

Métodos Cuánticos para la Meteorología Clásica

Nicolas Schiaffino^{1†}, Esteban Gárate^{1†}, Gabriel Leyton^{1†},
Mauricio Solar^{1*†}

^{1*}Departamento de Informática, Universidad Técnica Federico Santa
María, Av. Vicuña Mackenna 3939, Santiago, 8940000, Región
Metropolitana, Chile.

*Corresponding author(s). E-mail(s): mauricio.solar@usm.cl;
Contributing authors: Nicolas.Schiaffino@usm.cl;
Esteban.Garate@usm.cl; Gabriel.Leyton@usm.cl;

[†]Los autores contribuyeron igualmente al desarrollo de este trabajo.

Abstract

En este trabajo se examina las ventajas y beneficios que puede ofrecer la computación cuántica a los métodos que utiliza la meteorología, centrándose en su aplicación a la predicción numérica del clima (NWP, por sus siglas en inglés de *Numerical Weather Prediction*). Se abordan los desafíos actuales y el potencial que la computación cuántica presenta para optimizar procesos en la meteorología, como la predicción por conjuntos, los algoritmos de aprendizaje automático cuántico, y el procesamiento de grandes volúmenes de datos.

Aunque la tecnología cuántica aplicada a la meteorología aún enfrenta desafíos significativos, ofrece oportunidades prometedoras en áreas críticas de predicción y análisis meteorológico, importantes en el contexto actual del cambio climático. Por este motivo, se muestra una implementación básica del algoritmo clásico del método Runge-Kutta que se utiliza para la integración temporal de ecuaciones diferenciales en simulaciones meteorológicas de gran escala. El algoritmo clásico se compara con una versión cuántica de baja complejidad considerando 4 variables, demostrándose la factibilidad del uso de herramientas cuánticas en la meteorología.

Keywords: Quantum meteorology, predicción numérica del tiempo, quantum computing

1 Introducción

La predicción numérica del tiempo (NWP, por sus siglas en inglés de *Numerical Weather Prediction*) ha revolucionado el campo de la meteorología al permitir la simulación detallada de la atmósfera mediante modelos computacionales que se basan en principios físicos fundamentales como la conservación de la masa, el momento y la energía. Estos modelos proporcionan una herramienta esencial para prever el comportamiento atmosférico a distintas escalas temporales y espaciales. Sin embargo, las crecientes demandas de información meteorológica más detallada han impulsado la exploración de nuevas tecnologías, como la computación cuántica, para mejorar la precisión y la eficiencia de las predicciones.

Los modelos NWP actuales utilizan métodos numéricos tradicionales para resolver las complejas ecuaciones que describen los procesos atmosféricos. Es aquí donde ha surgido interés en la aplicación de tecnologías cuánticas para optimizar estos procesos. [Kaur \(2023\)](#) presenta máquinas de meteorología que combinan tecnología cuántica con enfoques tradicionales, empresas como IBM, Pasqal and BASF, Rigetti Computing, 1QBit, entre otras, han implementado computadores cuánticos para la medición del clima, pero al parecer no se mencionan usos híbridos de tecnología, tales como serían el explotar específicamente la computación cuántica para realizar y resolver NWP de manera más clara. Se cree que el futuro relacionado a la investigación meteorológica es amplio, y por situaciones como lo ocurrido el 2024 con el huracán Milton¹ puede transformarse en una de las ramas fundamentales en un mundo en pleno cambio climático.

Según el DWD ([Deutscher Wetterdienst 2024](#)), se reconocen varios temas en el procesamiento de cálculos, entre ellos el uso de ecuaciones diferenciales (EDOs) o esquemas de integración temporal (usando el método de Runge-Kutta y predictor-corrector). Estos métodos se utilizan principalmente para resolver una gigantesca EDO, que va en el orden de 10^8 a 10^9 ecuaciones. Hoy en día se resuelven ecuaciones de componentes horizontales explícitamente, mientras que los componentes verticales son tratados implícitamente. Por este motivo, es que para mejorar los métodos actuales, se podría utilizar métodos híbridos para el procesamiento de la información. En la literatura hay investigaciones de métodos numéricos como [Zanger et al. \(2021\)](#), [Chagneau et al. \(2023\)](#), [Macaluso et al. \(2022\)](#), [Gubernatis et al. \(2016\)](#), [Asaka et al. \(2020\)](#), [Bäumer et al. \(2024\)](#), y [Wang et al. \(2019\)](#), entre otros, resumidos a continuación.

El trabajo de [Zanger et al. \(2021\)](#) muestra una manera general de lidiar con la aproximación Runge-Kutta a través de la computación cuántica. Se demuestra que, a pesar de que se copien las operaciones, se piensa que utilizando esto como bloque se puede mejorar el paralelismo, la solución de problemas inversos que provienen del método y más.

La computación cuántica puede mejorar los métodos de Runge-Kutta al explotar su paralelismo, proporcionar soluciones directas a problemas inversos y optimizar esquemas implícitos mediante técnicas como el recocido cuántico. Estas ventajas, particularmente en el manejo del alto costo computacional y la complejidad de resolver ecuaciones diferenciales, apuntan a un futuro en el que los métodos de integración de

¹Ciclón tropical extremadamente poderoso y devastador que se convirtió en el segundo huracán más intenso del Atlántico jamás registrado en el Golfo de México, solo detrás del huracán Rita en 2005.

tiempo, como Runge-Kutta, pueden volverse más eficientes, escalables y capaces de abordar sistemas más complejos. Esto es especialmente relevante en escenarios que requieren alta precisión y estabilidad, como la predicción meteorológica o simulaciones cuánticas de procesos físicos. Como se indica en el documento del DWD ([Deutscher Wetterdienst 2024](#)), el método Runge-Kutta se utiliza en el sistema de modelado meteorológico COSMO (*Consortium for Small-scale Modelling*) para la integración temporal de ecuaciones diferenciales, siendo COSMO uno de los más importantes modelados de meteorología en el mundo. Sin embargo, desde 2021 que COSMO no ha recibido actualizaciones, dejando de herencia al modelo ICON (*Icosahedral Nonhydrostatic*).

Este trabajo busca explorar cómo la computación cuántica puede integrarse con los métodos numéricos actuales en la meteorología, con el objetivo de optimizar aspectos críticos como la inicialización de valores y el procesamiento de datos en los modelos NWP. Dado que los recursos computacionales necesarios para desarrollar modelos NWP más complejos continúan excediendo las capacidades convencionales, la computación cuántica podría representar una solución para acelerar el procesamiento y mejorar la eficiencia sin comprometer la precisión. Por esta razón, se hace una implementación del algoritmo clásico del método Runge-Kutta de baja complejidad considerando sólo 4 variables para poder compararlo con su versión cuántica. El algoritmo clásico se compara con su versión cuántica demostrándose la factibilidad del uso de herramientas cuánticas en la meteorología.

En la siguiente sección se presenta resumidamente el estado del arte y una breve discusión bibliográfica. Luego, en la sección 3 se detallan dos algoritmos implementados, uno clásico y otro cuántico, cuyos resultados muestran la ventaja de usar computación cuántica. Finalmente, en la sección 4 se presentan las conclusiones de este trabajo.

2 Estado del Arte

Existen diversos trabajos relacionados con mejorar la medición meteorológica y mejorar los métodos numéricos asociados a la computación de la meteorología como se presenta en [Kaur \(2023\)](#), que resume en 4 las líneas de investigación para desarrollar el NWP, idealmente siendo métodos cuánticos puros:

1. Método de Diferencias Finitas ([Chagneau et al. 2023](#))
2. Transformada rápida de Fourier (FFT, del inglés *Fast Fourier Transform*) ([Asaka et al. 2020](#))
3. Transformada de Fourier ([Bäumer et al. 2024](#))
4. Método de Monte Carlo ([Gubernatis et al. 2016](#))

El método llamado predictor-corrector, es usado por el framework de modelamiento ICON (*Icosahedral Nonhydrostatic*), que en 2024 fue liberado como open source, y ha sido el método de meteorología actual que utiliza técnicas avanzadas de corrección temporal que garantizan una resolución precisa para la evolución atmosférica en la malla icosaédrica, optimizando la predicción en diversos escenarios climáticos.

Para traducir los métodos centrales de ICON a computación cuántica, se puede considerar las siguientes adaptaciones:

- La estructura de malla y la discretización espacial en ICON, basada en un esquema icosaédrico que minimiza los problemas de los polos y consigue una malla global casi uniforme, utiliza métodos de volúmenes finitos o diferencias finitas para capturar la dinámica atmosférica con precisión. La computación cuántica podría mejorar la eficiencia en estos problemas espacialmente discretizados mediante el uso de algoritmos como la Transformada Cuántica de Fourier (QFT, del inglés *Quantum Fourier Transform*), la cual facilita descomposiciones espectrales en mallas y acelera la resolución de problemas espaciales complejos. Además, versiones cuánticas de los métodos de diferencias y volúmenes finitos, como el Método Cuántico de Diferencias Finitas (QFD, del inglés *Quantum Finite Difference*) investigado por [Chagneau et al. \(2023\)](#), podrían aproximar eficientemente las derivadas en las ecuaciones de Navier-Stokes dentro de la malla icosaédrica, optimizando la eficiencia computacional de ICON.
- ICON aplica esquemas avanzados de integración temporal, como el predictor-corrector o Runge-Kutta, para resolver ecuaciones de manera iterativa y garantizar estabilidad y precisión en modelos atmosféricos no lineales y dinámicos. La adaptación de estos métodos al ámbito cuántico podría proporcionar ventajas significativas: el primero nombrado por [Zanger et al. \(2021\)](#) mostró una forma de tratar la aproximación Runge-Kutta mediante computación cuántica, indicando que al utilizar estos métodos como bloques cuánticos, es posible mejorar el paralelismo y abordar problemas inversos complejos inherentes al método. La computación cuántica, al explotar este paralelismo y técnicas como el recocido cuántico, puede también mejorar los esquemas implícitos, haciéndolos más eficientes y escalables, aspectos cruciales en simulaciones atmosféricas que requieren alta precisión y estabilidad. El método Runge-Kutta, tal como se emplea en el modelo meteorológico COSMO según [Deutscher Wetterdienst \(2024\)](#), es esencial en la integración temporal de ecuaciones diferenciales en simulaciones meteorológicas de gran escala, siendo este modelo un predecesor de ICON. En 2024, ICON ha continuado esta tradición y ha liberado su código como open source, promoviendo una mayor accesibilidad en el modelado climático.
- Para mejorar la predicción y la cuantificación de la incertidumbre, ICON utiliza métodos de asimilación de datos y predicción por conjuntos, donde se ejecutan múltiples simulaciones con ligeras variaciones en condiciones iniciales para capturar un rango de posibles resultados. La computación cuántica podría aportar a este proceso mediante técnicas de predicción de conjuntos cuánticos [Macaluso et al. \(2022\)](#), que emplean superposición para manejar múltiples estados simultáneamente y optimizan el muestreo estocástico en la asimilación de datos, como el Muestreo Cuántico de Monte Carlo ([Gubernatis et al. 2016](#)).
- En su núcleo, ICON depende de la resolución de las ecuaciones de Navier-Stokes compresibles, unas ecuaciones diferenciales parciales (PDEs, del inglés *Partial Differential Equation*) complejas y no lineales que describen el flujo de fluidos, y cuya solución es computacionalmente exigente. Los avances recientes en algoritmos cuánticos para la resolución de PDEs ([Zanger et al. 2021](#)), como el algoritmo HHL (por sus autores Harrow, Hassidim y Lloyd) para sistemas lineales, ofrecen métodos

para aproximar soluciones en componentes linealizadas de Navier-Stokes, y los algoritmos cuánticos adaptados para PDEs no lineales podrían reducir notablemente la carga computacional. Dado que un modelo totalmente cuántico de las ecuaciones de Navier-Stokes sigue siendo un desafío, un enfoque híbrido en el cual la computación cuántica resuelva partes específicas de las ecuaciones, como la modelización de turbulencias o características particulares del flujo, mientras los sistemas clásicos procesan el resto, podría optimizar la eficiencia y permitir a ICON aprovechar progresivamente los recursos cuánticos.

Si bien el método más utilizado para la resolución de *weather forecasting* es NWP, existe también una aproximación de *Machine Learning* (ML) (Wang et al. 2019). Los algoritmos de aprendizaje automático cuántico (QML, del inglés *Quantum Machine Learning*), incluyendo redes neuronales cuánticas (QNN, del inglés *Quantum Neural Networks*), podrían procesar grandes volúmenes de datos atmosféricos y mejorar la precisión en la identificación de patrones no lineales, incrementando así la precisión en la predicción por conjuntos y la interpretación de sistemas meteorológicos caóticos. Uno de los enfoques más prometedores es la aplicación de QNN, que pueden aprovechar la superposición y el entrelazamiento, fenómenos propios de la mecánica cuántica, para procesar información de manera más eficiente que las redes neuronales clásicas. Esto podría permitir la identificación de patrones complejos y no lineales en los datos meteorológicos, mejorando la precisión de las predicciones, especialmente en la anticipación de eventos extremos como huracanes, inundaciones o sequías.

En la literatura se revela un creciente interés en la aplicación de la computación cuántica a la meteorología, particularmente en la NWP y la predicción por conjuntos. Los hallazgos clave apuntan a que la computación cuántica tiene el potencial de abordar algunas de las limitaciones computacionales de los métodos clásicos, como la simulación eficiente de sistemas complejos, la optimización de parámetros del modelo y la gestión de la incertidumbre inherente a los pronósticos meteorológicos.

En varios trabajos, como Palmer (2019), Bauer et al. (2015), y Kaur (2023), se destaca el uso de la computación cuántica y métodos estocásticos para mejorar la predicción climática y meteorológica. Palmer (2019) y Kaur (2023) enfatizan los avances potenciales en la predicción del clima y su relevancia para el cambio climático, mientras que Bauer et al. (2015) discuten la evolución de los métodos de predicción numérica tradicionales que podrían complementarse con enfoques cuánticos, dando lugar a una revolución silenciosa en la predicción meteorológica.

Asaka et al. (2020) y Bäumer et al. (2024) presentan desarrollos en QFT como base de procesamiento en computación cuántica. Aunque ambos estudios se enfocan en optimizar el rendimiento de la QFT, los autores adoptan enfoques distintos. Asaka et al. (2020) desarrollan un circuito específico para realizar QFT de manera más rápida, mientras que Bäumer et al. (2024) exploran el uso de circuitos dinámicos que permiten la implementación más flexible y eficiente en simulaciones cuánticas complejas.

En el ámbito de simulación cuántica y modelado, Chagneau et al. (2023) y Zanger et al. (2021) proponen diferentes enfoques para resolver ecuaciones diferenciales aplicadas a sistemas físicos. Mientras que Chagneau et al. (2023) abordan métodos de diferencia finita para simulaciones en física, Zanger et al. (2021) investigan algoritmos cuánticos que aplican integración clásica para resolver ecuaciones diferenciales. Ambos

enfoques son complementarios, ya que la diferencia finita ofrece soluciones directas y eficientes en ciertos contextos, mientras que los algoritmos cuánticos de Zanger et al. (2021) buscan abordar sistemas altamente complejos y multivariados.

Chattopadhyay et al. (2022) y Reberstrost et al. (2014) exploran el impacto de la simetría y la reducción de la complejidad en los algoritmos cuánticos. Chattopadhyay et al. (2022) se centran en cómo la simetría puede facilitar la conversión de problemas de consulta cuántica a problemas de comunicación, permitiendo simulaciones de mayor precisión. Por otro lado, Reberstrost et al. (2014) abordan el uso de máquinas de soporte vectorial cuánticas (QSVM, del inglés *Quantum Support Vector Machine*), que explotan la complejidad reducida para clasificar grandes volúmenes de datos con un enfoque de QML.

En cuanto a métodos de cuantificación de incertidumbre, Wang et al. (2019) y Leutbecher and Palmer (2008) exploran la importancia de integrar enfoques probabilísticos en la predicción climática. Wang et al. (2019) desarrollan modelos de cuantificación de incertidumbre profunda basados en ML para mejorar la previsión meteorológica, mientras que Leutbecher and Palmer (2008) proponen métodos de predicción por conjuntos que permiten estimar probabilidades de diferentes escenarios meteorológicos. Ambos enfoques contribuyen a la reducción de errores y a una predicción más confiable.

Alford and Wilson (2021) y Palmer (2019) se enfocan en las oportunidades de la computación cuántica en el ámbito meteorológico, pero con perspectivas diferentes. Alford and Wilson (2021) revisan cómo las técnicas cuánticas pueden aplicarse directamente en modelos de predicción meteorológica operativa, destacando avances tecnológicos y posibles desafíos. Palmer (2019), en cambio, pone un mayor énfasis en los modelos estocásticos y en la capacidad de los sistemas cuánticos para manejar mejor la variabilidad inherente del clima y el tiempo.

En la predicción de conjuntos clásica, se ejecutan múltiples simulaciones o modelos de manera independiente uno de los otros, cada ejecución con una ligera variación de las condiciones iniciales o de sus parámetros, buscando generar un espectro de posibles resultados. Este proceso es muy costoso computacionalmente, los modelos altamente dinámicos como el de la atmósfera son especialmente demandantes. La computación cuántica con su capacidad de superposición y entrelazamiento, podría permitir hacer estas simulaciones en paralelo, reduciendo no solo los tiempos de ejecución sino que también la carga computacional.

La predicción por conjuntos puede mejorar con la computación cuántica basada en los siguientes elementos:

- **Superposición cuántica para simulaciones simultáneas:** En la computación clásica, los modelos de conjunto deben ejecutar cada simulación secuencialmente o en paralelo, utilizando grandes recursos computacionales. Sin embargo, la computación cuántica puede aprovechar la superposición para codificar múltiples estados iniciales dentro de un solo estado cuántico, lo que permite explorar múltiples resultados en un solo paso computacional. Esto puede hacer que la predicción por conjuntos sea más eficiente y escalable, incluso para sistemas complejos y no lineales como el clima.
- **Muestreo cuántico y predicción probabilística:** Los computadores cuánticos pueden utilizar técnicas de muestreo cuántico para mejorar la generación de miembros del conjunto. Esto significa que pueden representar mejor la incertidumbre

en las condiciones iniciales y los procesos físicos, lo que potencialmente ofrecería distribuciones de probabilidad más precisas para los pronósticos meteorológicos.

- **Mayor diversidad de modelos:** Los algoritmos cuánticos pueden permitir la creación de modelos más diversos dentro de un conjunto al permitir la exploración de más posibles estados del sistema. Esto conduce a una mejor comprensión de eventos extremos o escenarios raros que tal vez no sean capturados con tanta precisión por los métodos de conjunto clásicos.

Los beneficios potenciales de la predicción por conjuntos cuántica se pueden resumir en:

- **Manejo de mayor complejidad:** Los computadores cuánticos están inherentemente diseñados para abordar la naturaleza compleja y caótica de los sistemas atmosféricos. Pueden explorar una gran cantidad de posibles estados y relaciones dentro de los datos, lo que resulta en pronósticos más completos y precisos.
- **Mayor eficiencia:** La predicción por conjuntos clásica requiere recursos computacionales considerables, particularmente cuando se utilizan muchos miembros del conjunto. La computación cuántica puede reducir significativamente el costo computacional al realizar estas tareas de manera más eficiente.
- **Mejor cuantificación de la incertidumbre:** La capacidad de la computación cuántica para manejar problemas probabilísticos puede mejorar la forma en que se cuantifican las incertidumbres en los pronósticos meteorológicos, lo que lleva a una comprensión más profunda del rango potencial de resultados.
- **Soporte para la toma de decisiones más rápida:** Sectores como la gestión de desastres, el transporte y la agricultura dependen en gran medida de pronósticos meteorológicos precisos y oportunos. La predicción por conjuntos mejorada cuánticamente podría proporcionar pronósticos más rápidos con probabilidades mejor definidas, mejorando los procesos de toma de decisiones donde el tiempo es crucial.

3 Algoritmo Clásico y Algoritmo Cuántico

La implementación desarrollada realiza una comparación conceptual entre un método clásico y el uso de la computación cuántica para resolver un sistema dinámico de EDO's. Las EDOs en esta implementación simulan la evolución de un sistema meteorológico de baja complejidad con 4 variables consideradas. Modelos comerciales como ICON el cual es uno de los modelos mas avanzados al día de hoy, puede llegar a usar cientos de variables. El foco de este trabajo es estudiar la factibilidad del uso de herramientas cuánticas para la meteorología.

El modelo meteorológico dinámico simula un sistema dinámico con variables climáticas, tales como temperatura, humedad, presión, y velocidad del viento. Las variables son evaluadas en un conjunto de EDOs las cuales representan el modelo, en que se incluyen factores de ruido para simular incertidumbre y variabilidad ambientales.

Para la solución clásica se usó el método de Runge-Kutta de orden cuatro (RK4) como método numérico para aproximar las soluciones del sistema dinámico descrito

anteriormente. Calculando iterativamente los valores de las variables meteorológicas en un intervalo de tiempo dado.

Para la solución cuántica se usa operaciones cuánticas para resolver RK4, se espera que la diferencia entre clásico y cuántico crezca a medida que se implementa una mayor complejidad en el sistema. Los incrementos intermedios (k_1, k_2, k_3, k_4) de Runge-Kutta se resuelven cuánticamente y los resultados de las operaciones se almacenan en vectores de estado.

Los resultados del método clásico y cuántico son almacenados y se comparan gráficamente. Las curvas en la sección resultados muestran la evolución de las variables en función del tiempo.

La implementación se desarrolló usando el simulador *aer* de Qiskit. Una vez logrado un producto maduro y satisfactorio se usaron los computadores cuánticos de IBM para hacer la evaluación final de resultados.

3.1 Representación

El sistema se define como un conjunto de ecuaciones diferenciales según la ecuación 1.

$$\frac{d\hat{x}_i}{dt} = f_i(\hat{x}, t) \quad (1)$$

donde \hat{x}_i es el vector que representa en cada x_i una variable meteorológica. f_i es la función a evaluar, incluye sus términos, parámetros y ruido. Acá es donde se aplica RK4 para resolver el sistema.

Con el objetivo de probar el resultado y la comparación, se utiliza como f_i las ecuaciones 2 y 3.

$$\frac{dy_1}{dt} = -ay_1 + by_2 + \text{ruido} \quad (2)$$

$$\frac{dy_2}{dt} = -cy_2 + dy_1 + \text{ruido} \quad (3)$$

El *ruido* en cada componente del vector y es generado mediante una distribución normal con media cero y desviación estándar σ . Es decir, para cada componente i de y , se tiene la ecuación 4.

$$\epsilon_i \sim \mathcal{N}(0, \sigma^2) \quad \text{para } i = 1, 2, \dots, n \quad (4)$$

donde n es el número de elementos en el vector y , y cada ϵ_i es independiente y generado de forma aleatoria.

3.2 Descripción del Algoritmo Clásico

Tanto para la solución clásica como para la cuántica se utilizó el mismo método de resolución (Runge-Kutta). Para la solución clásica, se utiliza el algoritmo con el método de Runge-Kutta clásico de orden 4, sin ningún paso extra.

Algoritmo Clásico de Runge-Kutta de cuarto orden

Data: Condiciones iniciales $y_1(0), y_2(0)$, tiempo inicial t_0 , tamaño del paso h , número de pasos n , función $f(t, y)$ que define las ecuaciones.

Result: Solución aproximada $y_1(t)$ y $y_2(t)$ para cada paso.

Inicializar $t \leftarrow t_0$

Inicializar $y \leftarrow [y_1(0), y_2(0)]$

Crear un arreglo vacío *resultados* para almacenar las soluciones

for $i \leftarrow 0$ **to** $n - 1$ **do**

 Almacenar el estado actual en $resultados[i] \leftarrow y$

 Calcular $k_1 \leftarrow f(t, y)$

 Calcular $k_2 \leftarrow f(t + 0.5 \cdot h, y + 0.5 \cdot h \cdot k_1)$

 Calcular $k_3 \leftarrow f(t + 0.5 \cdot h, y + 0.5 \cdot h \cdot k_2)$

 Calcular $k_4 \leftarrow f(t + h, y + h \cdot k_3)$

 Actualizar $y \leftarrow y + \frac{h}{6} \cdot (k_1 + 2 \cdot k_2 + 2 \cdot k_3 + k_4)$

 Incrementar el tiempo $t \leftarrow t + h$

end

return *resultados*

3.3 Descripción del Algoritmo Cuántico

El algoritmo clásico se modificó para agregar estados cuánticos al método según el siguiente algoritmo.

Algoritmo Híbrido Cuántico para evolución de sistemas dinámicos

Data: Condiciones iniciales $y_1(0), y_2(0)$, tiempo inicial t_0 , tamaño del paso h , número de pasos n , función $f(t, y)$ para las ecuaciones.

Result: Estados cuánticos representando $y_1(t)$ y $y_2(t)$, y mediciones finales.

Inicializar circuito cuántico qc con 2 qubits y 2 bits para medición

Inicializar $y \leftarrow [y_1(0), y_2(0)]$

Crear una lista $y_{\text{quantum}} \leftarrow [y]$ para almacenar los estados

Preparación del estado inicial:

- Normalizar $y_1(0)$ y $y_2(0)$ para obtener componentes cuánticas $norm_{y1}, norm_{y2}$ y y_{1_init}, y_{2_init}
- Inicializar los qubits con el estado $[norm_{y1}, y_{1_init}, norm_{y2}, y_{2_init}]$

for $i \leftarrow 0$ **to** $n - 1$ **do**

 Calcular $y \leftarrow \text{runge_kutta_step}(y, t_0 + i \cdot h, h)$

 Añadir y a y_{quantum}

Representar los nuevos estados en el circuito:

- Calcular ángulos de rotación $\theta_1 \leftarrow 2 \cdot \arcsin(y[0]), \theta_2 \leftarrow 2 \cdot \arcsin(y[1])$
- Aplicar rotaciones $R_y(\theta_1)$ y $R_y(\theta_2)$ en los qubits correspondientes

Medición:

- Medir qubits y almacenar resultados en los bits clásicos

end

Ejecutar el circuito cuántico con múltiples repeticiones

Obtener los conteos de mediciones para cada estado

Postprocesamiento:

- Calcular probabilidades a partir de los conteos
- Estimar valores finales y_1 y y_2 combinando probabilidades con valores iniciales

return y_{quantum} (trayectorias cuánticas) y las estimaciones finales

3.4 Experimentos

Para obtener resultados y comparar el desempeño del algoritmo clásico con el algoritmo cuántico se evaluaron 4 casos (Caso 1, Caso 2, Caso 3 y Caso 4). A continuación se entrega la descripción de cada caso, con sus parámetros y condiciones iniciales.

Los parámetros del Caso 1 son:

- $\sigma = 0.1$ # Desviación estándar del ruido
- $a = 0.1$ # Tasa de enfriamiento de la temperatura
- $b = 0.5$ # Influencia de la humedad sobre la temperatura
- $c = 0.5$ # Tasa de disminución de la humedad
- $d = 0.2$ # Influencia de la temperatura sobre la humedad

Las condiciones iniciales del Caso 1 son:

- $y_1(0) = 20$ # Temperatura inicial ($^{\circ}\text{C}$)
- $y_2(0) = 40$ # Humedad inicial (%)
- $t_0 = 0$ # Tiempo inicial (s)
- $h = 0.1$ # Tamaño del paso (s)
- Número de pasos: 12

Las condiciones iniciales del Caso 2 son iguales al Caso 1. Los parámetros del Caso 2 son:

- $\sigma = 0.1$ # Desviación estándar del ruido
- $a = 0.12$ # Tasa de enfriamiento de la temperatura
- $b = 0.45$ # Influencia de la humedad sobre la temperatura
- $c = 0.15$ # Tasa de disminución de la humedad
- $d = 0.25$ # Influencia de la temperatura sobre la humedad

Los parámetros del Caso 3 son:

- $\sigma = 0.15$ # Desviación estándar del ruido
- $a = 0.12$ # Tasa de enfriamiento de la temperatura
- $b = 0.45$ # Influencia de la humedad sobre la temperatura
- $c = 0.15$ # Tasa de disminución de la humedad
- $d = 0.25$ # Influencia de la temperatura sobre la humedad

Las condiciones iniciales del Caso 3 son:

- $y_1(0) = 18$ # Temperatura inicial ($^{\circ}\text{C}$)
- $y_2(0) = 55$ # Humedad inicial (%)
- $t_0 = 0$ # Tiempo inicial (s)
- $h = 0.1$ # Tamaño del paso (s)
- Número de pasos: 12

Las condiciones iniciales del Caso 4 son iguales al Caso 3. Los parámetros del Caso 4 son iguales al Caso 3, solo que cambia la desviación estándar del ruido por $\sigma = 0.12$.

3.5 Resultados

En la Figura 1 se muestra la simulación del clima del Caso 1 con los resultados de ambos algoritmos, clásico y cuántico. El error que se observa en y_1 (Temperatura) entre clásico y cuántico es de 79.92412843835095. Mientras que el error en y_2 (Humedad) entre clásico y cuántico es de 8.55457452855834.

En la Figura 2 se muestra otra simulación del clima con los datos del Caso 2 y los resultados de ambos algoritmos, clásico y cuántico. El error que se observa en y_1 entre clásico y cuántico es de 195.74847703996056. Mientras que el error en y_2 entre clásico y cuántico es de 103.53836515812696.

En la Figura 3 se muestra la simulación del clima para el Caso 3 con los resultados de ambos algoritmos, clásico y cuántico. El error que se observa en y_1 entre clásico y cuántico es de 244.60986656903427. Mientras que el error en y_2 entre clásico y cuántico es de 122.81526299657705.




Fig. 1 Simulación del clima (clásico versus cuántico) para el Caso 1




Fig. 2 Simulación del clima (clásico versus cuántico) para el Caso 2

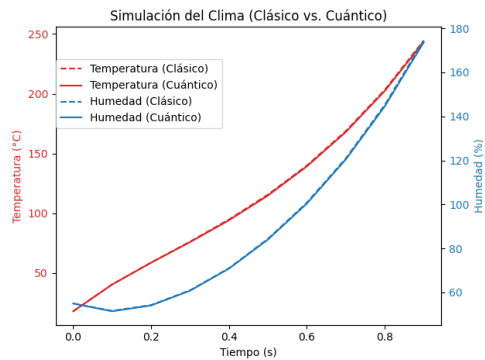


Fig. 3 Simulación del clima (clásico versus cuántico) para el Caso 3

La Figura 4 muestra la simulación del clima para el Caso 4 con los resultados de ambos algoritmos, clásico y cuántico. El error que se observa en y_1 entre clásico y

cuántico es de 243.3764860297735. Mientras que el error en y_2 entre clásico y cuántico es de 122.60614016332269.




Fig. 4 Simulación del clima (clásico versus cuántico) para el Caso 4

Si bien las 3 gráficas de las Figuras 2, 3 y 4 parecen representar igualdad en los resultados de ambos algoritmos, el error en los resultados finales para humedad y temperatura difieren, los valores tienden a ir en la misma dirección, debido a la importancia de la función.

4 Conclusiones

El futuro de los modelos de predicción meteorológica apunta claramente a una colaboración entre la computación cuántica y los métodos clásicos. Aunque la dependencia exclusiva de sistemas cuánticos aún se vislumbra lejana, los modelos híbridos y la investigación en algoritmos específicamente diseñados para entornos cuánticos ofrecen una promesa sólida de hacer que las predicciones meteorológicas sean más eficientes, precisas y oportunas. Esta sinergia entre enfoques abre un horizonte de posibilidades para la ciencia atmosférica y la tecnología predictiva del clima, con una implementación acelerada que resulta crucial en el contexto del cambio climático, donde la precisión en la predicción es cada vez más urgente.

Una vía viable para aplicar esta colaboración cuántico-clásica es comenzar transformando gradualmente componentes específicos del modelo ICON a operaciones cuánticas. ICON, que desde el 2024 se ha liberado como código abierto, ofrece una oportunidad única para experimentar con sus algoritmos y evaluar el impacto de un modelamiento híbrido en comparación con el enfoque clásico. Inicialmente, podrían aplicarse métodos cuánticos en subprocesos específicos de la meteorología que devuelvan resultados en formato clásico, lo cual permitiría una transición progresiva y sin interrupciones en el flujo de datos, al mismo tiempo que facilita comparaciones entre el rendimiento del método puramente clásico y el modelo híbrido.

References

- Asaka, R., Sakai, K., Yahagi, R.: Quantum circuit for the fast fourier transform. *Quantum Information Processing* **19**, 277 (2020) <https://doi.org/10.1007/s11128-020-02776-5>
- Alford, M.G., Wilson, M.J.: Quantum computing in weather forecasting. *Bulletin of the American Meteorological Society* **102**(8), 1546–1563 (2021) <https://doi.org/10.1175/BAMS-D-20-0163.1>
- Bauer, P., Thorpe, A., Brunet, G.: The quiet revolution of numerical weather prediction. *Nature* **525**(7567), 47–55 (2015) <https://doi.org/10.1038/nature14956>
- Bäumer, E., Tripathi, V., Seif, A., Lidar, D., Wang, D.S.: Quantum fourier transform using dynamic circuits. *Phys. Rev. Lett.* **133**, 150602 (2024) <https://doi.org/10.1103/PhysRevLett.133.150602>
- Chagneau, A., Nathoo, L., Alloul, J., Gabriel, B.: Quantum finite difference solvers for physics simulation. *IET Quantum Communication* **4**(2), 70–83 (2023) <https://doi.org/10.1049/qtc2.12054> <https://ietresearch.onlinelibrary.wiley.com/doi/pdf/10.1049/qtc2.12054>
- Chakraborty, S., Chattopadhyay, A., Høyer, P., Mande, N., Paraashar, M., de Wolf, R.: Symmetry and quantum query-to-communication simulation. In: 39th International Symposium on Theoretical Aspects of Computer Science (STACS 2022). *Leibniz International Proceedings in Informatics (LIPIcs)*, vol. 219, pp. 28–12819. Schloss Dagstuhl–Leibniz-Zentrum für Informatik, Dagstuhl (2022). <https://doi.org/10.4230/LIPIcs.STACS.2022.20>
- Deutscher Wetterdienst: Numerical methods. Accessed: 2024-10-12 (n.d.). https://www.dwd.de/EN/research/weatherforecasting/num_modelling/01_num_weather_prediction_modells/01a_num_methods/numerical_methods.html?nn=484268
- Gubernatis, J., Kawashima, N., Werner, P.: *Quantum Monte Carlo Methods*. Cambridge University Press, Cambridge (2016)
- Kaur, A.: Quantum computers: Advancement in weather forecasts and climate change mitigation. *Medium* (2023). Accessed: 2024-10-13
- Leutbecher, M., Palmer, T.N.: Ensemble forecasting. *Journal of Computational Physics* **227**(7), 3515–3539 (2008) <https://doi.org/10.1016/j.jcp.2007.02.014>
- Li, S., Wu, Y., Chen, Y.: A systematic and bibliometric review of the latest techniques in quantum-dot computers. *Optik* **283**, 170893 (2023) <https://doi.org/10.1016/j.ijleo.2023.170893>
- Macaluso, A., Clissa, L., Lodi, S., Sartori, C.: *Quantum Ensemble for Classification*

(2022). <https://arxiv.org/abs/2007.01028>

Palmer, T.N.: Quantum computing and the future of weather and climate prediction. *Quantum Science and Technology* **4**(4), 043001 (2019) <https://doi.org/10.1088/2058-9565/ab3d2f>

Rebentrost, P., Mohseni, M., Lloyd, S.: Quantum support vector machine for big data classification. *Physical Review Letters* **113**(13), 130503 (2014) <https://doi.org/10.1103/PhysRevLett.113.130503>

Wang, B., Lu, J., Yan, Z., Luo, H., Li, T., Zheng, Y., Zhang, G.: Deep Uncertainty Quantification: A Machine Learning Approach for Weather Forecasting (2019). <https://arxiv.org/abs/1812.09467>

Zanger, B., Mendl, C.B., Schulz, M., Schreiber, M.: Quantum algorithms for solving ordinary differential equations via classical integration methods. *Quantum* **5**, 502 (2021) <https://doi.org/10.22331/q-2021-07-13-502>