



# QUANTUM SUPPORT VECTOR MACHINES IN CARDIAC SOUND ANALYSIS: EVALUATING PERFORMANCE WITH SIGNAL REPRESENTATION TECHNIQUES

*Antonio J. Muñoz Montoro<sup>1</sup>, Pablo Revuelta Sanz<sup>2</sup>, Juan De La Torre Cruz<sup>3</sup>, Francisco J. Cañadas Quesada<sup>3</sup>, Jose Ranilla Pastor<sup>2</sup>*

<sup>1</sup> Universidad de Málaga, Málaga, España

<sup>2</sup> Universidad de Oviedo, Gijón, España

<sup>3</sup> Universidad de Jaén, Linares, España

## RESUMEN

El análisis de los sonidos cardíacos desempeña un papel crucial en la detección y diagnóstico de enfermedades cardiovasculares. Con los avances en el procesamiento digital de señales y las técnicas de inteligencia artificial, la clasificación automática de estos sonidos se ha convertido en un campo de investigación activo. Este estudio aborda los desafíos y oportunidades de aplicar modelos de aprendizaje cuántico (QML) en el análisis de sonidos cardíacos reales. El objetivo de este trabajo es evaluar el rendimiento de las máquinas de soporte vectorial cuánticas (QSVM) utilizando diferentes técnicas de representación de señales como la transformada de Fourier de tiempo corto (STFT), los coeficientes cepstrales de Mel-frecuencia (MFCC) y los cocleogramas. Los experimentos realizados, en los cuales se utilizan máquinas de soporte vectorial clásicas (SVM) como referencia, indican una clara viabilidad para incorporar técnicas cuánticas en el análisis y diagnóstico de enfermedades cardiovasculares, especialmente cuando hay pocos ejemplos y se utilizan un número reducido de características. Este hecho podría mejorar significativamente la precisión y eficacia de los métodos de detección utilizados en este contexto, donde generalmente hay datos limitados disponibles.

## ABSTRACT

The analysis of cardiac sounds plays a crucial role in the detection and diagnosis of cardiovascular diseases. With advances in digital signal processing and artificial intelligence techniques, the automatic classification of these sounds has become an active field of research. This study addresses the challenges and opportunities of applying quantum machine learning (QML) models in the analysis of real cardiac sounds. The goal of this work is to evaluate the performance of quantum support vector machines (QSVM) using different signal representation techniques such as Short-Time Fourier Transform (STFT), Mel-Frequency Cepstral Coefficients (MFCC), and cochleograms. The conducted experiments, where classical support vector

machines (SVM) are used as reference, indicate a clear feasibility to incorporate quantum techniques in the analysis and diagnosis of cardiovascular diseases, especially when there are few examples, and a reduced number of features are used. This fact could significantly improve the accuracy and effectiveness of the detection methods used in this context where, precisely, there is usually limited data available.

**Palabras Clave**— quantum machine learning, heart sound classification, quantum support vector machines, signal representation.

## 1. INTRODUCCIÓN

Las enfermedades cardiovasculares imponen un impacto significativo en el sistema de salud a nivel mundial, con millones de muertes anuales y un sustancial impacto económico en los sistemas de atención médica. La detección temprana y el diagnóstico preciso de estas enfermedades son imperativos para lograr un tratamiento efectivo y prevenir complicaciones graves. En este contexto, el análisis de los sonidos cardíacos emerge como un recurso esencial, proporcionando información crucial sobre la función cardíaca y asistiendo a los profesionales médicos en la identificación de posibles anomalías que puedan requerir evaluación adicional.

Históricamente, el análisis de los sonidos cardíacos se ha basado en técnicas como la auscultación, en la que los médicos escuchan los sonidos producidos por el corazón utilizando un estetoscopio. Sin embargo, esta auscultación manual es subjetiva y depende en gran medida de la experiencia y la pericia del profesional, lo que puede dar lugar a variaciones en la interpretación. Además, puede ser un desafío detectar anomalías sutiles o clasificar con precisión los sonidos cardíacos basándose únicamente en señales auditivas percibidas.

Para superar estas limitaciones y mejorar la precisión y eficiencia en el análisis de los sonidos cardíacos, los

investigadores han recurrido a técnicas de procesamiento de señales digitales y aprendizaje automático. Entre estas técnicas, los coeficientes cepstrales de Mel-frecuencia (MFCCs) han ganado amplia aceptación. Estos coeficientes se emplean comúnmente en aplicaciones de reconocimiento de voz, análisis musical y otras disciplinas relacionadas con el procesamiento de audio. Los MFCCs permiten extraer características relevantes vinculadas con la distribución de frecuencias y la energía de los sonidos cardíacos, las cuales luego sirven como entradas para algoritmos de aprendizaje automático destinados a la clasificación de los sonidos cardíacos [1].

En este contexto, han surgido numerosos algoritmos de aprendizaje automático, como pueden ser las máquinas de soporte vectorial (SVM) [1], las redes neuronales (NN) [1] y los bosques aleatorios (RF) [2], mostrando resultados prometedores cuando se combinan con características basadas en MFCC para la clasificación de los sonidos cardíacos. Estos enfoques ofrecen soluciones no invasivas, rentables y automatizadas para la detección temprana de enfermedades cardiovasculares, lo que permite intervenciones oportunas que pueden mejorar los resultados para los pacientes y reducir los costos de atención médica.

A pesar de los avances en esta dirección, existe una laguna en la literatura científica en cuanto a la aplicación de técnicas de aprendizaje automático basadas en la computación cuántica para la clasificación de sonidos cardíacos. Esta falta de exploración en el ámbito de la computación cuántica plantea el interrogante fundamental de cuál sería la representación de señal óptima para lograr una clasificación precisa utilizando estos enfoques. Considerando que las representaciones de señal más comunes para sonidos cardíacos incluyen los MFCCs [8], la transformada de Fourier de tiempo corto (STFT) [9] y los cocleogramas, surge la necesidad de abordar una investigación profunda y rigurosa para determinar cuál de estas representaciones resultaría más adecuada en el contexto de las técnicas cuánticas de aprendizaje automático.

Este trabajo tiene como objetivo principal realizar un análisis exhaustivo y comparativo de las distintas representaciones de señal mencionadas, con el fin de determinar cuál de ellas ofrece los resultados más prometedores cuando se emplean en enfoques de aprendizaje automático basados en la computación cuántica. A través de esta investigación, aspiramos a arrojar luz sobre la idoneidad de las representaciones de señal en el contexto de la computación cuántica y contribuir así al avance de las técnicas de diagnóstico de enfermedades cardiovasculares.

## 2. APRENDIZAJE AUTOMÁTICO CUÁNTICO

El aprendizaje automático cuántico, conocido en inglés como quantum machine learning (QML), se presenta como un enfoque prometedor donde confluyen la computación cuántica y el aprendizaje automático, aprovechando los principios de la mecánica cuántica para desarrollar métodos más potentes y eficientes en el procesamiento y análisis de datos [3]. Mediante la explotación de los fenómenos cuánticos, el QML abre la posibilidad de enriquecer las capacidades de los algoritmos tradicionales de aprendizaje automático.

Uno de los modelos cuánticos destacados en este campo es la máquina de soporte vectorial cuántica (QSVM) [4]. La QSVM aprovecha la dimensionalidad exponencial del espacio de Hilbert para calcular núcleos cuánticos de manera eficiente, lo que potencia la separación de datos. Al hacer uso de algoritmos cuánticos, las QSVM tienen el potencial de alcanzar un rendimiento de clasificación superior en comparación con sus contrapartes clásicas. La elección de mapas de características desempeña un papel crucial en la determinación de la eficacia de las QSVM. A través de la selección cuidadosa de mapas de características y la optimización de hiperparámetros, los investigadores pueden aprovechar el potencial de las QSVM en el análisis de sonidos cardíacos.

En el marco de este estudio, hemos adoptado las QSVM para explorar su aplicabilidad en el campo del análisis de sonidos cardíacos. Mediante el empleo de las QSVM, buscamos proporcionar una vía para aprovechar las ventajas de los núcleos cuánticos en la precisa clasificación de sonidos cardíacos. Para la implementación y evaluación de estos modelos, hemos hecho uso de PennyLane, una versátil biblioteca de aprendizaje automático cuántico que nos ha permitido simular cálculos cuánticos en hardware clásico [5].

Con la incursión de modelos de QML en el análisis de sonidos cardíacos se persigue aprovechar las innatas fortalezas de la computación cuántica para mejorar la detección y el diagnóstico de enfermedades cardiovasculares. Al incorporar algoritmos cuánticos en el proceso de análisis de sonidos cardíacos, anticipamos un incremento en la precisión, un mejor rendimiento en la clasificación, y el potencial para descubrir nuevas perspectivas a partir de los datos. Nuestro estudio sienta las bases para futuras investigaciones en este campo emergente, allanando el camino hacia nuevos avances en la aplicación del QML para abordar retos complejos en la salud cardiovascular.

### 3. RESULTADOS EXPERIMENTALES

Los experimentos se llevaron a cabo utilizando una variante de la "Base de Datos de Sonidos Cardíacos Yaseen" (YHSD) [6], que contiene grabaciones de alta calidad de sonidos cardíacos adquiridos de pacientes con diversas afecciones cardíacas. Esta base de datos se divide en dos conjuntos distintos: uno normal y otro anormal. El conjunto anormal comprende cuatro categorías: estenosis aórtica, estenosis mitral, regurgitación mitral y prolapso de la válvula mitral. Cada categoría consta de 200 archivos de audio, lo que suma un total de 1.000 archivos de audio en la base de datos. Las grabaciones se llevaron a cabo meticulosamente y se capturaron utilizando estetoscopios electrónicos, garantizando así su precisión y fiabilidad. YHSD forma parte de un conjunto de bases de datos de acceso público en constante crecimiento, creadas con el propósito de facilitar la investigación y los avances en el diagnóstico de enfermedades cardiovasculares mediante el empleo de técnicas de procesamiento de señales y aprendizaje automático. Este conjunto de datos sirvió como fundamento para evaluar el rendimiento del modelo propuesto, permitiendo así medir su eficacia en la clasificación de sonidos cardíacos y su potencial impacto en la mejora de los resultados en el ámbito de la salud cardiovascular.

En el contexto de este estudio, abordaremos dos enfoques distintos de clasificación en el análisis de sonidos cardíacos. En primera instancia, nos enfocaremos en una clasificación binaria con el objetivo de detectar la presencia de anomalías cardíacas en los pacientes. Este enfoque implica la diferenciación entre sonidos cardíacos normales y anormales. En segunda instancia, emprenderemos una clasificación multiclase, donde se buscará categorizar los sonidos anormales clasificados en las cuatro categorías anteriormente descritas.

Para evaluar la eficacia de la propuesta en este estudio, se empleó la métrica de precisión, la cual se define como la proporción de resultados correctamente clasificados sobre el total de predicciones realizadas por el modelo. En otras palabras, la precisión mide la capacidad del modelo para clasificar de manera correcta y certera los sonidos cardíacos como normales o anormales, o en el caso de la clasificación multiclase, dentro de las categorías específicas de anomalías cardíacas. Esta métrica es fundamental en la evaluación de la exactitud de los modelos de aprendizaje automático, ya que proporciona una medida cuantitativa de su capacidad para realizar predicciones precisas.

Para lograr la selección óptima de los parámetros relacionados con las diferentes representaciones de señal, llevamos a cabo un exhaustivo estudio experimental. Inicialmente, variamos el número de puntos de la transformada y el grado de solapamiento de tramas de la

STFT. Como resultado de este análisis, identificamos que los mejores resultados se obtuvieron al utilizar 256 puntos en la transformada, junto con un solapamiento del 70% para la clasificación binaria y un solapamiento del 20% para la clasificación multiclase. Estos valores óptimos se aplicaron posteriormente en el cálculo de las demás representaciones de señal, asegurando así una comparación justa y equitativa. En el caso de MFCC, tras un detenido análisis de sus diversos parámetros, determinamos que el conjunto óptimo consiste en un banco de filtros compuesto por 100 filtros y la selección exclusiva de los primeros 10 coeficientes MFCC. De manera similar, en el caso de los cocleogramas, se optó por seleccionar 10 coeficientes para garantizar la coherencia de las representaciones de señal utilizadas en este estudio. Además, es importante destacar que se emplearon ventanas de longitud 30 ms y que la frecuencia de muestreo fue 8 kHz.

En lo que respecta al tamaño de los conjuntos de entrenamiento y prueba, destinamos el 20% del conjunto total de ejemplos para la fase de prueba. Sin embargo, debido a restricciones en la capacidad de cómputo cuántico que pudimos simular de manera clásica, nos vimos limitados a utilizar apenas 200 ejemplos para el proceso de entrenamiento. Para el entrenamiento del modelo basado QSVM, se implementó una sintonización de hiperparámetros mediante un enfoque de validación cruzada ( $k=5$ ). Esta sintonización de hiperparámetros se centró en la selección del núcleo cuántico óptimo a partir de una variedad de mapas de características, entre los cuales se incluyen el mapa de características ZZ, la incrustación de ángulos y la incrustación de amplitud (véase [7]).

**Tabla 1.** Resultados obtenidos por el modelo QSVM para el conjunto de datos YHSD, incluyendo diferentes representaciones de señal.

Representación	Precisión	
STFT	87,6	51,9
MFCC	95,5	60,7
Cocleograma	84,2	26,3
	<i>Binaria</i>	<i>Multiclase</i>

La Tabla 1 muestra los resultados obtenidos por el modelo basado en QSVM para el conjunto de datos descrito. Se puede observar una diferencia notable en términos de precisión entre la clasificación binaria y multiclase. Esto se debe en gran medida a la naturaleza del problema, donde la clasificación binaria, al distinguir entre sonidos cardíacos normales y anormales, tiende a ser más sencilla en comparación con la clasificación multiclase, que aborda la categorización específica de anomalías cardíacas. En ambos casos, se destacan los resultados obtenidos al utilizar los MFCC como representación de señal, alcanzando un nivel de precisión del 95% en la clasificación binaria y del 60% en la clasificación multiclase. Estos resultados sugieren que los

MFCC tienen la capacidad de sintetizar eficazmente la información espectral en sus primeros 10 coeficientes, lo que facilita una clasificación precisa. Por otro lado, se observa que los cocleogramas muestran un rendimiento inferior en comparación con los MFCC, lo que podría atribuirse a su capacidad limitada para capturar características relevantes de los sonidos cardíacos. En cuanto a la STFT, no logra superar a los MFCC, posiblemente debido a que los sonidos cardíacos se suelen encontrar en frecuencias bajas, y la inclusión de contenido espectral de alta frecuencia podría estar limitando la capacidad del modelo para la clasificación.

#### 4. CONCLUSIÓN

En este estudio, se abordó el desafío de la clasificación de sonidos cardíacos mediante el empleo de técnicas basadas en QML, explorando la idoneidad de distintas representaciones de señal en este contexto. Se evaluaron tres representaciones de señal ampliamente utilizadas: la STFT, los MFCC y los cocleogramas. Los resultados obtenidos arrojaron luz sobre la eficacia de estas representaciones en el marco de la QML y su capacidad para mejorar la detección y el diagnóstico de enfermedades cardiovasculares a través del análisis de sonidos cardíacos. Se observó que, en general, los MFCC destacaron como la representación de señal más efectiva. Este rendimiento sugiere que los MFCC tienen la capacidad de sintetizar de manera efectiva la información espectral relevante en los sonidos cardíacos, lo que facilita una clasificación precisa.

Este estudio allana el camino para futuras investigaciones en el campo emergente del aprendizaje automático cuántico aplicado al análisis de sonidos cardíacos. Los resultados prometedores obtenidos al emplear MFCC en modelos QSVM sugieren la posibilidad de mejorar significativamente la detección y el diagnóstico de enfermedades cardiovasculares mediante la integración de técnicas cuánticas. Además, se destaca la importancia de seleccionar cuidadosamente la representación de señal adecuada al utilizar métodos de QML, ya que esta elección puede tener un impacto sustancial en el rendimiento del modelo.

#### 5. AGRADECIMIENTOS

Este trabajo ha sido parcialmente respaldado por la subvención PID2020-119082RB financiada por el MCIN/AEI/10.13039/501100011033, la subvención AYUD/2021/50994 financiada por el Gobierno del Principado de Asturias (España) y el proyecto QUANTUM SPAIN financiado por el Ministerio de Asuntos Económicos y Transformación Digital del Gobierno de España y la Unión Europea a través del Plan de Recuperación, Transformación y Resiliencia - NextGenerationEU. También queremos expresar nuestro agradecimiento al CTIC de Asturias por

proporcionarnos la infraestructura necesaria para llevar a cabo este trabajo.

#### 6. REFERENCIAS

- [1] G. Y. Son and S. Kwon. "Classification of heart sound signal using multiple features", *Applied Sciences*, vol. 8, no 12, pp. 2344, 2018.
- [2] M. Nassralla, Z. El Zein, and H. Hajj, "Classification of normal and abnormal heart sounds," in Proc. of the Fourth International Conference on Advances in Biomedical Engineering (Beirut, Lebanon), pp. 1-4, 2017.
- [3] J. Biamonte, P. Wittek, N. Pancotti, P. Rebentrost, N. Wiebe, and S. Lloyd, "Quantum machine learning", *Nature*, vol. 549, no 7671, pp. 195-202, 2017.
- [4] V. Havlíček, A.D. Córcoles, K. Temme, A.W. Harrow, A. Kandala, J.M. Chow, and J.M. Gambetta, "Supervised learning with quantum-enhanced feature spaces", *Nature*, vol. 567, no 7747, pp. 209-212, 2019.
- [5] V. Bergholm, J. Izaac, M. Schuld, C. Gogolin, S. Ahmed, V. Ajith, and N. Killoran, "Pennylane: Automatic differentiation of hybrid quantum-classical computations", *arXiv preprint arXiv:1811.04968*, 2018.
- [6] Yaseen Heart Sound Database Portal, (<https://github.com/yaseen21khan/Classification-of-Heart-Sound-Signal-Using-Multiple-Features->).
- [7] E. F. Combarro and S. González-Castillo, "A Practical Guide to Quantum Machine Learning and Quantum Optimization", *Packt*, 2023.
- [8] D. M. Nogueira, C. A. Ferreira, and A. M. Jorge, "Classifying Heart Sounds Using Images of MFCC and Temporal Features", in Proc. 18th EPIA Conference on Artificial Intelligence, (Porto, Portugal), pp. 186-203, 2017.
- [9] S. M. Debbal y F. Bereksi-Reguig, "Time-Frequency Analysis of the First and the Second Heartbeat Sounds", *Applied Mathematics and Computation*, vol. 184, no. 2, pp. 1041-1052, 2007.