RedUNCI

WICC 2021 Chilecito La Rioja

UNdeC

XXIII Edición del Workshop de Investigadores en Ciencias de la Computación

LIBRO de ACTAS

Abril 2021 - Chilecito – La Rioja – Argentina
Universidad Nacional de Chilecito - UNdeC
Red de Universidades con Carreras de Informática - RedUNCI

Frati, Fernando Emmanuel
XXIII Edición del Workshop de Investigadores en Ciencias de la Computación / Fernando Emmanuel Frati ; Fernanda Beatriz Carmona. - 1a ed adaptada. - Chilecito : UNdeC, 2021.
Libro digital, PDF

Archivo Digital: descarga y online
ISBN 978-987-24611-3-3

1. Computación. I. Carmona, Fernanda Beatriz. II. Título.
CDD 004.071

Optimización de Carteras de Inversión: Un Benchmark con Modelos Clásico, de Computación Cuántica y de Hibridación AI /QC

Juan Pablo Braña, Alejandra M.J. Litterio y Alejandro Fernández
Centro de Altos Estudios en Tecnología Informática- Facultad de Tecnología Informática - U.A.I
Av. Montes de Oca 745 - (C1270AAH) Ciudad Autónoma de Buenos Aires, República Argentina
{juan.brana, alejandra.litterio, alejandroa.fernandez}@uai.edu.ar

RESUMEN

La optimización de carteras de inversión representa un desafío para el inversor al momento de seleccionar la combinación correcta de acciones a efectos de maximizar los retornos esperados y minimizar los riesgos. Es así que en contraste con el paradigma de la computación tradicional, la computación cuántica no sólo acelera de manera sustancial el proceso de las computadoras tradicionales si no que optimiza la performance del método que determina cuáles acciones deben ser incluidas en las carteras de inversión y cuáles no. En este trabajo presentamos un estudio de comparación y referencia entre el resultado obtenido por tres diferentes metodologías de optimización de cartera: a) aproximación clásica, b) aproximación cuántica, c) un híbrido entre la aproximación cuántica incorporando criterios de Inteligencia Artificial. Para el primero de los casos utilizamos el modelo de Markowitz, el cual es un algoritmo clásico para determinar carteras eficientes, para nuestra aproximación cuántica hemos trabajado con un algoritmo de optimización cuántico llamado *Variational Quantum Eigensolver* (VQE) y por último hemos intentado mejorar este último criterio de optimización con un índice de sentimiento calculado con procesamiento de lenguaje natural (NLP) y una métrica de *forecasting* multivariado basado en *Machine Learning.*

Palabras clave: Computación Cuántica, Procesamiento de Lenguaje Natural Cuántico, Optimización de Cartera de Inversión, Finanzas, Machine Learning, AI

CONTEXTO

El presente trabajo es parte del proyecto “Inteligencia Artificial y Computación Cuántica en Finanzas”, iniciado en Marzo 2020, el cual se desarrolla en el Centro de Altos Estudios en Tecnología Informática (CAETI) dependiente de la Facultad de Tecnología Informática de la Universidad Abierta Interamericana (UAI). Se enmarca dentro de la línea de Algoritmos y Software y continúa las investigaciones iniciadas en el proyecto “Modelo de Sentiment Analysis para la clasificación de noticias en tiempo real”. Es financiado y evaluado por la Secretaría de Investigación de la Universidad. Cuenta con la participación de docentes y alumnos de la Maestría en Tecnología Informática y de la Diplomatura en Análisis de Datos para Negocios, Finanzas e Investigación de Mercados.

1. INTRODUCCION

El inversor racional siempre ha buscado dos metas cuando toma la decisión de conformar una cartera de inversión: a) maximizar los retornos, b) disminuir el riesgo. Para ello, diferentes metodologías han sido empleadas, desde un enfoque clásico como el Modelo de Markowitz [12], uno de mayor reconocimiento por la industria financiera, por un lado, y un enfoque moderno, por el otro lado, que nos presenta algoritmos de *Machine Learning*, tanto modelos supervisados como no-supervisados que permiten la selección de instrumentos financieros y su rebalanceo periódico de la cartera, incluso, híbridos con Aprendizaje por Refuerzo (*Reinforcement Learning*) los que han sido presentados con éxito [1].
En relación a lo mencionado y trabajos anteriores han realizado numerosos experimentos y benchmarking en un esfuerzo por evaluar y e identificar las ventajas en aplicaciones en el mundo real [6], [8]. De la misma manera, se ha observado que la Computación Cuántica (QC) cuenta con el potencial de resolver problemas de índole financiera como detección de fraude, *pricing* de derivados [6], [8], [14], [16], [18] riesgo crediticio [5], [19], entre otros. En particular, el caso que nos ocupa, la Computación Cuántica como mecanismo de optimización de carteras de inversión ha introducido un nuevo paradigma [10], [11], [13], [15], [17]. Además, se espera que la fusión entre la Computación Cuántica y la Inteligencia Artificial sea la próxima revolución que cambie el rumbo de la industria, no solo la financiera, sino cualquiera relacionada con grandes volúmenes de procesamiento, velocidad y seguridad en los datos.

2. LÍNEAS DE INVESTIGACIÓN Y DESARROLLO

El presente estudio se enmarca en la investigación de aplicación de técnicas y algoritmos de minería de datos y pretende dar un enfoque y soporte académico a toda la comunidad sea que esté relacionada a la industria financiera o dentro del marco académico. En este estudio, damos continuidad a las estrategias desarrolladas para codificar algoritmos de *Machine Learning* en computadoras cuánticas para la administración de carteras de inversión y su relación con trading algorítmico.

3. RESULTADOS OBTENIDOS/ESPERADOS

Pregunta Problema:
Una aproximación híbrida entre la Computación Cuántica e Inteligencia Artificial podría conseguir mejores resultados para un modelo de optimización de cartera de inversión en comparación con los resultados obtenidos con una aproximación que solo utiliza Computación Cuántica.

Objetivo General:
Realizar un benchmark entre los resultados obtenidos por un modelo clásico, uno basado en Computación Cuántica, y otro híbrido entre Computación Cuántica e Inteligencia Artificial.

Objetivos Específicos:
a. Crear una metodología que permita generar un modelo híbrido entre los resultados obtenidos por los modelos de *Machine Learning* de *forecasting*, nuestro indicador de Sentimiento y los resultados provistos por el algoritmo cuántico QVE.
b. Testear nuestros desarrollos contra una de las computadoras cuánticas físicas de 5 qubits (no simuladores) que provee IBM.

Metodología de Trabajo

En nuestra investigación hemos creado un panel que permite:
a. Seleccionar cinco instrumentos financieros y
b. Correr: (i) En primera instancia: un modelo tradicional de Markowitz; (ii) en segunda instancia un algoritmo cuántico (VQE) desarrollado por la comunidad de Qiskit [21] y (iii) en tercera instancia un algoritmo desarrollado por nuestro equipo de investigadores que conjuga el algoritmo VQE del punto anterior, pero le agrega una capa de lógica y confirmación de la compra/venta de instrumentos con reglas de nuestro desarrollo de la fase anterior de índice de sentimiento más un índice de *forecasting* realizado con Modelos de *Machine Learning*.

Nuestra estrategia se basa en un criterio de asignar un instrumento financiero que tiene el potencial de conformar la cartera de inversión a un qubits de una computadora cuántica, cuando el estado de ese qubits se acerca a 0 una regla lógica nos indica que ese instrumento no ingresa a la cartera de inversión o lo hace en un porcentaje muy bajo, por el contrario, cuando el estado de un qubits se acerca a 1, ese instrumento ingresa a la cartera de inversión con un porcentaje alto. En este punto nos parece importante aclarar que la cantidad de cinco instrumentos a optimizar en este trabajo no es arbitraria, sino que se justifica teniendo en cuenta que la compañía IBM, con su servicio IBM-Q Experience brinda una serie de computadoras cuánticas físicas de 5 qubits de manera libre y gratuita, lo cual presenta un excelente entorno de desarrollo y testing.

Recordemos también que en trabajos anteriores hemos presentado diferentes algoritmos de NLP [3], [20], que permitían procesar noticias financieras en tiempo real con nuestro lexicón FSAL [2] asignándoles un índice de sentimiento que a su vez se reforzaba con un indicador de predicción (*forecasting*) realizado con redes neuronales LSTM. En el presente trabajo, ambos indicadores brindan una capa de ajuste para determinar con que peso un instrumento ingresa a la cartera o no lo hace.

Resultados Obtenidos /Esperados

A. Resultados Obtenidos

Realizando un *backtesting* de los tres criterios de comparación descriptos previamente hemos obtenido los siguientes resultados en nuestra primera fase:

- Las carteras de inversión con los retornos más altos, a menor riesgo fueron obtenidos en un 92% por la APROXIMACIÓN CLÁSICA.
- El 8% de las veces, nuestro DESARROLLO HÍBRIDO entre la aproximación Cuántica con AI ha superado a la APROXIMACIÓN CLÁSICA.
- El 89% de las veces, nuestro desarrollo híbrido ha sido mejor que el netamente CUÁNTICO sin AI.

B. Resultados Esperados

Como se ha mencionado, solo hemos podido experimentar con la generación de carteras con hasta cinco (5) instrumentos financieros. Al momento de escribir este trabajo, IBM ha liberado computadoras cuánticas con hasta 16 qubits y se espera que pronto haga lo propio con 65 qubits, lo que nos permitirá ampliar nuestro universo de manera considerable. Cuando esto suceda, y cuando los algoritmos cuánticos, los cuales se encuentran en parmente desarrollo y actualización, esperamos que estos resultados obtenidos de manera provisoria se reviertan hasta el punto de que la aproximación híbrida Cuántica con *Machine Learning* se

acerque e incluso mejore la performance de la aproximación Clásica.

4. FORMACIÓN DE RECURSOS HUMANOS

El proyecto consta de un equipo multidisciplinario conformado por docentes de la Diplomatura en Análisis de Datos para Negocios, Finanzas e Investigación de Mercado, y la Maestría en Tecnología Informática así como expertos del área de Lingüística y Finanzas. Por su parte, señalamos que el proyecto contará con la participación de alumnos avanzados de la Maestría en Tecnología Informática, quienes llevan a cabo su pasantía de investigación al tiempo que identifican temas en los que puedan desarrollar su tesis. Además se cuenta con la colaboración de alumnos de la mencionada Diplomatura.

5. BIBLIOGRAFÍA

[1] Alcazar, J., Leyton-Ortega, V. and A. Perdomo-Ortiz (2020). Classical versus Quantum Models in Machine Learning: Insights from a Finance Application en *arXiv:1908.10778v2 [quant-ph] 8 Jan 2020.*

[2] Braña, J.P., Litterio, A.M.J. and A. Fernández (2018). "FSAL: Lexicón financiero de sentimiento en español rioplatense diseñado para "Bolsas y Mercados Argentinos" (BYMA) en Revista Abierta de Informática Aplicada (RAIA), vol.2, Nro1., 2018. ISSN: 2591-5320. Disponible en: **http://portalreviscien.uai.edu.ar/ojs/index.php/RAIA/article/view/159**

[3] Braña, J.P., Litterio, A.M.J. and A. Fernández. (2020). "Inteligencia Artificial y Computación Cuántica en Finanzas". XXII Workshop de Investigadores en Ciencias de la Computación WICC 2020. Universidad Nacional de la Patagonia Austral (UNPA), El Calafate, Santa Cruz, Argentina. 25 de Mayo de 2020.

[4] Dasgupta, S., Banerjee, A. (2019). Quantum Annealing Algorithm for Expected Shortfall based Dynamic Asset Allocation en *arXiv:1909.12904v1 [q-fin.RM] 27 Sep 2019.*

[5] Egger, D., García Gutiérrez, R., Cahué Mestre, J. and S. Woerner (2019). Credit Risk Analysis using Quantum Computers en *arXiv:1907.03044v1 [quant-ph] 5 Jul 2019.*

[6] Hao, W., Lefevre, C., Tamturk, M. and S. Utev, (2019). Quantum option pricing and data analysis en *Quantitative Finance and Economics*, QFE, 3(3): 490–507. DOI:10.3934/QFE.2019.3.490

[7] Grant, E., Humble, T. and B. Stump (2021). Benchmarking Quantum Annealing Controls with Portfolio Optimization, in Physical Review Applied 15,014012. DOI: 10.1103/PhysRevApplied.15.014012

[8] Gonzalez-Conde, J., Rodriguez –Rosas, A., Solano, E. and M. Sanz (2021). Pricing Financial Derivatives with Exponential Quantum Speedup in Quantum Physics (quant-ph), arXiv:2101.04023 [quant-ph]

[9] Hodson, M., Ruck, B., Ongy, H., Garvin, D., and S. Dulman. (2019). Portfolio rebalancing experiments using the Quantum Alternating Operator Ansatz en *arXiv: 1911.05296v1 [quant-ph] 13 Nov 2019.*

[10] Kerenidis, I., Prakash, A. and D. Szilagyi. (2019). Quantum Algorithms for Portfolio Optimization en arXiv: 1908.08040v1 [math.OC] 22 Aug 2019.

[11] Mahajan, R.P. (2011). A Quantum Neural Network Approach for Portfolio Selection en *International Journal of Computer Applications*, Volume 29– No.4, September 2011.

[12] Markowitz, H. (1952). Portfolio Selection in The Journal of Finance Vol. 7, No. 1 (Mar., 1952), pp. 77-91

[13] Marzec, M. (2016). "Portfolio Optimization: Applications in Quantum Computing", en Ionut Florescu, Maria C. Mariani, H. Eugene Stanley, Frederi G. Viens (eds.) Handbook of High-Frequency Trading and Modeling in Finance, John Wiley & Sons, Inc.

[14] Martin, A., Candelas, B., Rodríguez-Rozas, Martín-Guerrero, J. Chen, X., Lamata, L., Orus, R., Solano, E. and M. Sanz (2019). Towards Pricing Financial Derivatives with an IBM Quantum Computer en *arXiv: 1904.05803v1 [quant-ph] 11 Apr 2019.*

[15] Mugel, S., Kuchkovsky, C., Sánchez, E., Fernández-Lorenzo, S., Luis-Hita, J., Lizaso, E. and R. Orús (2020). Dynamic Portfolio Optimization with Real Datasets Using
Quantum Processors and Quantum-Inspired Tensor Networks, in arXiv:2007.00017 [quant-ph]

[16] Orrell, D. (2020). A Quantum Walk Model of Financial Options (January 1, 2020). Available at SSRN: https://ssrn.com/abstract=3512481 or http://dx.doi.org/10.2139/ssrn.3512481

[17] Orus, R., Mugel, S. and E. Lizaso (2019). Quantum computing for finance: overview and prospects en Reviews in Physics, Volume 4, November 2019, 100028. https://doi.org/10.1016/j.revip.2019.100028
[18] Stamatopoulos, N., Egger, D.J., Sun, Y., Zoufal, C., Iten, R., Shen, N. and S. Woerner. (2020). Option Pricing using Quantum Computers en *arXiv: 1905.02666 [quant-ph], 17 Feb 2020*.
[19] Woerner, S., Egger, D.J. Quantum risk analysis. En *NPJ Quantum Inf,* 5, 15 (2019). https://doi.org/10.1038/s41534-019-0130-6.
[20] Zeng, W. and Coecke, B. (2016) Quantum Algorithms for Compositional Natural Language Processing en Kartsaklis, D., Lewis, M. and Rimell, L. (Eds) *2016 Workshop on Semantic Spaces at the Intersection of NLP, Physics and Cognitive Science* (SLPCS'16) EPTCS 221, 2016, pp. 67–75, doi:10.4204/EPTCS.221.8
[21] IBM Qiskit Portfolio Optimization Tutorial https://qiskit.org/documentation/tutorials/finance/01_portfolio_optimization.html