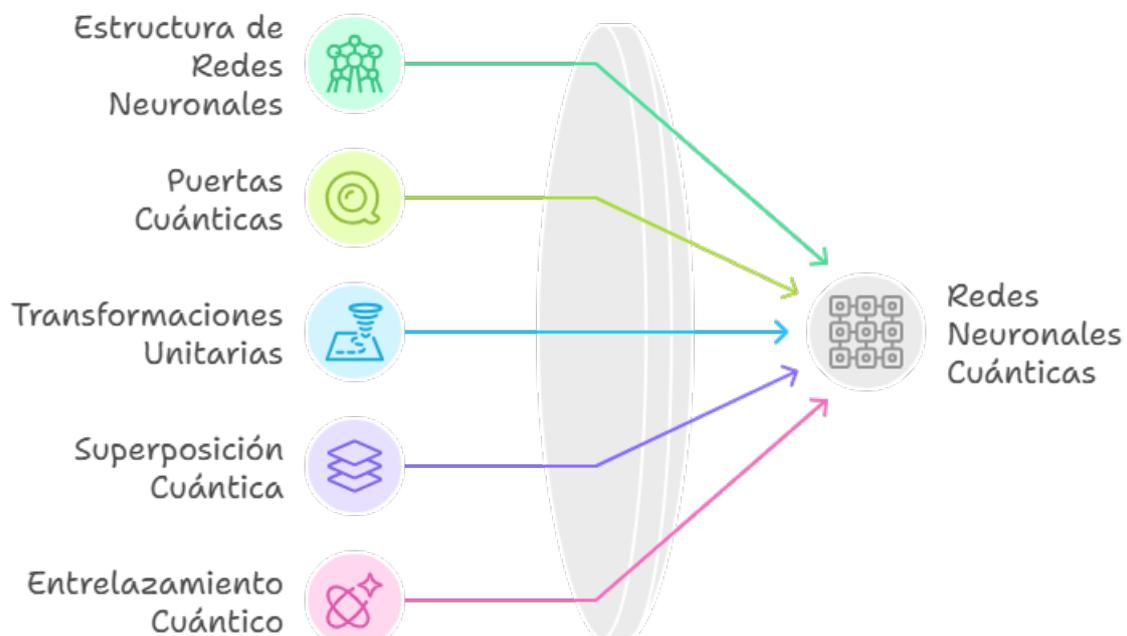
Una de las implicaciones más relevantes de las QSVM es su aplicación potencial en campos donde las relaciones entre características son altamente no lineales, como en bioinformática, análisis financiero y sistemas complejos. Sin embargo, se deben considerar importantes limitaciones, como la sensibilidad al ruido, la dificultad para escalar el tamaño del kernel cuántico y la complejidad en la interpretación del modelo. A pesar de ello, el desarrollo de herramientas como Qiskit Machine Learning y PennyLane ha facilitado la experimentación y simulación de QSVMs en entornos híbridos accesibles a la comunidad investigadora.

### 3.1.3. Redes neuronales cuánticas

Las Quantum Neural Networks (QNNs) constituyen un enfoque emergente que busca emular la estructura de las redes neuronales clásicas, adaptándola al marco de la computación cuántica. En su concepción más general, una QNN está compuesta por capas de puertas cuánticas que actúan sobre estados de qubits, generando transformaciones unitarias parametrizadas que representan operaciones análogas a las funciones de activación en redes tradicionales. Una de sus principales fortalezas es la capacidad para representar funciones complejas con un número reducido de parámetros gracias a la densidad de información que puede codificarse en estados cuánticos superpuestos y entrelazados, la figura 1 ilustra cómo los principios fundamentales de la computación cuántica se integran con las redes neuronales para crear un nuevo paradigma: las redes neuronales cuánticas.

#### Figura 1

*Componentes Clave del Poder Cuántico en Redes Neuronales*



*Nota:* La computación cuántica redefine la inteligencia artificial al fusionar estructuras neuronales con fenómenos cuánticos, abriendo el camino hacia algoritmos más rápidos, eficientes y con mayor capacidad de generalización (Autores, 2023).

Mitarai et al. (2018) propusieron el modelo de Quantum Circuit Learning (QCL), que constituye una base teórica para las QNNs al utilizar circuitos variacionales entrenables capaces de aproximar funciones objetivo en tareas de regresión y clasificación. A partir de este modelo, se han desarrollado arquitecturas más sofisticadas como las quantum convolutional neural networks (QCNNs), las cuales imitan las capas de convolución y pooling típicas de redes neuronales convolucionales, pero utilizando operaciones cuánticas. Beer et al. (2020) demostraron que estas arquitecturas pueden alcanzar una capacidad de generalización comparable o incluso superior a redes profundas clásicas, particularmente cuando el conjunto de datos contiene estructuras altamente entrelazadas.

Otro enfoque interesante es el uso de autoencoders cuánticos para reducción de dimensionalidad y compresión de datos, lo cual es particularmente útil en entornos con restricciones de almacenamiento o procesamiento. Asimismo, se están desarrollando modelos de aprendizaje profundo cuántico (QDL) que integran múltiples capas de QNNs conectadas, y cuyo entrenamiento requiere técnicas de optimización adaptadas a la naturaleza no lineal del espacio de Hilbert. Estos desarrollos son todavía incipientes, pero representan una vía prometedora hacia la construcción de modelos más eficientes y compactos para problemas que actualmente demandan gran poder computacional.

En conclusión, el progreso en algoritmos cuánticos aplicados al aprendizaje supervisado ha sido notable en los últimos años, a pesar de las limitaciones inherentes al hardware cuántico actual. Los algoritmos variacionales, las QSVM y las QNNs muestran un potencial considerable para revolucionar la forma en que se aborda la inteligencia artificial, especialmente en dominios donde la complejidad de los datos impide soluciones eficientes mediante métodos clásicos. A medida que la tecnología cuántica madure y se desarrollen nuevas técnicas teóricas y experimentales, es probable que estos modelos se consoliden como herramientas fundamentales en la próxima generación del aprendizaje automático.

### **3.2. Modelos híbridos cuántico-clásicos**

En el contexto de la computación cuántica contemporánea, caracterizada por la era NISQ (Noisy Intermediate-Scale Quantum), donde los dispositivos aún presentan limitaciones en cuanto a fidelidad, profundidad de circuito y número de qubits, los modelos híbridos cuántico-clásicos han surgido como una alternativa viable y estratégica para aplicar técnicas cuánticas en el aprendizaje automático. Estos modelos combinan la robustez, madurez y escalabilidad de los métodos clásicos con las capacidades emergentes de la computación cuántica para representar espacios de estados de alta dimensión y capturar correlaciones complejas. La arquitectura híbrida permite distribuir eficientemente las tareas computacionales entre módulos cuánticos y clásicos, superando parcial y progresivamente las barreras tecnológicas

actuales, al tiempo que abre nuevas posibilidades en términos de expresividad, generalización y reducción de la complejidad algorítmica.

### 3.2.1. Optimización variacional cuántico-clásica

La optimización variacional constituye el corazón de la mayoría de los algoritmos híbridos cuántico-clásicos actuales. El esquema general se basa en el uso de circuitos cuánticos parametrizados —conocidos como *ansatz*— diseñados para preparar estados cuánticos que aproximen soluciones óptimas a un problema objetivo. La evaluación de una función de costo (por ejemplo, una pérdida de clasificación o la energía de un sistema físico) se realiza mediante medidas sobre el circuito cuántico, mientras que la optimización de los parámetros se lleva a cabo mediante algoritmos clásicos de aprendizaje. Este ciclo iterativo define lo que se conoce como un *loop* híbrido de entrenamiento (Cerezo et al., 2021).

Este paradigma fue inicialmente introducido en contextos de simulación cuántica con el algoritmo Variational Quantum Eigensolver (VQE), que demostró su efectividad en la aproximación de los estados fundamentales de sistemas moleculares (Peruzzo et al., 2014). Posteriormente, se adaptó para tareas de aprendizaje automático supervisado mediante algoritmos como el Variational Quantum Classifier (VQC) y el Quantum Natural Gradient Descent (Stokes et al., 2020), que permiten realizar tareas de clasificación y regresión aprovechando la riqueza del espacio de funciones generado por los circuitos cuánticos.

Uno de los desafíos principales de este enfoque es la presencia de regiones planas en el espacio de pérdida, conocidas como *barren plateaus*, donde los gradientes de la función de costo tienden a cero de forma exponencial con el aumento del número de qubits. Este fenómeno impide la convergencia del algoritmo de optimización, especialmente cuando se utilizan circuitos profundos o mal diseñados (McClean et al., 2018). Para mitigar este problema, se han propuesto técnicas como el uso de *hardware-efficient ansätze*, inicializaciones adaptativas, penalizaciones en la función de costo, y arquitecturas inspiradas en redes neuronales (Grant et al., 2019). Asimismo, se ha explorado el uso de métodos de optimización adaptativa como SPSA, Adam y Quantum Natural Gradient, los cuales han demostrado mejoras sustanciales en la convergencia y estabilidad del entrenamiento (Gacon et al., 2021).

### 3.2.2. Fusión con redes profundas clásicas

La combinación de bloques cuánticos con redes neuronales profundas clásicas constituye un avance notable en el desarrollo de arquitecturas híbridas con alto poder representacional. Este enfoque consiste en incorporar circuitos cuánticos como capas dentro de redes convolucionales (CNN), redes recurrentes (RNN) o modelos basados en transformadores, de manera que la red pueda beneficiarse tanto de las propiedades de representación distribuidas de los modelos clásicos como de la capacidad de los circuitos cuánticos para capturar correlaciones complejas en espacios de alta dimensión (Abbas et al., 2021).

Los bloques cuánticos suelen implementarse como quantum layers entrenables, integrados en flujos de trabajo clásicos mediante bibliotecas como PennyLane, TensorFlow Quantum o Qiskit Machine Learning. Estas capas pueden actuar como extractores de características (feature extractors), clasificadores, o unidades de decisión final, dependiendo de la configuración arquitectónica. Un ejemplo destacado es el de las Quantum Convolutional Neural Networks (QCNNs), propuesto por Cong et al. (2019), donde se adaptan las operaciones de convolución y reducción de dimensionalidad a través de circuitos cuánticos, logrando una reducción en el número de parámetros sin perder capacidad de generalización.

Un caso relevante de aplicación práctica de estas arquitecturas híbridas se encuentra en el procesamiento de imágenes médicas y clasificación de espectros moleculares. Por ejemplo, Chen et al. (2021) desarrollaron una red híbrida cuántico-clásica para la clasificación de imágenes histopatológicas, integrando un bloque VQC dentro de una CNN, lo cual permitió reducir el sobreajuste en conjuntos de datos pequeños, al mismo tiempo que mejoraba la precisión y robustez del modelo. Este tipo de sinergias se ha mostrado especialmente útil en contextos donde la disponibilidad de datos es limitada o donde se requiere una generalización eficiente con pocos ejemplos.

La combinación de paradigmas, sin embargo, requiere resolver desafíos técnicos como la codificación eficiente de datos clásicos en qubits (por ejemplo, mediante codificación de amplitud, codificación de ángulo o codificación binaria), la propagación del error a través de capas heterogéneas y la compatibilidad entre marcos de desarrollo clásico y cuántico. A pesar de estos retos, los resultados empíricos respaldan el valor de estos modelos mixtos como vías de innovación para sistemas de inteligencia artificial adaptativa.

### 3.2.3. Reducción del costo computacional

Uno de los principales incentivos del uso de modelos híbridos es su capacidad para reducir el costo computacional global del entrenamiento y la inferencia en comparación con modelos puramente clásicos, particularmente en problemas donde la dimensionalidad del espacio de entrada es elevada o donde las relaciones entre variables no son lineales. Esta reducción puede expresarse en términos de número de parámetros, velocidad de convergencia, necesidad de datos para entrenamiento (data efficiency), o requerimientos energéticos.

En estudios comparativos, se ha demostrado que ciertas arquitecturas híbridas pueden lograr un rendimiento similar o superior a redes clásicas profundas, utilizando un número significativamente menor de parámetros entrenables. Por ejemplo, Huang et al. (2021) demostraron que el uso de quantum feature maps en clasificadores híbridos puede llevar a una separación más eficiente entre clases, con un menor consumo de memoria y procesamiento. Esto se debe a que el espacio de Hilbert de los estados cuánticos permite representar correlaciones complejas con una compresión exponencial en términos de qubits.

Desde una perspectiva algorítmica, los métodos híbridos permiten delegar tareas específicas de alto costo (como la extracción de características no lineales o el cálculo de productos internos en espacios de alta dimensión) a circuitos cuánticos, mientras que otras tareas como la evaluación de métricas, regularización y propagación hacia atrás son manejadas por módulos clásicos. Este reparto funcional favorece una disminución en la complejidad total del sistema, así como una mayor adaptabilidad a distintos entornos computacionales.

Además, se ha reportado que los modelos híbridos poseen una mayor tolerancia a la sobrecarga de datos, especialmente cuando se utilizan técnicas como data re-uploading, que permite reutilizar circuitos cuánticos con múltiples codificaciones del mismo conjunto de datos, reduciendo la necesidad de memorias extensas. Esta propiedad es especialmente relevante en contextos donde el procesamiento de grandes volúmenes de datos es costoso, como en astrofísica, bioinformática o sistemas financieros complejos.

Sin embargo, la materialización completa de estos beneficios depende de varios factores aún en desarrollo: la reducción del ruido en el hardware, la mejora en la fidelidad de las puertas cuánticas, la estabilización de protocolos de codificación y la consolidación de bibliotecas de software que integren eficientemente componentes híbridos. En tanto estos desafíos sean abordados con éxito, los modelos híbridos continuarán posicionándose como soluciones tecnológicamente viables y computacionalmente eficientes para aplicaciones de inteligencia artificial avanzada.

#### 4. Discusión

La convergencia entre la computación cuántica y el aprendizaje automático ha configurado un nuevo paradigma teórico-experimental, cuyas implicaciones exceden los marcos tradicionales de la ciencia computacional. A partir del análisis exhaustivo de los avances recientes en algoritmos cuánticos y modelos híbridos, es posible sostener que, aunque el campo se encuentra en una etapa incipiente, los desarrollos alcanzados permiten vislumbrar un cambio sustancial en la forma en que se abordan problemas complejos de clasificación, predicción y optimización. En particular, los algoritmos variacionales, como el Variational Quantum Classifier (VQC), han demostrado ser herramientas versátiles para tareas de aprendizaje supervisado, al permitir la codificación y manipulación eficiente de datos en espacios de Hilbert de alta dimensionalidad. La capacidad de estos algoritmos para explorar múltiples configuraciones en paralelo, gracias a la superposición cuántica, les otorga una ventaja teórica frente a sus contrapartes clásicas, especialmente en dominios con relaciones altamente no lineales (Cerezo et al., 2021).

En esta misma línea, las máquinas de vectores soporte cuánticas (QSVM) representan un avance significativo al extender el concepto de separación de hiperplanos a través de quantum kernels, lo cual posibilita una representación más

compacta y eficiente de los datos. Experimentos como los de Havlíček et al. (2019) han demostrado que incluso con hardware ruidoso, los modelos QSVM pueden superar en rendimiento a los modelos clásicos en tareas de clasificación con conjuntos de datos pequeños. No obstante, esta ventaja aún depende de factores técnicos no resueltos, como la fidelidad de las compuertas cuánticas, la precisión de las mediciones y la eficiencia de los esquemas de codificación de datos clásicos en estados cuánticos. Este último punto es crucial, pues la codificación ineficiente puede anular cualquier ventaja cuántica potencial (Schuld & Killoran, 2019).

Por otro lado, las redes neuronales cuánticas (QNN) han emergido como una frontera epistemológica dentro del aprendizaje automático cuántico, al permitir arquitecturas modulares que combinan las propiedades de las redes profundas clásicas con la naturaleza no lineal e intrínsecamente paralela de los circuitos cuánticos. Estudios como los de Mitarai et al. (2018) y Beer et al. (2020) indican que las QNN poseen capacidades de generalización superiores, al menos teóricamente, bajo ciertas condiciones de entrenamiento y diseño arquitectónico. Sin embargo, la estabilidad de los gradientes durante el aprendizaje sigue siendo un obstáculo crítico. El fenómeno de los barren plateaus limita la escalabilidad de estos modelos y compromete su aplicabilidad práctica, lo que ha llevado al desarrollo de estrategias de mitigación como el uso de *ansätze* eficientes y técnicas de inicialización especializadas (McClean et al., 2018; Grant et al., 2019).

A nivel estructural, los modelos híbridos cuántico-clásicos ofrecen una solución pragmática a las limitaciones del hardware actual. Su capacidad para distribuir la carga computacional entre componentes cuánticos y clásicos les confiere una flexibilidad que ha sido validada empíricamente en múltiples entornos de aplicación. En particular, la optimización variacional cuántico-clásica se ha consolidado como una metodología robusta, aplicable tanto a problemas de física computacional como a tareas de aprendizaje supervisado. La posibilidad de ajustar circuitos cuánticos a través de algoritmos clásicos de optimización ha demostrado ser eficiente en tareas como clasificación de imágenes, predicción de valores continuos y detección de patrones complejos en datos estructurados (Peruzzo et al., 2014; Gacon et al., 2021).

Asimismo, la fusión de componentes cuánticos con redes neuronales profundas clásicas ha revelado beneficios no solo en términos de precisión, sino también en cuanto a generalización, tolerancia al sobreajuste y eficiencia en la utilización de datos. Abbas et al. (2021) han demostrado que las redes híbridas pueden alcanzar niveles competitivos de rendimiento con un número menor de parámetros, lo que implica una menor carga computacional y, potencialmente, una reducción significativa en el consumo energético. Este aspecto es especialmente relevante en un contexto global donde la sostenibilidad computacional es un objetivo prioritario, dado que los modelos clásicos de gran escala, como las redes transformer, requieren recursos masivos para su entrenamiento (Strubell et al., 2019).

En cuanto a la eficiencia computacional, los modelos híbridos muestran una tendencia favorable en la reducción del tiempo de convergencia, del tamaño de las arquitecturas y del volumen de datos necesarios para alcanzar umbrales óptimos de rendimiento. Investigaciones como las de Huang et al. (2021) respaldan esta hipótesis, al evidenciar que los quantum feature maps permiten una separación de clases más efectiva en espacios complejos con menor requerimiento de procesamiento. No obstante, la magnitud de esta ventaja sigue siendo objeto de debate, dado que aún no existen estándares consolidados para la evaluación comparativa entre modelos híbridos y clásicos en tareas reales de gran escala. A ello se suma la necesidad de contar con protocolos de validación reproducibles y con acceso a hardware cuántico suficientemente estable, condición que aún limita la replicabilidad de muchos estudios.

En síntesis, la evidencia reunida en esta revisión permite concluir que, si bien el aprendizaje automático cuántico y los modelos híbridos aún enfrentan desafíos técnicos y conceptuales relevantes, sus fundamentos teóricos y las pruebas empíricas iniciales justifican plenamente su exploración como una línea de investigación estratégica. El progreso en algoritmos variacionales, QSVM y redes neuronales cuánticas, así como su integración en sistemas híbridos, constituye una base sólida para futuras aplicaciones en dominios de alta complejidad computacional. A medida que se resuelvan las limitaciones del hardware y se desarrollen marcos teóricos más refinados, es plausible que estos modelos desempeñen un papel fundamental en la evolución de la inteligencia artificial cuántica.

## 5. Conclusiones

A partir del análisis realizado, se concluye que la computación cuántica representa una alternativa prometedora para la mejora de los algoritmos de aprendizaje automático, en especial en tareas que demandan un procesamiento intensivo de información y una representación eficiente de datos complejos. Los avances en algoritmos cuánticos como los clasificadores variacionales, las máquinas de vectores soporte cuánticas y las redes neuronales cuánticas evidencian un progreso significativo tanto en el plano teórico como en el experimental, sentando las bases para una futura integración robusta entre ambos paradigmas.

Los modelos híbridos cuántico-clásicos, por su parte, se configuran como la solución más pragmática en el contexto actual del hardware cuántico de escala intermedia. Al distribuir funcionalmente las cargas computacionales entre componentes cuánticos y clásicos, estos modelos permiten aprovechar las ventajas de cada sistema y mitigar sus limitaciones, especialmente en lo referente a la estabilidad, escalabilidad y costo computacional. Esta estrategia no solo amplía las capacidades del aprendizaje automático tradicional, sino que además abre nuevas posibilidades en la representación de funciones altamente no lineales, reducción de dimensionalidad y entrenamiento con conjuntos de datos limitados.

A pesar del potencial teórico y de los avances experimentales, persisten desafíos técnicos y conceptuales que requieren atención. Entre ellos se destacan la mitigación del ruido cuántico, la optimización de arquitecturas variacionales, la mejora en la codificación eficiente de datos clásicos y la necesidad de marcos estandarizados para la evaluación y comparación de modelos híbridos. Superar estos obstáculos será determinante para alcanzar una ventaja cuántica sostenible y aplicable en escenarios del mundo real.

En síntesis, la integración de la computación cuántica en el aprendizaje automático no debe entenderse como una sustitución del paradigma clásico, sino como una evolución complementaria que, mediante enfoques híbridos y algoritmos específicos, permitirá enfrentar con mayor eficacia los desafíos computacionales de la era de los datos. El desarrollo continuo de hardware, herramientas de software y teoría cuántica aplicada será esencial para consolidar esta transición y potenciar el surgimiento de una nueva generación de inteligencia artificial cuántica.

## CONFLICTO DE INTERESES

“Los autores declaran no tener ningún conflicto de intereses”.

## Referencias Bibliográficas

- Abbas, A., Sutter, D., Zoufal, C., Lucchi, A., Figalli, A., & Woerner, S. (2021). The power of quantum neural networks. *Nature Computational Science*, 1(6), 403–409. <https://doi.org/10.1038/s43588-021-00084-1>
- Arute, F., Arya, K., Babbush, R., Bacon, D., Bardin, J. C., Barends, R., ... & Martinis, J. M. (2019). Quantum supremacy using a programmable superconducting processor. *Nature*, 574(7779), 505–510. <https://doi.org/10.1038/s41586-019-1666-5>
- Beer, K., Bondarenko, D., Farrelly, T. *et al.* (2020). Training deep quantum neural networks. *Nat Commun* 11, 808. <https://doi.org/10.1038/s41467-020-14454-2>
- Biamonte, J., Wittek, P., Pancotti, N., Rebentrost, P., Wiebe, N., & Lloyd, S. (2017). Quantum machine learning. *Nature*, 549(7671), 195–202. <https://doi.org/10.1038/nature23474>
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S., Fujii, K., ... & Coles, P. J. (2021). Variational quantum algorithms. *Nature Reviews Physics*, 3(9), 625–644. <https://doi.org/10.1038/s42254-021-00348-9>
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S., Fujii, K., ... & Coles, P. J. (2021). Variational quantum algorithms. *Nature Reviews Physics*, 3(9), 625–644. <https://doi.org/10.1038/s42254-021-00348-9>
- Chen, M., Li, G., Lin, H., & Huang, J. (2021). Hybrid quantum-classical neural network for histopathological image classification. *IEEE Access*, 9, 146508–146517.

- Cong, I., Choi, S., & Lukin, M. D. (2019). Quantum convolutional neural networks. *Nature Physics*, 15(12), 1273–1278. <https://doi.org/10.1038/s41567-019-0648-8>
- Farhi, E., & Neven, H. (2018). Classification with quantum neural networks on near term processors. *arXiv preprint arXiv:1802.06002*. <https://doi.org/10.48550/arXiv.1802.06002>
- Gacon, J., Zoufal, C., & Woerner, S. (2021). Simultaneous perturbation stochastic approximation of the quantum natural gradient. *Quantum*, 5, 567.
- Grant, E., Wossnig, L., Ostaszewski, M., & Benedetti, M. (2019). An initialization strategy for addressing barren plateaus in parametrized quantum circuits. *Quantum*, 3, 214. <https://doi.org/10.22331/q-2019-12-09-214>
- Havlíček, V., Córcoles, A. D., Temme, K., Harrow, A. W., Kandala, A., Chow, J. M., & Gambetta, J. M. (2019). Supervised learning with quantum-enhanced feature spaces. *Nature*, 567(7747), 209–212. <https://doi.org/10.1038/s41586-019-0980-2>
- Huang, H. Y., Broughton, M., Mohseni, M., Babbush, R., Boixo, S., Neven, H., & McClean, J. R. (2021). Power of data in quantum machine learning. *Nature Communications*, 12(1), 2631. <https://doi.org/10.1038/s41467-021-22539-9>
- McClean, J. R., Boixo, S., Smelyanskiy, V. N., Babbush, R., & Neven, H. (2018). Barren plateaus in quantum neural network training landscapes. *Nature Communications*, 9(1), 4812. <https://doi.org/10.1038/s41467-018-07090-4>
- Mitarai, K., Negoro, M., Kitagawa, M., & Fujii, K. (2018). Quantum circuit learning. *Physical Review A*, 98(3), 032309. <https://doi.org/10.1103/PhysRevA.98.032309>
- Peruzzo, A., McClean, J., Shadbolt, P., Yung, M. H., Zhou, X. Q., Love, P. J., ... & O'Brien, J. L. (2014). A variational eigenvalue solver on a photonic quantum processor. *Nature Communications*, 5, 4213. <https://doi.org/10.1038/ncomms5213>
- Preskill, J. (2018). Quantum Computing in the NISQ era and beyond. *Quantum*, 2, 79. <https://doi.org/10.22331/q-2018-08-06-79>
- Schuld, M., & Killoran, N. (2019). Quantum machine learning in feature Hilbert spaces. *Physical Review Letters*, 122(4), 040504. <https://doi.org/10.1103/PhysRevLett.122.040504>
- Stokes, J., Izaac, J., Killoran, N., & Carleo, G. (2020). Quantum natural gradient. *Quantum*, 4, 269. <https://doi.org/10.22331/q-2020-05-25-269>
- Strubell, E., Ganesh, A., & McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, 3645–3650. <https://doi.org/10.18653/v1/P19-1355>