

Resumen

Los sensores hiperespectrales capturan cientos de longitudes de onda que van desde el infrarrojo al ultravioleta pasando por el visible. El análisis de la información espectral proporciona datos detallados acerca de la composición y estructura de los tejidos permitiendo mejorar la precisión de procedimientos médicos como cirugías guiadas por imágenes para la extirpación de tumores, ayudando al equipo de cirujanos en la disección de los márgenes de tejidos dañados y sanos mediante mapas de diagnóstico extraídos a través de técnicas de clasificación.

Llevar a cabo dicha clasificación requiere una gran potencia de cálculo debido a la alta dimensionalidad de los datos hiperespectrales junto con la complejidad de los algoritmos de clasificación. Además, en el caso de una cirugía guiada hay que proporcionar una respuesta inmediata o en tiempo real. El hardware reconfigurable ofrece un gran rendimiento junto con un bajo consumo, tamaño reducido y bajo coste, lo que lo convierte en la tecnología más adecuada.

Para poder realizar análisis sobre estos datos es obligatorio aplicar previamente alguna técnica de reducción dimensional. Estas técnicas extraen la información más relevante, suprimiendo información de bandas que no aporten valor al análisis del diagnóstico, información duplicada o ruido. En este trabajo, se presentan los resultados de la reducción dimensional de imágenes hiperespectrales de cáncer cerebral capturadas durante operaciones quirúrgicas mediante una implementación propia de la técnica de análisis de componentes principales en hardware reconfigurable.

Imágenes hiperespectrales

Los datos espectrales se organizan en cubos de datos como los de la Figura 1.

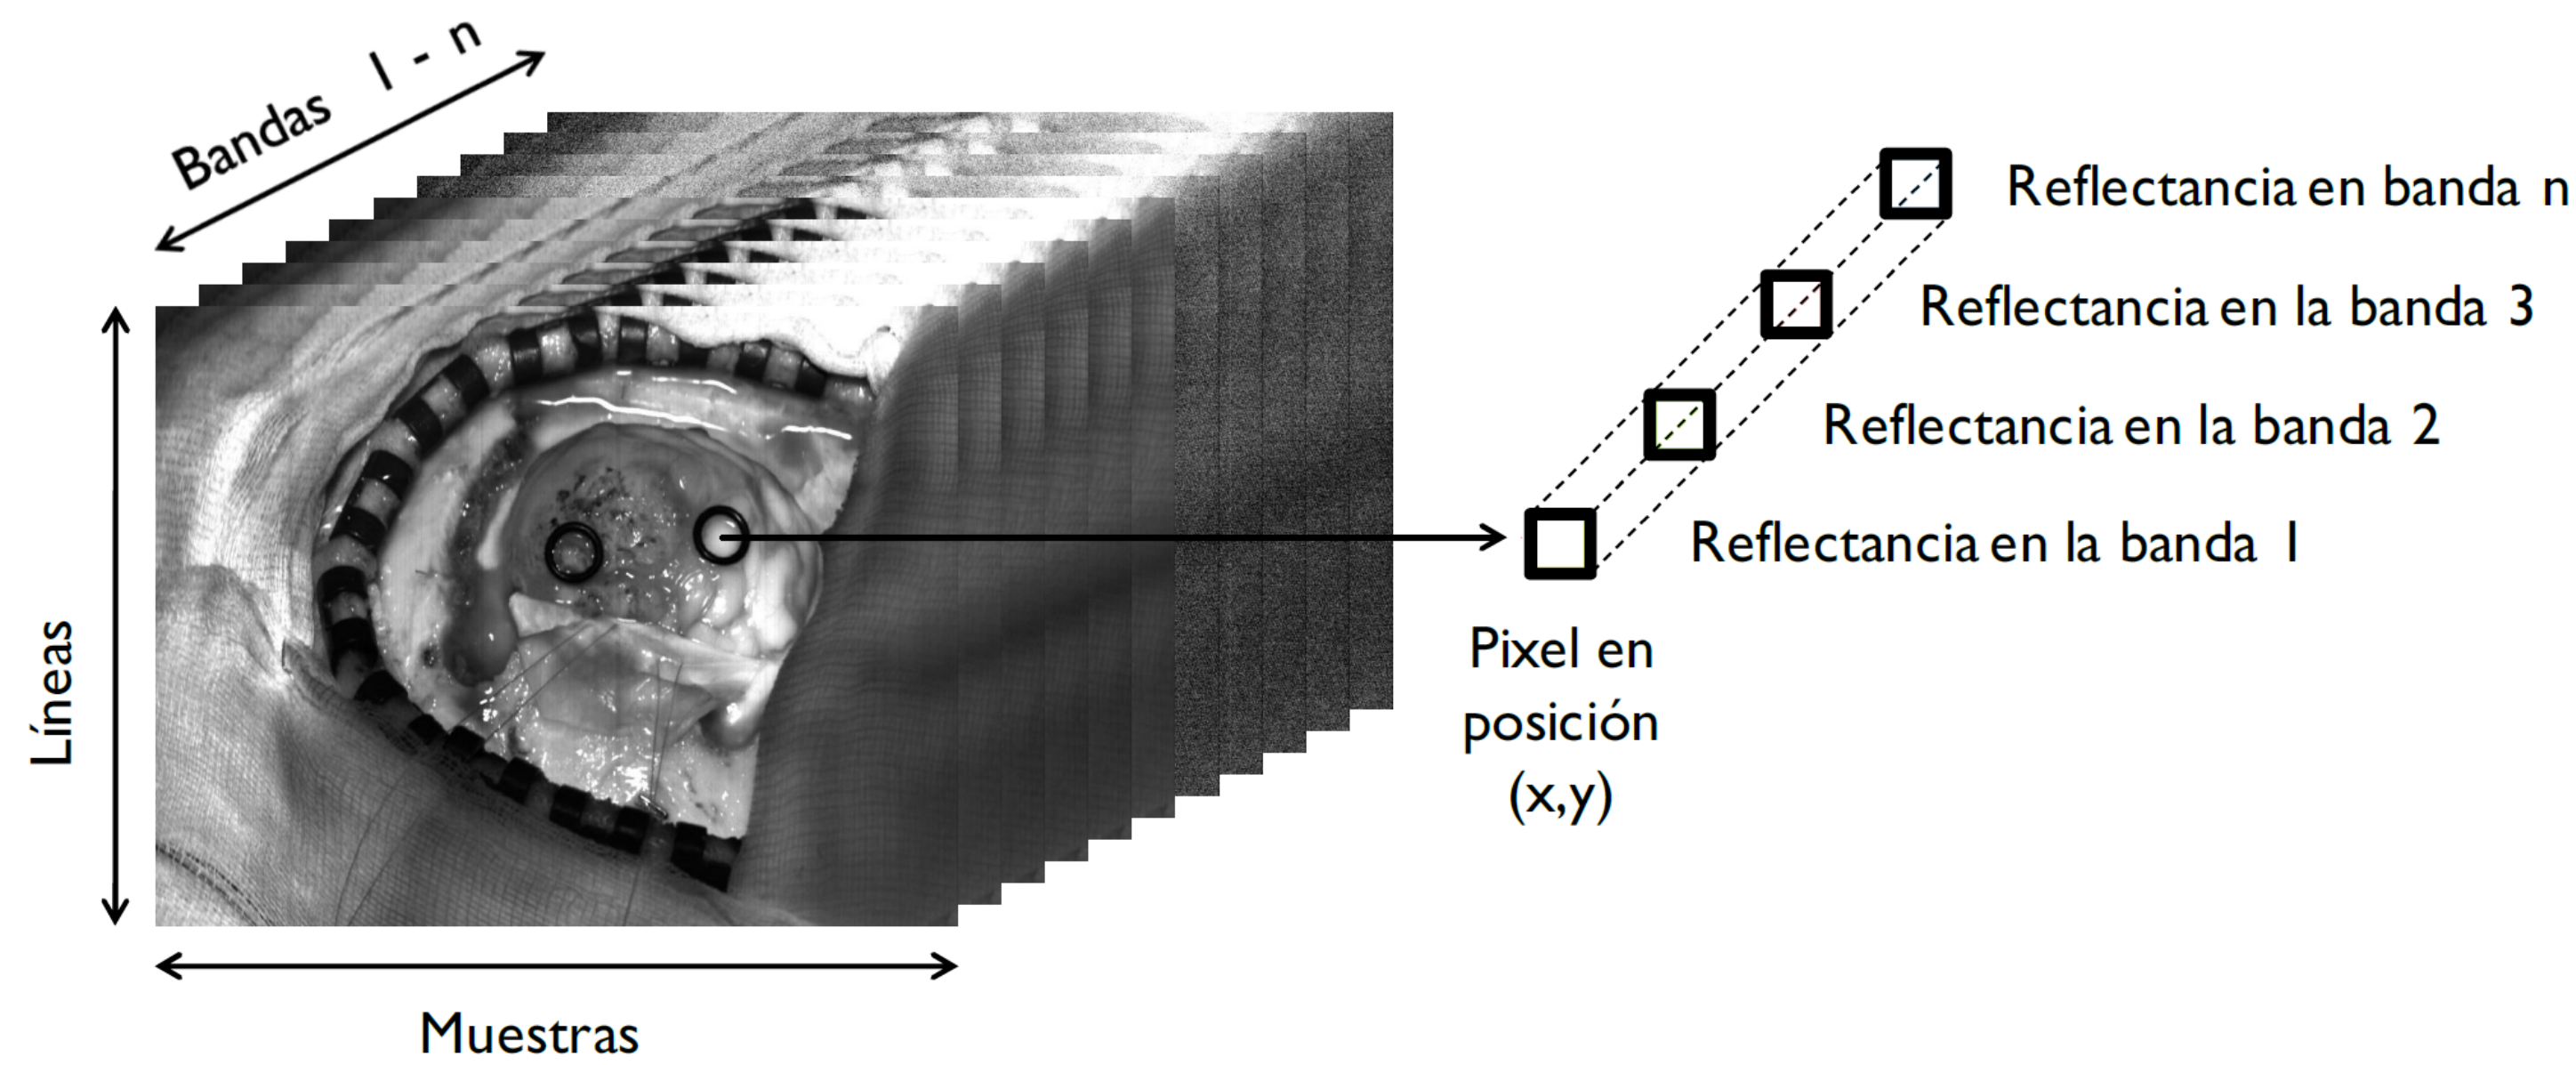


Figura 1. Representación de una imagen hiperespectral como cubo de datos.

El número de píxeles y bandas viene determinado por el rango de captura del espectro electromagnético y la precisión del sensor espectral.

Hardware reconfigurable

Una FPGA es un dispositivo programable que contiene bloques de lógica cuya interconexión y funcionalidad puede ser configurada en el momento, mediante un lenguaje de descripción especializado. Ofrecen flexibilidad y un alto rendimiento junto con un bajo consumo y un coste reducido. La Figura 2 muestra la arquitectura interna simplificada de una FPGA.

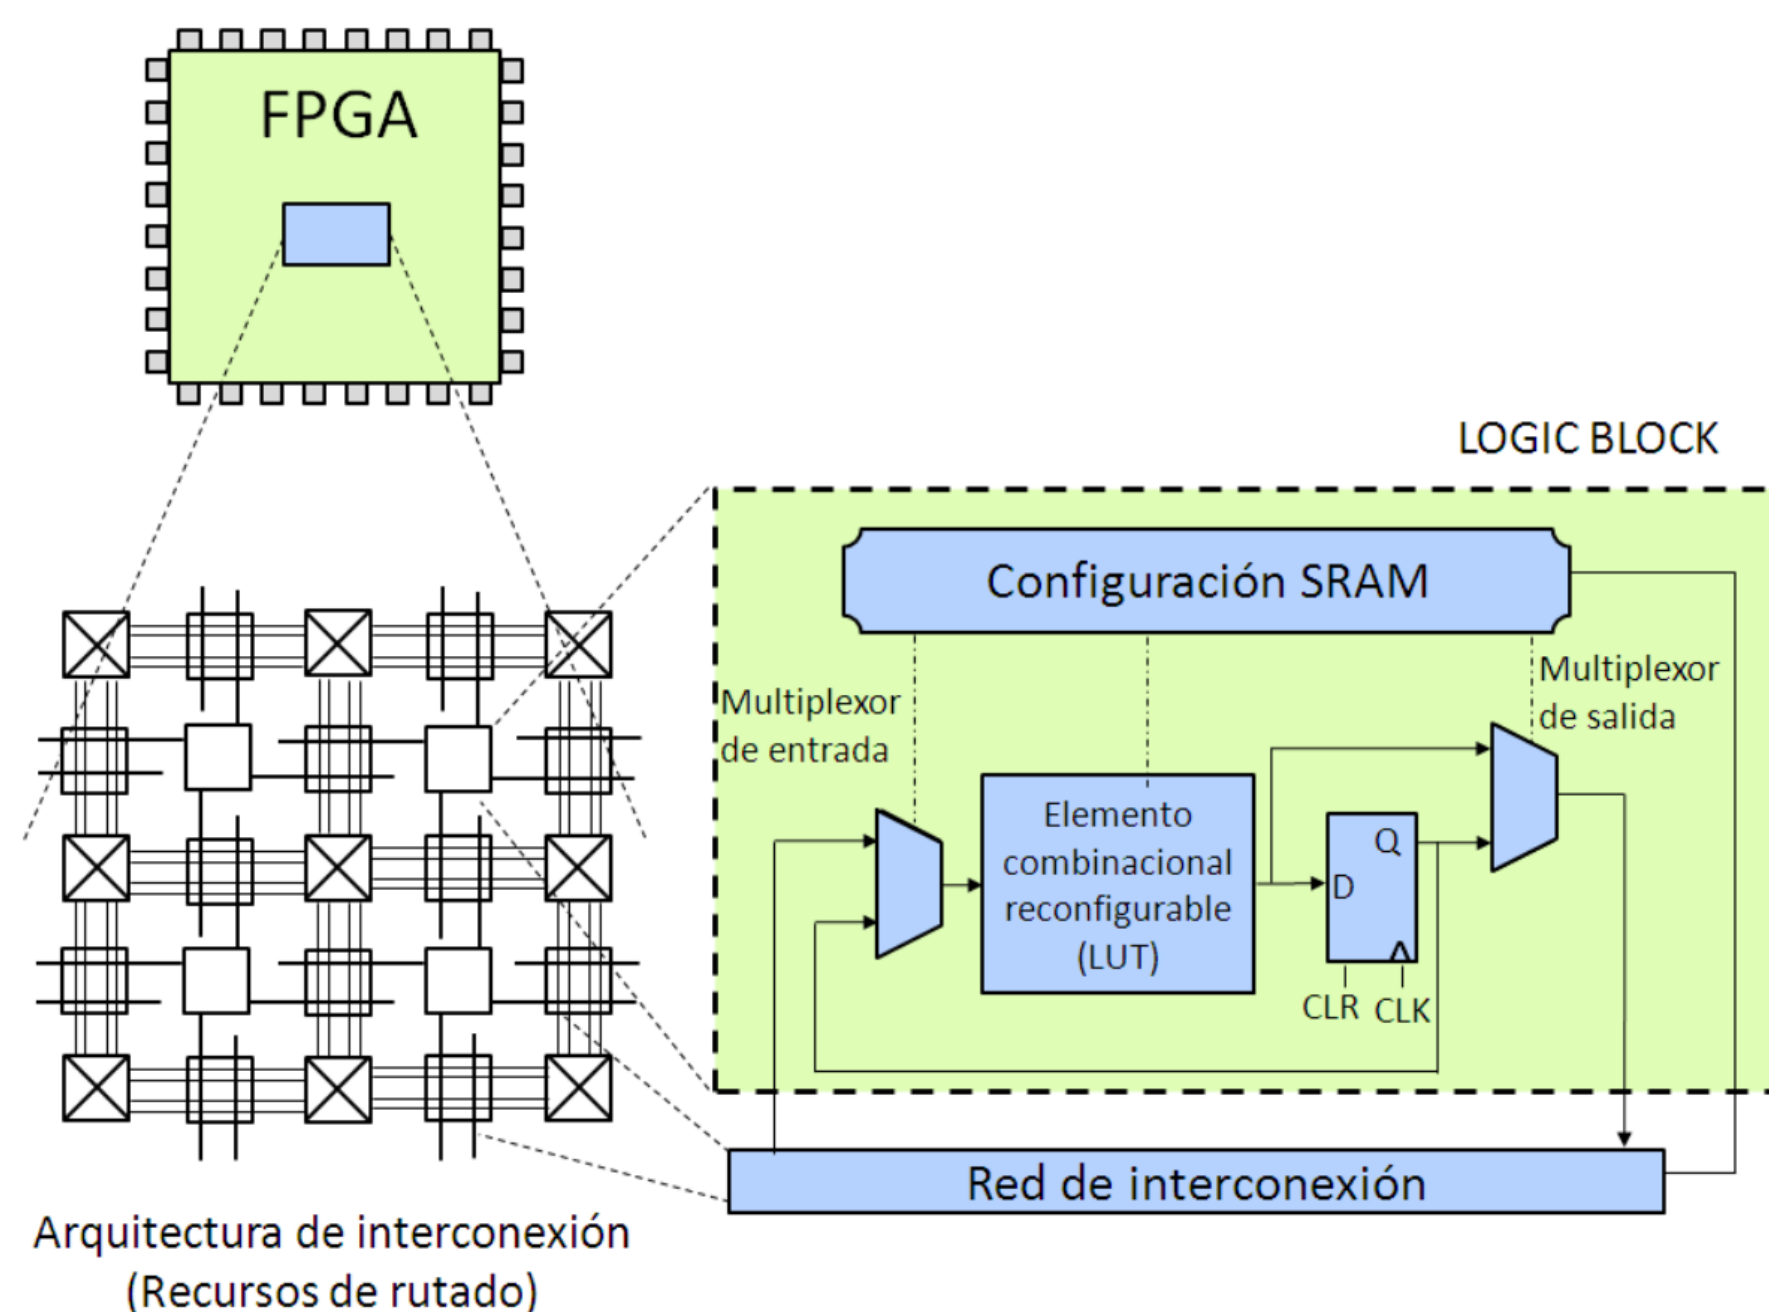


Figura 2. Modelo genérico de la arquitectura interna de una FPGA.

Análisis de componentes principales (PCA)

PCA es un algoritmo que ordena los datos en función de varianza decreciente mediante la descomposición en autovectores y autovalores de la matriz de covarianza [2, 3]. Permite seleccionar los conjuntos de datos más representativos en términos de varianza y eliminar información no relevante.

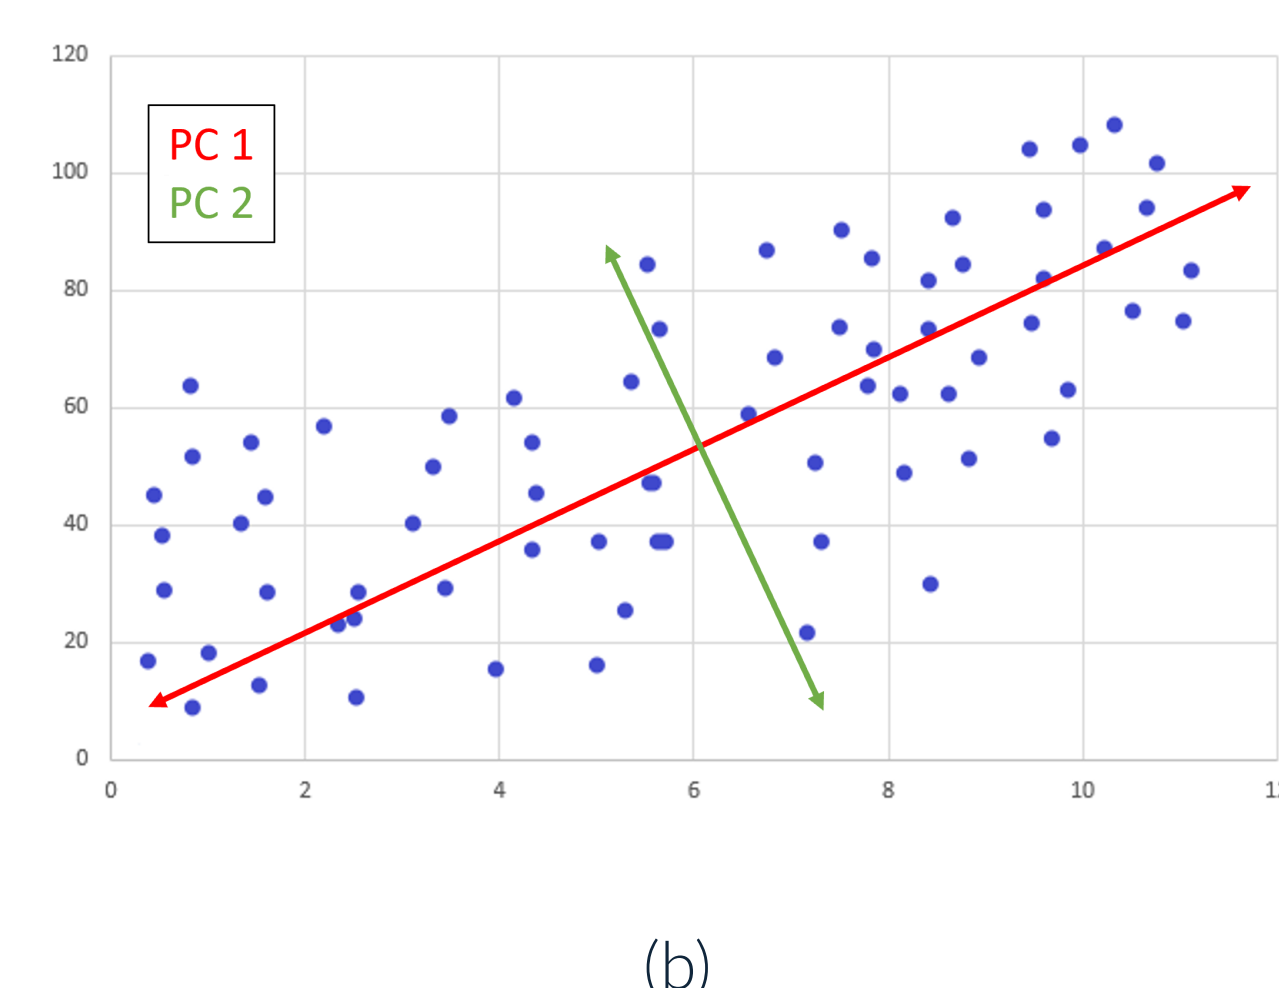
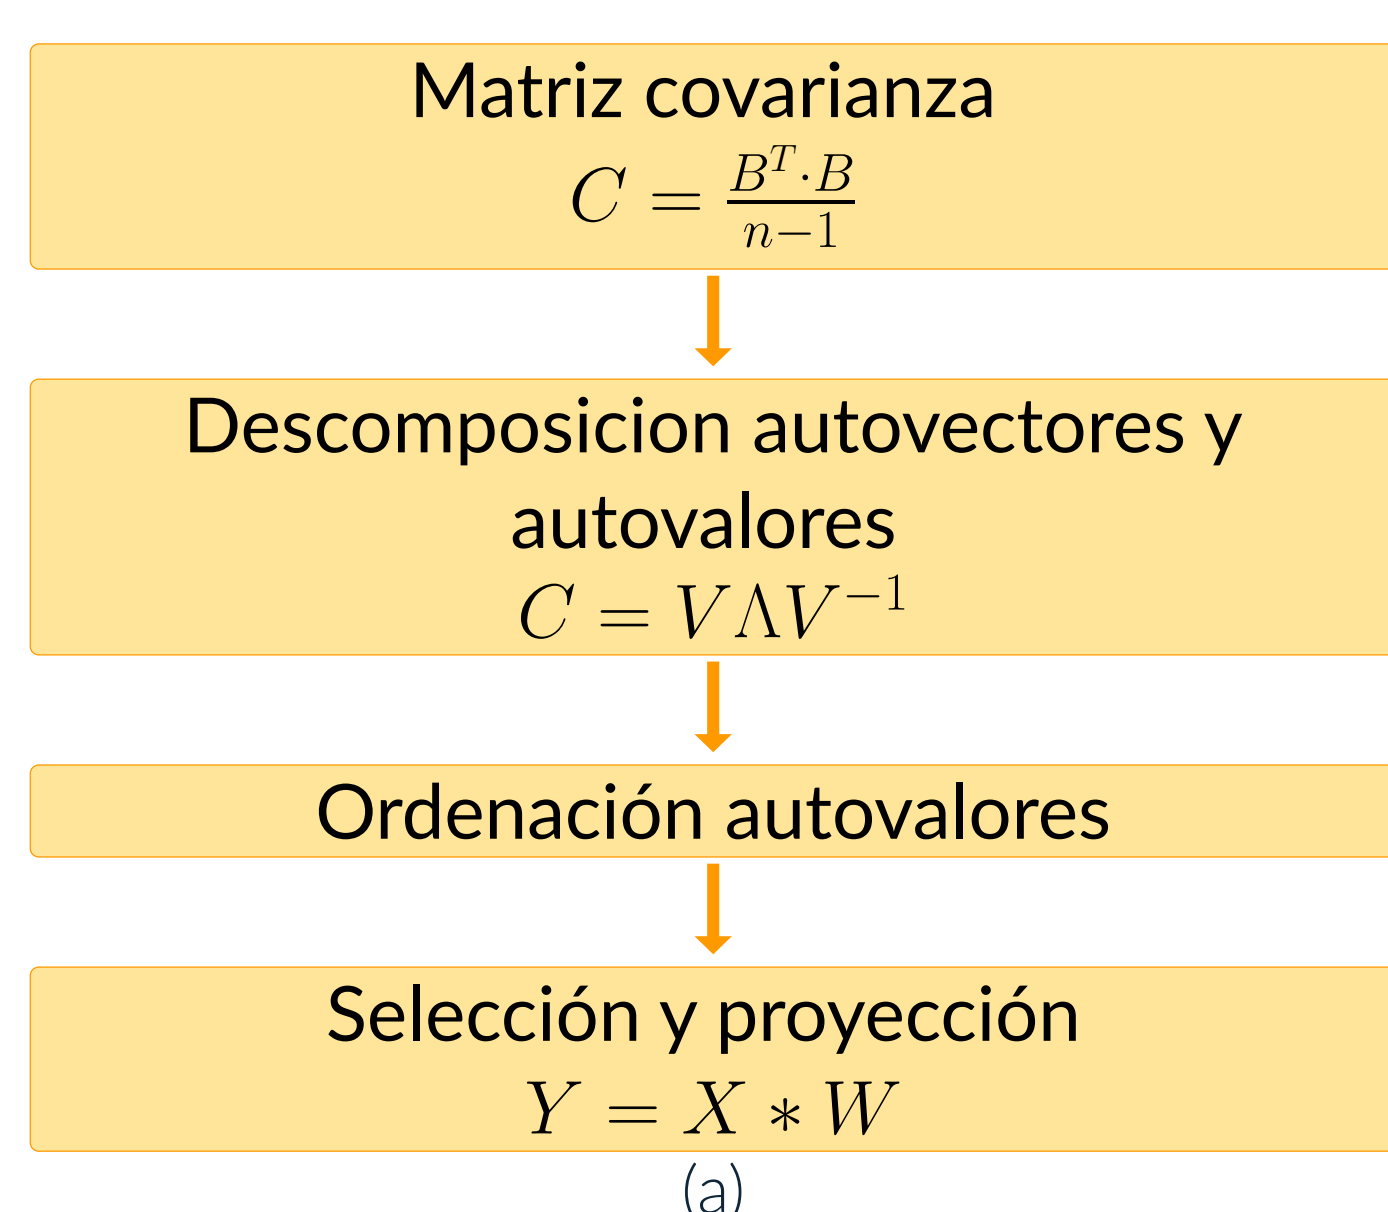


Figura 3. (a) Diagrama por fases del algoritmo (b) Interpretación geométrica de dos componentes principales para un conjunto de puntos.

Resultados experimentales

La imagen hiperespectral médica tomada como referencia consta de un total de 826 bandas en un rango espectral entre 400 μm a 1000 μm y un tamaño de 1004 columnas y 777 filas.

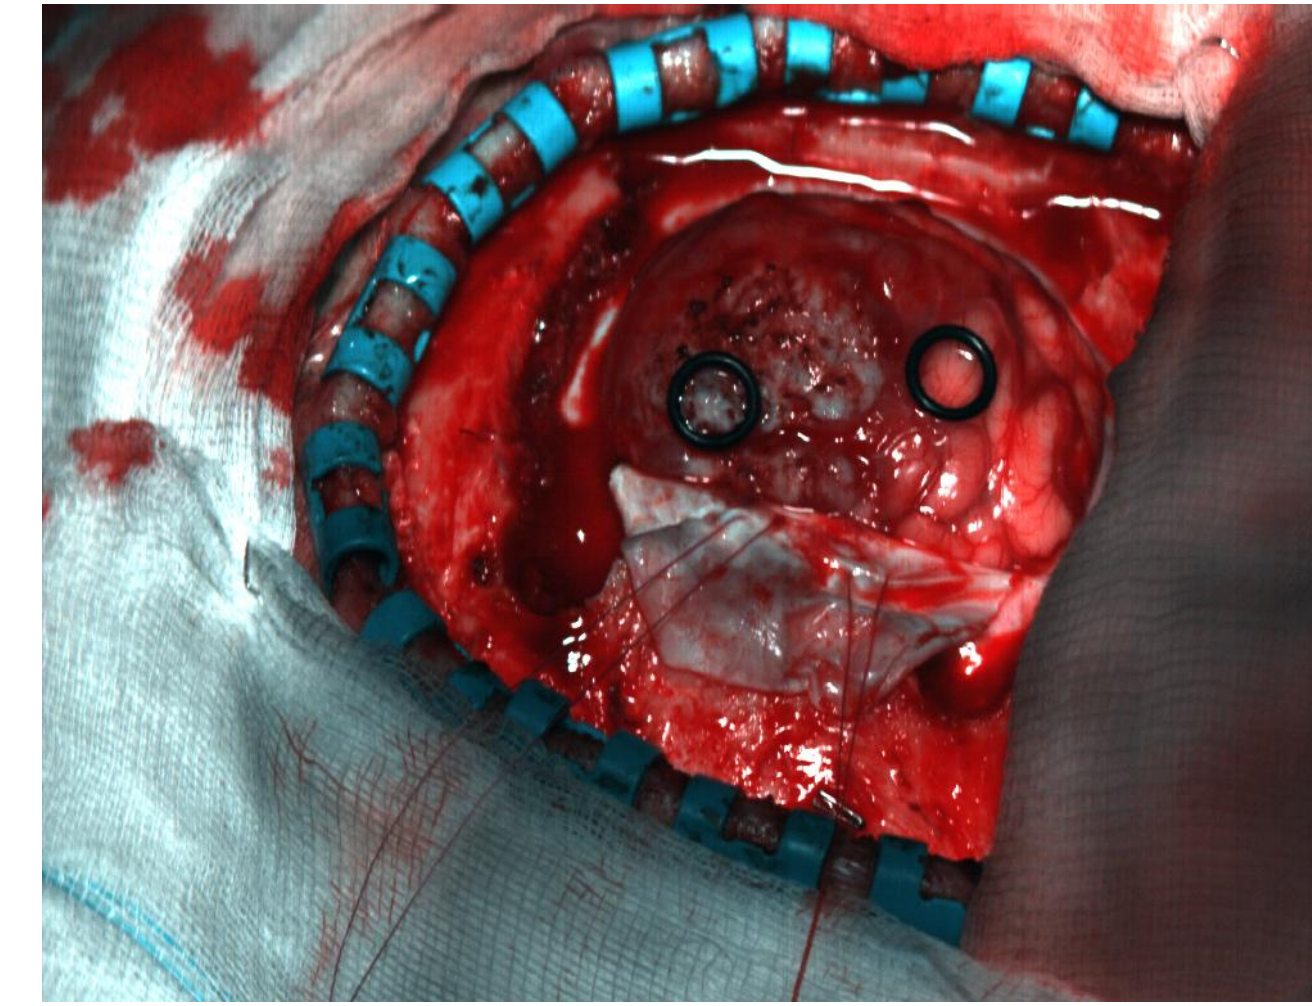


Figura 4. Composición en falso color de una imagen hiperespectral de la superficie cerebral afectada por un tumor [1].

A partir de la implementación hardware para el algoritmo PCA es posible obtener una reducción en torno al 80%, donde con tan solo las 164 primeras componentes principales se conserva un 99.9% de la información original.




Figura 5. Primeras 20 componentes principales después de la reducción dimensional mediante PCA.

Para comprobar la precisión y validez de la reducción dimensional, realizamos tareas de clasificación sobre la imagen original y la reducida donde podemos observar que el resultado es muy similar.





Figura 6. Clasificación no supervisada Isodata de la escena hiperespectral (a) Clasificación a partir de la imagen original (b) Clasificación a partir de la imagen reducida con PCA (c) Porcentajes de clasificación por clases para ambas imágenes.

Conclusiones

En este trabajo se muestra cómo es posible reducir considerablemente la alta dimensionalidad de los datos hiperespectrales (suprimiendo información irrelevante o ruido de la imagen) sin pérdida significativa de precisión, mejorando así la complejidad computacional de los algoritmos de análisis posteriores (como la clasificación) y los requisitos de almacenamiento. Mediante la implementación sobre FPGA se demuestra, que utilizando esta tecnología, es posible extraer las componentes principales de una imagen hiperespectral con un tiempo de respuesta suficientemente bajo para poder analizarlas en tiempo real.

Referencias

- [1] H. Fabelo et al. In-Vivo Hyperspectral Human Brain Image Database for Brain Cancer Detection. IEEE Access vol. 7 pp. 39098-39116 2019.
- [2] Bishop Christopher M, Nasrabadi Nasser M. Pattern recognition, and machine learning. Springer 2006.
- [3] Fodor I K. A Survey of Dimension Reduction Techniques. 2002.