

**DETECCIÓN DE ERRORES EN SISTEMAS CUÁNTICOS TOPOLÓGICOS USANDO
*MACHINE LEARNING***

**ERROR DETECTION IN TOPOLOGICAL QUANTUM SYSTEMS USING MACHINE
LEARNING**

José Roman Castro San Agustín¹

jcastros248@alumno.uaemex.mx

ORCID: 0000-0001-6383-6700

Marco Alberto Mendoza Pérez²

mamendozap@uaemex.mx

ORCID: 0000-0003-4911-4757

Manuel Ávila Aoki³

vlkmanuel@uaemex.mx

ORCID: 0000-0002-3951-6421

Doricela Gutiérrez Cruz⁴

dgutierrezcr@uaemex.mx

ORCID: 0000-0003-2843-3273

¹ Doctorado en Ciencias de la Computación, Centro Universitario UAEM Valle de Chalco, Universidad Autónoma del Estado de México.

² Doctorado en Ciencias de la Computación, Centro Universitario UAEM Valle de Chalco, Universidad Autónoma del Estado de México.

³ Doctorado en Ciencias de la Computación, Centro Universitario UAEM Valle de Chalco, Universidad Autónoma del Estado de México.

⁴ Doctorado en Ciencias de la Computación, Centro Universitario UAEM Nezahualcóyotl, Universidad Autónoma del Estado de México.



Resumen

La computación cuántica, que utiliza *qubits* para el procesamiento de la información, enfrenta desafíos constantes debido a la fragilidad y susceptibilidad a errores de los sistemas cuánticos. La computación cuántica topológica, que utiliza *qubits* de Majorana, ofrece una vía interesante para construir computadoras cuánticas estables. La detección de coherencia en estos sistemas puede beneficiarse del análisis de datos mediante redes neuronales, facilitando la identificación de factores que contribuyen a la pérdida de coherencia. La decoherencia y la amplificación de errores son problemas clave que afectan la precisión de los cálculos cuánticos. Para abordar estos inconvenientes, se desarrollan técnicas avanzadas de corrección y detección de errores. El aprendizaje profundo emerge como una herramienta prometedora para mejorar la computación cuántica. Técnicas como las redes neuronales convolucionales y los *autoencoders* podrían identificar y clasificar errores en la información. En particular, las redes neuronales pueden detectar patrones extraños en los datos generados por experimentos cuánticos, lo que permite implementar correcciones más efectivas. El diseño de redes neuronales para la detección de errores implica un proceso de entrenamiento utilizando datos de estados cuánticos con errores. Estas redes pueden ser ajustadas para mejorar su capacidad de detección y validación de los estados cuánticos. El presente artículo muestra la importancia de la implementación de estas técnicas avanzadas para asegurar la fidelidad y precisión de los cálculos de computadoras cuánticas estables.

Palabras clave: Computación cuántica, *Qubits* de Majorana, Decoherencia, Redes neuronales, Corrección de errores.

Abstract

Quantum computing, which utilizes qubits for information processing, continually faces challenges due to the fragility and susceptibility of quantum systems to errors. Topological quantum computing, which employs Majorana qubits, offers a promising approach to building stable quantum computers. Coherence detection in these systems can benefit from data analysis using neural networks, facilitating the identification of factors that contribute to coherence loss. Decoherence and error amplification are key issues that affect the accuracy of quantum calculations. To address these challenges, advanced error correction and detection techniques are



being developed. Deep learning emerges as a promising tool to enhance quantum computing. Techniques such as convolutional neural networks and autoencoders can identify and classify errors in the information. Neural networks, in particular, can detect anomalies in data generated by quantum experiments, enabling more effective error corrections. Designing neural networks for error detection involves a training process using data from quantum states with errors. These networks can be fine-tuned to improve their capacity for detecting and validating quantum states. This article highlights the importance of implementing these advanced techniques to ensure the fidelity and accuracy of calculations in stable quantum computers.

Keywords: Quantum computing, Majorana qubits, Decoherence, Neural networks, Error correction

Fecha de envío: 06/06/2024

Fecha de aprobación: 10/11/2024

Fecha de publicación: 01/01/2025

Introducción

La informática cuántica es una rama de la informática que utiliza la teoría cuántica para procesar y transmitir información. En la informática cuántica, la unidad básica de información es el *qubit*, que es un sistema cuántico de dos estados. A diferencia de los bits clásicos que solo pueden estar en dos estados (0 o 1), los *qubits* pueden estar en una superposición de ambos estados al mismo tiempo, lo que les permite procesar información de manera mucho más eficiente.

Los algoritmos cuánticos son algoritmos diseñados para ser ejecutados en una computadora cuántica. La principal diferencia que tienen con los algoritmos clásicos, es que se aprovechan las propiedades cuánticas para resolver problemas de manera mucho más eficiente (Nielsen y Chuang, 2010). Ejemplos de algoritmos cuánticos incluyen el algoritmo de Grover para la búsqueda no estructurada y el algoritmo de Shor para la factorización de números enteros grandes, que es de gran importancia en criptografía (De Wolf, 2023).



La computación cuántica es una tecnología emergente que promete revolucionar muchos campos de la ciencia y la tecnología al ofrecer la posibilidad de realizar cálculos a velocidades que los ordenadores clásicos no pueden alcanzar. Sin embargo, los sistemas cuánticos son frágiles y susceptibles a errores debido a la naturaleza misma de la mecánica cuántica. Esto representa un gran desafío para la construcción de sistemas cuánticos escalables y fiables.

Afortunadamente, las técnicas de aprendizaje profundo, un subcampo de la inteligencia artificial, están emergiendo como una herramienta valiosa para detectar y reducir errores en sistemas cuánticos. Estas técnicas se han utilizado para mejorar la tolerancia a errores en sistemas cuánticos, lo que los hace más estables y fiables, lo cual es fundamental para el éxito de la computación cuántica en el futuro (Deng y Yu, 2014).

El campo de la inteligencia artificial ha presentado algoritmos de aprendizaje automático basado en una red neuronal recurrente para la corrección continua de errores cuánticos en sistemas superconductores de tres *qubits transmon* (Convy, Liao, Zhang, Patel, Livingston, Nguyen, Siddiqi, y Whaley, 2022). Además de procedimientos automatizados que utilizan circuitos variacionales para generar operaciones lógicas a partir de procedimientos de codificación y corrección conocidos. El procedimiento se ha probado mediante simulación en computadoras clásicas en códigos cuánticos de cuatro a quince *qubits* (Chen, Vasmer, Breuckmann, y Grant, 2019).

En el presente trabajo se explicará cómo las técnicas de aprendizaje profundo se están utilizando para detectar errores en sistemas cuánticos. También se presentarán algunos casos de estudio recientes. Adicionalmente el presente artículo tiene también como objetivo ofrecer una introducción accesible a la aplicación del aprendizaje profundo en la computación cuántica, y mostrar cómo esta tecnología está ayudando a superar uno de los mayores desafíos en la construcción de sistemas cuánticos escalables y fiables.

Antecedentes

Un *qubit* es la unidad mínima lógica para el tratamiento y procesamiento de información cuántica. La representación de los estados básicos del *qubit* se denotan por un vector de estado en el espacio de Hilbert:

$$|0\rangle = \begin{pmatrix} 1 \\ 0 \end{pmatrix}; |1\rangle = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$



por lo tanto

$$|\psi\rangle = \begin{pmatrix} \alpha \\ \beta \end{pmatrix} = \alpha|0\rangle + \beta|1\rangle$$

La base $|0\rangle$ o $|1\rangle$ puede ser representada por:

$$|\psi\rangle = \alpha|0\rangle + \beta|1\rangle = \alpha \frac{\alpha + \beta}{\sqrt{2}}|+\rangle + \alpha \frac{\alpha - \beta}{\sqrt{2}}|-\rangle$$

Ettore Majorana postuló en 1937 la existencia de una partícula capaz de ser simultáneamente su propia antipartícula, lo que significa que su creación y aniquilación podrían ocurrir a través del mismo operador.

$$\gamma = \gamma^\dagger$$

En la Figura 1 podemos ver gráficamente lo anterior: El operador de creación $c^\dagger$ se utiliza para representar la presencia de un electrón, mientras que el operador de aniquilación c se usa para representar la presencia de un hueco.




Figura 8: Operadores de creación y aniquilación (elaboración propia,2023).

Cuando se trata de una superposición igual de ambos operadores, podemos comprobar que estos operadores de Majorana cumplen con la propiedad de ser su propia adjunta (Ver Figura 2):



Figura 2: Estados de superposición de Majorana (elaboración propia,2023).

La coherencia es esencial en este tipo de sistemas cuánticos ya que es la propiedad que permite que los *qubits* estén en un estado cuántico entrelazado (si hablamos un sistema de dos *qubits*), lo que significa que las mediciones realizadas en uno de los *qubits* están correlacionadas con las mediciones realizadas en el otro, incluso si están separados por una gran distancia. La coherencia permite que los *qubits* mantengan sus estados cuánticos superpuestos y entrelazados durante el tiempo suficiente para realizar cálculos cuánticos complejos.



Los sistemas cuánticos son una herramienta muy poderosa para el procesamiento y la transmisión de información, así como para la simulación de sistemas complejos. Sin embargo, la naturaleza cuántica de estos sistemas también los hace susceptibles a errores, lo que puede limitar su utilidad en algunas aplicaciones.

Uno de los principales problemas en los sistemas cuánticos es la decoherencia que se refiere a la pérdida de coherencia cuántica debido a la interacción con el entorno. Esto puede causar errores en la información almacenada en el sistema, lo que puede afectar la precisión de las operaciones cuánticas. Además, la decoherencia puede provocar la desaparición de estados cuánticos superpuestos, que son esenciales para la computación cuántica (Fortin, 2012).

Otro problema común es la amplificación de errores. A diferencia de los sistemas clásicos, en los sistemas cuánticos no se pueden copiar los estados cuánticos exactamente, lo que significa que cualquier intento de hacer una copia exacta de un estado cuántico siempre será imperfecto. Esto puede resultar en una propagación de errores a medida que se realizan más operaciones en el sistema.

Los sistemas cuánticos también están sujetos a errores causados por la falta de precisión en la implementación de las operaciones cuánticas. Esto puede ser causado por errores en la calibración de los dispositivos, fluctuaciones de ruido en los campos electromagnéticos utilizados para manipular los *qubits*, y otros factores.

Para minimizar estos errores, los científicos están trabajando en el desarrollo de técnicas para la corrección de errores en sistemas cuánticos. Estas técnicas se basan en la redundancia y la codificación de información para detectar y corregir errores, y pueden ayudar a mejorar la precisión de los cálculos cuánticos y la fiabilidad de los sistemas cuánticos en general (Ittrends, 2021).

Aprendizaje Profundo (Deep Learning)

El aprendizaje profundo es una técnica de inteligencia artificial que se basa en el uso de redes neuronales para analizar grandes cantidades de datos y extraer patrones complejos. En el contexto de los sistemas cuánticos, el aprendizaje profundo se utiliza para analizar la información generada por los sistemas y detectar cualquier error o anomalía en los resultados (González, 2018).



Una de las técnicas más prometedoras en este campo es el uso de redes neuronales convolucionales que han demostrado ser especialmente efectivas para detectar patrones en datos de imágenes y señales (Mera y Ochoa, 2021). En el contexto de los sistemas cuánticos, estas redes se utilizan para analizar los datos generados por los experimentos cuánticos y detectar cualquier patrón anómalo que pueda indicar la presencia de errores.

Una vez que se detectan los errores, se pueden implementar técnicas de corrección de errores para reducir su impacto en los resultados finales. Estas técnicas incluyen el uso de códigos de corrección de errores, que son algoritmos diseñados específicamente para detectar y corregir errores en los datos cuánticos (por el momento solo nos enfocaremos a la detección de errores).

La detección de errores en sistemas cuánticos es una tarea crítica para la realización de cálculos cuánticos precisos y confiables. Las técnicas de aprendizaje profundo están demostrando ser un enfoque prometedor para mejorar la detección de errores en estos sistemas. A medida que se desarrollan nuevas técnicas y algoritmos, es probable que veamos avances significativos en la capacidad de los sistemas cuánticos para el procesamiento de operaciones complejas en el futuro.

Deep Learning para la Detección de Errores

El uso de redes neuronales profundas para detectar y corregir errores en un sistema cuántico es posible gracias al aprendizaje a partir de los datos del sistema. Esto permite identificar patrones que indiquen la presencia de errores. Del mismo modo, esta técnica permite la clasificación de errores en diferentes categorías, lo que puede ayudar a los investigadores a entender mejor los tipos de errores que afectan el sistema cuántico. Esto puede llevar a una corrección de errores más efectiva.

Actualmente los *autoencoders* son redes neuronales que aprenden a reconstruir la entrada original (Wang y Prokhorov, 2012). En el contexto de la detección de errores cuánticos, los *autoencoders* se utilizan para detectar y corregir errores en un sistema cuántico. Para poder diseñar una red neuronal es necesario identificar los errores comunes que se presentan en la implementación de los sistemas cuánticos.

Los sistemas cuánticos son propensos a errores debido a las interacciones con el ambiente y a la decoherencia. Es necesario identificar los tipos de errores cuánticos que se quieren detectar y corregir, como errores de fase, errores de amplitud o errores de entrelazamiento. Los estados



cuánticos pueden ser representados mediante vectores de estado o matrices densidad. Es importante definir la representación que se utilizará para entrenar y evaluar la red neuronal.

La arquitectura de la red neuronal dependerá del tipo de errores cuánticos que se quieren detectar y corregir. Una posible arquitectura es la red neuronal de *autoencoder* cuántico, que consta de una capa de codificación y una capa de decodificación. La capa de codificación transforma el estado cuántico original en un código cuántico, mientras que la capa de decodificación transforma el código cuántico de nuevo al estado cuántico original.

Materiales y Métodos

Para poder identificar los tipos de errores que afectan a los sistemas cuánticos como errores de fase, errores de amplitud y errores de entrelazamiento. Una red neuronal puede ser útil para detectar la coherencia en un sistema de entrelazamiento de dos *qubits* mediante el análisis de datos obtenidos de mediciones cuánticas. La red neuronal puede ser entrenada para detectar patrones específicos en los datos que indican la presencia o ausencia de coherencia. Esto es especialmente útil para sistemas cuánticos grandes y complejos, donde la detección manual de la coherencia es difícil o incluso imposible. Además, una red neuronal también puede ayudar a identificar factores que pueden contribuir a la pérdida de coherencia en el sistema, lo que puede ser útil para el diseño y optimización de sistemas cuánticos.

Los estados cuánticos pueden ser representados mediante vectores de estado o matrices de densidad. Esta identificación es importante para diseñar una red neuronal efectiva que pueda detectar y corregir estos errores.

Para entrenar la red neuronal, se generan datos de entrenamiento a partir de simulaciones de sistemas cuánticos con errores inducidos. Estos datos incluyen estados cuánticos en los que se han introducido errores específicos.

La red neuronal diseñada para este estudio es una red de *autoencoder*, que consta de una capa de codificación y una capa de decodificación. La capa de codificación transforma el estado cuántico original en un código cuántico, mientras que la capa de decodificación transforma el código cuántico de nuevo al estado cuántico original. Esta arquitectura permite que la red neuronal aprenda a reconstruir el estado cuántico, identificando y corrigiendo los errores en el proceso.



La computación cuántica topológica es uno de los enfoques más interesantes para la construcción de computadoras cuánticas estables, y se basa en el uso de estados topológicos para almacenar y procesar información. Esta tecnología utiliza estados topológicos de la materia, en los que las excitaciones de las cuasipartículas son diferentes de los bosones y fermiones, y se conocen como aniones no abelianos. Estas partículas se caracterizan por seguir las estadísticas de trenzado no abelianas, lo que les da propiedades únicas y útiles para el desarrollo de la tecnología.

Resultados

El entrenamiento de la red neuronal se realiza utilizando datos de entrenamiento generados a partir de los estados cuánticos con errores. Durante el entrenamiento, se ajustan los pesos y las conexiones de la red neuronal para mejorar su capacidad para detectar errores en los estados cuánticos.

Después del entrenamiento, se valida la red neuronal utilizando datos de validación separados de los datos de entrenamiento. Luego, se prueba la red neuronal utilizando datos de prueba para determinar su precisión y eficacia en la detección de errores en los estados cuánticos. En la Figura 3, se presenta el diseño de la red neuronal que permite la detección de errores en sistemas cuánticos:




Figura 3: Red neuronal de detección de errores (elaboración propia,2023).

1. Entrada: La red neuronal recibe como entrada la información del estado cuántico que se



desea verificar y corregir.

2. Capa de preprocesamiento: Esta capa prepara los datos de entrada para ser procesados por la red neuronal. Puede incluir la normalización y la transformación de los datos.
3. Capas ocultas: La red neuronal utiliza varias capas ocultas para procesar los datos y extraer características relevantes del estado cuántico. Estas capas pueden ser diseñadas utilizando técnicas de aprendizaje profundo, como redes neuronales convolucionales o redes neuronales recurrentes.
4. Capa de detección de errores: Esta capa se encarga de detectar errores en el estado cuántico. Puede utilizar técnicas de clasificación binaria para determinar si el estado cuántico es correcto o si contiene errores.
5. Salida: La red neuronal produce una salida que indica si el estado cuántico ha sido verificado y corregido correctamente.

La red neuronal comienza recibiendo como entrada la información del estado cuántico que se desea verificar y corregir en este caso se trata de un par de Majoranas. La información de entrada es preprocesada para su procesamiento adecuado por la red neuronal, incluyendo normalización y transformación de los datos.

La red neuronal utiliza varias capas ocultas para procesar los datos y extraer características relevantes del estado cuántico (estados $|0\rangle$ y $|1\rangle$), utilizando técnicas de aprendizaje profundo, como redes neuronales convolucionales o redes neuronales recurrentes.

Si hay errores en el estado cuántico, la capa de detección de errores los detectará utilizando técnicas de clasificación binaria para determinar si el estado cuántico es correcto o si contiene errores.

Es importante señalar que el presente diseño de red neuronal puede variar dependiendo de la robustez de la arquitectura específica de cada sistema cuántico a la que se desee implementar. Además, es posible que se necesiten múltiples redes neuronales para manejar diferentes tipos de errores y operaciones cuánticas.



Discusión

La detección de errores en sistemas cuánticos es un desafío importante para los científicos e investigadores que trabajan en el campo de la informática cuántica. Los sistemas cuánticos son extremadamente sensibles a los errores, lo que puede comprometer la precisión y confiabilidad de los cálculos realizados en ellos. Por esta razón, se están desarrollando técnicas avanzadas de aprendizaje profundo para mejorar la detección y reducción de errores en estos sistemas.

Cierre

El diseño de redes neuronales para la detección de errores en sistemas cuánticos, en particular en sistemas de *qubits*, es un enfoque prometedor para mejorar la eficacia y eficiencia de la detección de errores en estos sistemas. La detección de errores es crucial para la fiabilidad y precisión de los cálculos realizados en sistemas cuánticos, y las redes neuronales son capaces de detectar patrones complejos en grandes conjuntos de datos que serían difíciles de detectar por métodos convencionales. A medida que la informática cuántica continúa avanzando, la aplicación de técnicas de aprendizaje profundo para la detección de errores será cada vez más importante para maximizar la precisión y confiabilidad de estos sistemas, y mejorar los métodos de fabricación de computadoras cuánticas escalables y prácticas.



Referencias

- Chen, H., Vasmer, M., Breuckmann, N., y Grant, E. (2019). "Machine learning logical gates for quantum error correction". arXiv:1912.10063v1 [quant-ph]. <https://doi.org/10.48550/arXiv.1912.10063>
- Convy, I., Liao, H., Zhang, S., Patel, S., Livingston, W. P., Nguyen, H. N., Siddiqi, I., y Whaley, K. B. (2022). "Machine learning for continuous quantum error correction on superconducting qubits". New Journal of Physics, Vol. 24 No.6, pp. 063019. <http://dx.doi.org/10.1088/1367-2630/ac66f9>.
- Deng, L., y Yu, D. (2014). "Deep learning: methods and applications". Foundations and Trends in Signal Processing, Vol. 7, No 3-4, pp. 197-387. <https://doi.org/10.1561/20000000039>
- De Wolf, R. (2023). "Quantum Computing: Lecture Notes". arXiv preprint arXiv:1907.09415 [quant-ph]. <https://doi.org/10.48550/arXiv.1907.09415>
- Fortin, S. (2012). "Hacia una mejor comprensión de la decoherencia desde una perspectiva general". Revista Colombiana de Filosofía de la Ciencia, Vol 24 No. 12, 65-82. <https://doi.org/10.18270/rcfc.v12i24.1695>
- González, M., A. (2018). "Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales". Tesis de maestría, Maestría en ingeniería de automatización e informática industrial. Universidad de Oviedo.
- Ittrends (2021). Crean un algoritmo de aprendizaje automático para detectar errores cuánticos. Recuperado el 27 de abril de 2023 de <https://goo.su/inLU7bJ>.
- Mera, J., L. y Ochoa, G., J. F. (2021). "Redes neuronales convolucionales para la clasificación de componentes independientes de rs-fMRI". TecnoLógicas, Vol. 24, No. 50. <https://doi.org/10.22430/22565337.1626>
- Nielsen, M.A. y Chuang, I.L. (2010). "Quantum Computation and Quantum Information". Cambridge University Press. New York.
- Wang, J., He, H., y Prokhorov, D. (2012). A Folded Neural Network Autoencoder for Dimensionality Reduction. Procedia Computer Science, Vol. 13, pp. 120-127. <http://doi:10.1016/j.procs.2012.09.120>.