

David G. Shatwell<sup>1</sup>, Victor Murray<sup>2,3</sup>, Augusto Barton<sup>4</sup>

<sup>1</sup> Hochschild Mining PLC, Calle La Colonia 180, Santiago de Surco, Lima, Perú (david.shatwell@hocplc.com)

<sup>2</sup>John A. Paulson School of Engineering and Applied Sciences, Harvard University, Cambridge, 02134, Massachusetts, USA (victormurray@seas.harvard.edu)

<sup>3</sup> Department of Electrical and Computer Engineering, University of New Mexico, Albuquerque, 87131, New Mexico, USA (vmurray@unm.edu)

<sup>4</sup> Hochschild Mining PLC, Calle La Colonia 180, Santiago de Surco, Lima, Perú (augusto.barton@hocplc.com)

## RESUMEN

La clasificación de minerales basada en sensores es una tecnología usada para clasificar rocas mineralizadas de rocas estériles con el objetivo de reducir los costos de operación. En el pasado, se han propuesto muchos algoritmos de clasificación de minerales usando imágenes a color o imágenes hiperespectrales, pero pocos de ellos aprovechan ambos tipos de imágenes para crear algoritmos más precisos. En este trabajo, se presenta un algoritmo novedoso que combina las mejores características de color, textura y de curvas espectrales de manera completamente automática usando inteligencia artificial. El algoritmo propuesto fue probado con imágenes de rocas extraídas de una mina subterránea ubicada en los andes peruanos. Todas las imágenes fueron clasificadas por un geólogo de la mina y luego fueron analizadas para estimar su contenido de oro y plata. Los resultados del algoritmo propuesto fueron sobresalientes, con un coeficiente de correlación de Matthews de 0.9787 y un potencial aumento en la recuperación de 1.3% con respecto a otras máquinas de clasificación de minerales comerciales.

## 1. Introducción

La ley de oro en distintas regiones del mundo ha ido disminuyendo con el paso de los años, debido a que muchos de los depósitos de alta ley están por agotarse o ya han sido agotados (Priester et al, 2019; Cho et al, 2020; Calvo et al, 2022). Esta tendencia también ha sido observada en depósitos de otros metales, como cobre (Cho et al, 2020) y manganeso (Eliott et al, 2020). El minado de depósitos de baja ley requiere una mayor cantidad de recursos para producir la misma cantidad de concentrado de mineral que un depósito de alta ley, lo cual resulta en un aumento de costos de procesamiento y, por lo tanto, una reducción en la rentabilidad de la operación (Ulrich et al, 2019). A lo

largo de los años, nuevas tecnologías han sido desarrolladas para afrontar este problema, haciendo que el minado de depósitos de baja ley sea más rentable económicamente y permitiendo cumplir con el aumento en la demanda.

Típicamente, el proceso de extracción de oro está compuesto por varias etapas que forman una cadena de valor de operaciones, las cuales son el minado, chancado, molienda, concentración y recuperación del oro (La Brooy et al, 1994; Lee et al, 2021). La clasificación de minerales basada en sensores, mejor conocida en inglés como *ore sorting*, es una tecnología de preconcentración normalmente usada entre los procesos de chancado y molienda para separar las rocas mineralizadas de las rocas estériles. El objetivo de esta tecnología es reducir la cantidad de material que ingresa a la planta de procesamiento sin impactar significativamente la recuperación del mineral (Lessard et al, 2014).

En las máquinas de *ore sorting*, el proceso de clasificación de minerales está compuesto por tres etapas principales. En la primera, se usa un conjunto de sensores para medir las propiedades físicas de la roca. Por ejemplo, se pueden usar cámaras a color para producir imágenes a color, sensores de transmisión de rayos X para medir la densidad atómica, láser y cámaras de triangulación para estimar la geometría de la roca o hasta cámaras hiperespectrales para producir curvas espectrales del mineral (Lessard et al, 2016; Robben et al, 2019). En la segunda etapa, la información de los sensores es enviada a un procesador, el cual estima si la roca se encuentra mineralizada y decide si esta debe ser enviada a la planta de procesamiento o al desmonte. Finalmente, luego de analizar las rocas, se utiliza un sistema de aire comprimido para eyectarlas a distintos compartimientos de acuerdo con la decisión del procesador en la etapa anterior.

El oro y la plata normalmente se encuentran dispersos en concentraciones mínimas dentro de una matriz de otros minerales, haciendo que sea difícil detectarlos de manera directa. Sin embargo, en muchos depósitos, la ley de oro y plata se encuentra fuertemente asociada a otros minerales más abundantes que sí pueden ser detectados directamente con el conjunto de sensores adecuados (Simmons, 2005; Ghasemi et al, 2022). El problema con este enfoque es que cada mina posee una mineralogía distinta, que incluso puede variar en distintas zonas de esta. Debido a que las máquinas de *ore sorting* comerciales utilizan algoritmos estándares, existen casos en los que no se logra detectar los distintos tipos de minerales asociados al oro con una alta precisión, lo cual ocasiona que parte de la roca mineralizada sea enviada al desmonte y parte de la roca estéril sea enviada a la planta de procesamiento. En estos casos, el porcentaje de rechazo podría no justificar el aumento en la recuperación de oro y, por lo tanto, el uso de máquinas de *ore sorting* tradicionales no resulta viable económicamente.

Varios artículos científicos publicados en el pasado han demostrado que es posible clasificar minerales con una alta precisión usando solamente cámaras a color o cámaras hiperespectrales. Sin embargo, no existe un solo método que funcione para todas las minas o para todos los tipos de minerales, ya que la diversidad y complejidad de los métodos depende fuertemente del sistema de minerales (Tessier et al, 2007; Zhang et al, 2021). Estos métodos pueden ser agrupados en dos categorías principales: los métodos basados en ingeniería de características y los métodos basados en aprendizaje de características.

Los métodos basados en ingeniería de características usualmente consisten en extraer vectores de características de color, textura y de las curvas hiperespectrales de las imágenes usando diversos algoritmos. Para las características de color y textura, Singh et al (2005) y McCoy et al (2019) propusieron algoritmos de *ore sorting* para clasificar rocas de una planta metalúrgica de manganeso usando parámetros estadísticos de los espacios de color, texturas de Haralick y redes neuronales. De manera similar, Tessier et al (2007) propusieron un nuevo algoritmo de *ore sorting* usando los vectores de carga obtenidos mediante el análisis de componentes principales como características de color, wavelets como características de textura y máquinas de vectores soporte como algoritmo de clasificación. Perez et al (2011) propusieron dos mejoras al algoritmo propuesto por Tessier et al (2007). La primera consiste en el uso del

algoritmo de máxima relevancia, mínima redundancia (MRMR) para reducir el espacio de características de color y textura, mientras que la segunda consiste en usar segmentación de cuencas (*watershed segmentation*, en inglés) y un sistema de votación para decidir la clasificación final de la roca. Luego, Perez et al (2015) propusieron otra mejora del método que consiste en extraer características de textura de los espacios rojo-verde-azul (RGB, por sus siglas en inglés) y tono-saturación-valor (HSV, por sus siglas en inglés) usando filtros de Gabor.

La ingeniería de características también ha sido aplicada a las imágenes hiperespectrales en trabajos previos. Robben et al (2012) evaluaron la efectividad de usar imágenes hiperespectrales con una longitud de onda máxima de 2400 nm para la clasificación de borato y talco. Dalm et al (2015) presentaron un método de clasificación de minerales para una mina epitelmal de oro y plata usando coeficientes de correlación entre los píxeles de la imagen y un grupo de curvas espectrales de referencia. Luego, Dalm et al (2017) estudiaron la aplicabilidad de usar imágenes hiperespectrales de infrarrojo de onda corta (SWIR, por sus siglas en inglés) junto con el algoritmo de análisis de componentes principales para la caracterización de leyes de cobre. Gülcan et al (2018) estudiaron el efecto de usar filtros ópticos para crear imágenes de banda corta en el espectro infrarrojo cercano (NIR, por sus siglas en inglés) para la clasificación de minerales de cobre. Finalmente, Tuşa et al (2020) desarrollaron un método de clasificación para minerales de casiterita y pórfido de cobre y oro usando máquinas de vectores soporte y bosques aleatorios (*random forest*, en inglés), obteniendo buenos resultados de recuperación y reducción de masa.

Recientemente, varios métodos de aprendizaje de características basados en redes neuronales convolucionales (CNN, por sus siglas en inglés) han sido propuestos para aplicaciones de minería. Okada et al (2020) propusieron un sistema de clasificación de minerales usando imágenes hiperespectrales y redes neuronales convolucionales, obteniendo mejores resultados que el uso de imágenes a color. Liu et al (2021a, 2021b y 2021c) exploraron el uso de modelos CNN con diferentes profundidades, estructuras y tamaños de base de datos para la clasificación de imágenes a color de mineral de carbón. Asimismo, Wang et al (2022) propusieron un método de aprendizaje no supervisado para extraer características semánticas de imágenes de espuma de flotación usando autocodificadores (*autoencoders*, en inglés) y

redes generativas adversarias (GAN, por sus siglas en inglés).

Todos los métodos presentados anteriormente lograron obtener buenos resultados para cumplir con el propósito por el que fueron creados. Sin embargo, cuando el algoritmo de clasificación de minerales tiene que aplicarse a una nueva mina, con mineralogía y materiales diferentes, no basta con simplemente replicar los métodos encontrados en el estado del arte. De hecho, en muchas ocasiones se necesitan usar datos propios de la mina y nuevos modelos de clasificación. Al utilizar datos específicos de la mina, se puede obtener una mayor cantidad de patrones para analizarlos con más detalle. Además, no todos los métodos de clasificación requieren utilizar todos los patrones encontrados; algunos de ellos trabajan sólo con algunos de ellos con diferentes pesos.

En el presente trabajo se describe un proceso novedoso usado para clasificar rocas de una mina peruana, la cual es operada por la empresa Hochschild Mining PLC. A diferencia de los algoritmos de *ore sorting* encontrados en el estado del arte, el método propuesto combina la mejor información del espectro visual, el espectro infrarrojo cercano y la textura usando algoritmos de inteligencia artificial. Asimismo, el método propuesto permite encontrar de manera automática un conjunto reducido de bandas espectrales que maximicen la precisión del algoritmo y a la vez reduzcan la cantidad de información que deba ser procesada.

La organización de este trabajo es la siguiente. La sección 2 describe los minerales de la mina seleccionada y el sistema de visión computacional que se necesita para implementar el método. La sección 3 presenta los algoritmos de procesamiento de imágenes y aprendizaje automático que componen el método. Finalmente, la sección 4 presenta los resultados de desempeño para varios modelos de clasificación y se selecciona el más adecuado para el problema específico de clasificación de minerales en la mina seleccionada.

## 2. Minerales y sistema de visión computacional

En esta sección se presentan las características del mineral encontrado en una de las vetas de la mina seleccionada, así como el sistema de visión computacional usado para implementar el algoritmo de *ore sorting*.

### 2.1. Características del mineral

La mina seleccionada para este trabajo es una mina de oro y plata ubicada en la región sur de los andes peruanos. Esta mina consta de cuarenta concesiones mineras y se caracteriza por ser sistemas mineralizados de baja y alta sulfuración, organizados por vetas, brechas y diseminaciones en rocas volcánicas terciarias. Todos los fragmentos de roca usados en este trabajo fueron extraídos de una veta compuesta mayormente por cuarzo rodeado por roca caja volcánica. La veta tiene un ancho de aproximadamente 2 m y una inclinación de 45° con respecto al suelo. La transición entre la veta principal y la roca caja no es abrupta, ya que hay una zona intermedia donde la roca caja contiene fragmentos y vetas pequeñas de cuarzo y sulfuros. Las rocas encontradas en esta zona intermedia son llamadas brechas. La Figura 1 muestra una imagen de la veta seleccionada, donde la brecha, el cuarzo y la roca caja pueden ser observadas de manera clara.



Figura 1. Sección de una de las vetas principales de la mina seleccionada. En esta figura se muestran los siguientes tipos de roca: (1) brecha, (2) veta de cuarzo y (3) roca caja.

Las rocas extraídas de la veta seleccionada, referidas en este trabajo como mineral blanco (MB), están compuestas mayormente por cuarzo ( $\text{SiO}_2$ ) y calcita ( $\text{CaCO}_3$ ). A pesar de que el cuarzo no es un mineral económico, su presencia está correlacionada con leyes altas de oro y plata (Corbett, 2002). Esto se debe principalmente a la diseminación de sulfuros (Sillitoe, 2000) como la acantita y la argentita ( $\text{Ag}_2$ ), el electrum (aleación de oro y plata) y el oro libre, los cuales son depositados en la veta por fluidos hidrotermales.

Las rocas extraídas de la brecha, referidas en este trabajo como mineral gris (MG) están compuestas mayormente por cuarzo y calcita encapsulada en una matriz de andesita. Este tipo de roca también tiene en promedio una ley alta debido a las partículas de oro y plata que son depositadas en el mineral por fluidos hidrotermales. Algunos sulfuros como acantita, galena,

esfalerita, pirrotina y pirita también pueden ser encontrados en el MG.

La roca caja está compuesta mayormente por andesita, la cual es un tipo de roca volcánica terciaria (Gibson et al, 1983). En la mina seleccionada, existen dos tipos de roca que tienen bajo valor económico: la andesita pura y la andesita alterada, las cual son referidas en este trabajo como desecho verde (DV) y desecho morado (DM). La principal diferencia entre estos dos tipos de roca son el color y la alteración. El desecho verde es una roca con tonos verdes oscuros y poca alteración, mientras que el desecho morado tiene matices morados y rojos por la presencia de óxido y arcillas. Otros minerales que pueden ser encontrados en la roca caja son la pirita y algunas vetas angostas de cuarzo y calcita, las cuales en ocasiones contienen partículas de oro y plata en menor concentración. La Figura 2 muestra imágenes de los cuatro tipos de roca descritos en esta sección.




Figura 2. Tipos de roca encontrados en la veta seleccionada. (a) Mineral blanco (MB), compuesto de cuarzo, calcita y sulfuros diseminados. (b) Mineral gris (MG) compuesto por brechas. (c) Desecho verde (DV) compuesto por andesita. (d) Desecho morado (DM), compuesto de andesita alterada.

Debido a que el oro y la plata no pueden ser detectados directamente de manera visual, los algoritmos de *ore sorting* necesitan usar correlaciones entre las diferentes clases de mineral y su ley de plata equivalente para poder clasificar las rocas como mineral o desecho. La Tabla 1 muestra que el MG tiene la ley promedio más alta (296 g/t), seguido de cerca por el MB (215 g/t). Tanto el DV como el DM tienen una ley inferior a la de la MB y MG, con 20 g/t y 30 g/t respectivamente.

Tabla 1. Ley de plata equivalente (AgEq) promedio de los cuatro tipos principales de roca encontrados en la veta seleccionada.

Clase	Acrónimo	AgEq (g/t)	Número de imágenes
Mineral blanco	MB	215	21
Mineral gris	MG	296	4
Desecho verde	DV	20	58
Desecho morado	DM	30	7
<b>Total</b>			<b>90</b>

## 2.2. Sistema de visión computacional

Un sistema de visión computacional típicamente está compuesto por dos partes: el hardware usado para capturar y procesar las imágenes y el software que está compuesto de los algoritmos y las imágenes. En esta sección se describen las propiedades del hardware y las imágenes, mientras que en la siguiente se describirán los algoritmos.

### 2.2.1. Hardware

El hardware usado para probar los algoritmos de *ore sorting* desarrollados está compuesto por 5 partes principales: una cámara a color, una cámara hiperespectral, una estructura para sujetar las cámaras, una caja de luz y una unidad de procesamiento que contiene los algoritmos. Este sistema de visión computacional no incluye un mecanismo de separación de rocas ni una faja transportadora, aunque esta última está siendo desarrollada para validar el algoritmo de forma más robusta en el futuro con velocidades de hasta 3 m/s.

La cámara a color del sistema de visión computacional es una Sony DSC-HX90V, la cual es una cámara de consumo masivo que puede capturar imágenes de alta resolución usando un sensor CMOS Exmor RTM de tipo 1/2.3" (7.82 mm). Las opciones de configuración usadas para capturar las imágenes a color con esta cámara son las siguientes: distancia focal de 50 mm, tiempo de exposición de 1/40 s y velocidad ISO de 200. Asimismo, la cámara hiperespectral usada es una Specim IQ, la cual captura imágenes en el espectro visual e infrarrojo cercano entre 400 y 1000 nm con una alta resolución espacial y espectral. Las opciones de configuración usadas para esta cámara son las siguientes: distancia focal de 21 mm y tiempo de integración de 200 ms por línea.

La estructura usada para sujetar las cámaras fue fabricada usando planchas de MDF (*medium density fiberboard*, en inglés) cortadas por medio de una fresadora CNC (*computer numerical control*, en inglés), tubos de aluminio y un cabezal de trípode. Esta estructura fue usada para ajustar de manera manual la distancia y el ángulo entre las cámaras y la muestra. Para este trabajo, se usó una distancia de 250 mm y un ángulo de aproximadamente  $70^\circ$  con respecto al suelo. Asimismo, se usó un cobertor negro de tela para cubrir la estructura y prevenir que la luz externa altere la medición de las cámaras. La caja de luz usada para iluminar las rocas de manera uniforme fue una gti PDV-2e/M3, la cual incluye cuatro focos incandescentes y tres focos fluorescentes de tipo D65, con una temperatura de color de 5000K. Para la toma de fotos a color se usaron los focos fluorescentes y para la toma de imágenes hiperespectrales se usaron los focos incandescentes, ya que estos iluminan de manera más uniforme el espectro visible e infrarrojo cercano. Finalmente, para poder implementar el algoritmo de clasificación se usó una computadora MacBook Pro con un procesador Intel Core i7 de cuatro núcleos y el sistema operativo macOS Catalina. La cámara hiperespectral, la estructura y la caja de luz son mostradas en la Figura 3.



Figura 3. Hardware usado para capturar las imágenes del sistema de visión computacional. En la figura se muestra la estructura de MDF, usada para posicionar la cámara a una distancia y ángulo fijo; la caja de luz, usada para iluminar las rocas de manera uniforme y la cámara hiperespectral, la cual fue intercambiada por una cámara a color de acuerdo con el tipo de imagen que se necesitaba adquirir.

### 2.2.2. Imágenes

Las imágenes digitales son arreglos numéricos de dos o tres dimensiones que contienen información espacial y espectral de una escena. Las imágenes son capturadas por medio de dispositivos de adquisición,

como cámaras a color, cámaras hiperespectrales u otros. Las imágenes a color normalmente son representadas por un conjunto de tres matrices, donde cada una es una imagen monocromática que captura la intensidad de la luz en los canales rojo, verde y azul. Estos canales están centrados alrededor de las longitudes de onda con 665 nm, 550 nm y 470 nm respectivamente. De manera matemática, las imágenes a color pueden ser representadas por  $I_{RGB}(m, n, c)$ , donde  $m$  y  $n$  representan las coordenadas espaciales verticales y horizontales respectivamente y  $c$  representa los canales de la imagen. Las imágenes hiperespectrales funcionan bajo el mismo principio que las imágenes a color, con la principal diferencia que estas no están limitadas a tres canales de color, sino que pueden llegar a tener hasta decenas o cientos de bandas espectrales con un ancho de banda angosto. Las imágenes hiperespectrales son representadas de manera matemática por  $I_{HS}(m, n, \lambda)$ , donde  $\lambda$  representa las bandas espectrales de la imagen.

La cámara a color usada en el sistema de visión computacional propuesto genera imágenes con una resolución espacial de  $1836 \times 2448$  píxeles y usa el espacio de color RGB estándar (sRGB). En este caso en particular, la imagen representa una escena rectangular de  $151 \times 201$  mm, la cual permite capturar estructuras de hasta  $82 \mu\text{m}$ . La información de los píxeles está codificada en cadenas de 3 bytes, donde cada byte representa la intensidad de uno de los canales de color. Las imágenes tomadas por la cámara fueron almacenadas en memoria en formato JPEG (*Joint Photographic Experts Group*, en inglés) usando la opción de alta calidad de la cámara. Cabe resaltar que todas las imágenes tomadas por la cámara a color contienen solo una roca, como se muestra en los ejemplos mostrados en la Figura 2.

La cámara hiperespectral genera imágenes con una resolución espacial de  $512 \times 512$  píxeles, lo cual representa una escena de  $233 \times 233$  mm y permite capturar estructuras de hasta  $454 \mu\text{m}$ . El rango de longitudes de onda que puede registrar el sensor se encuentra entre 400 y 1000 nm, muestreados en 200 bandas con una resolución espectral de 7 nm. En las imágenes hiperespectrales generadas, cada píxel representa una curva espectral donde el patrón de intensidades en cada longitud de onda está asociado al tipo de roca presente en dicho píxel. Al igual que en el caso de la cámara a color, las imágenes hiperespectrales contienen solo una roca.




Figura 4. Diagrama de bloques del algoritmo de clasificación de minerales. En la primera etapa, la imagen a color y la imagen hiperespectral son segmentadas para separar los píxeles pertenecientes a la roca del fondo. Luego, la imagen a color es partida en subimágenes que contienen el color y la textura local de la roca, mientras que en la imagen hiperespectral se seleccionan solo algunas bandas espectrales que contienen la mayor cantidad de información. Las subimágenes y las curvas espectrales son procesadas para extraer vectores de características que sirven para crear mapas de distribución de minerales. Finalmente, los mapas se usan como entrada a un sistema de votación que decide si la roca está mineralizada o si es estéril.

Para poder entrenar y probar los algoritmos de clasificación, se creó una base de datos con 90 imágenes a color e imágenes hiperespectrales de rocas provenientes de la mina seleccionada. Estas imágenes fueron clasificadas por un geólogo de la mina seleccionada y posteriormente las rocas fueron enviadas a un laboratorio geoquímico para determinar su ley de oro y plata. La cantidad de rocas y ley promedio por tipo de mineral son mostrados en la Tabla 1. Los métodos usados por el laboratorio para estimar las leyes fueron ensayos al fuego y agua regia, con los cuales se obtuvieron los siguientes rangos de detección: 0.005-10 ppm para el oro y 10-1000 ppm para la plata. Luego de obtener la ley de oro y plata de cada roca, se calculó la ley de plata equivalente ( $L_{AgEq}$ ) usando la siguiente expresión:

$$L_{AgEq} = L_{Ag} + fL_{Au},$$

donde  $L_{Ag}$  es la ley de plata,  $L_{Au}$  es la ley de oro y  $f$  es un factor de conversión basado en la razón entre el precio de contado de la plata y el precio de contado del oro. En este trabajo se usa un factor de  $f = 81$  para calcular la ley de plata equivalente.

### 3. Algoritmos de procesamiento de imágenes y clasificación

Esta sección describe los principales métodos propuestos para el algoritmo de *ore sorting*. Primero, se presenta el problema de visión computacional para dar contexto a los algoritmos desde un punto de vista de procesamiento de imágenes. Luego, se describen los algoritmos de análisis de imágenes y aprendizaje automático, los cuales consisten en 4 partes principales: (i) el preprocesamiento de las imágenes, (2) la extracción de características, (iii) la clasificación y creación de mapas de distribución de minerales y (iv) el sistema de votación usado para asignar una clase final a cada roca.

#### 3.1. Problema de visión computacional

En muchos casos, la clasificación de minerales no es un problema trivial porque los algoritmos que se necesitan dependen específicamente de los minerales encontrados en la mina de interés (Tessier et al, 2007). En la última década, varias arquitecturas de redes neuronales convolucionales (CNN) han sido propuestas para resolver problemas de clasificación de imágenes. Este nuevo tipo de algoritmos puede aprender de manera automática la representación de características a partir de un conjunto de imágenes de entrenamiento (Rawat et al, 2017). De esta manera, las CNN son capaces de eliminar la etapa manual de ingeniería de características del flujo de procesamiento. Sin embargo, para entrenar una CNN se requiere una base de datos de imágenes grade, lo cual puede llegar a ser muy costoso en minería. Esto es especialmente cierto para algoritmos de *ore sorting*, donde los resultados de clasificación necesitan ser validados por medio de ensayos químicos.

En la mina seleccionada, el desarrollo de algoritmos de *ore sorting* tiene desafíos adicionales. A pesar de que las rocas de tipo mineral blanco (MB) y desecho verde (DV) pueden ser clasificadas fácilmente por su color distintivo, las rocas de tipo mineral gris (MG) y desecho morado (DM) tienen colores muy similares. La única diferencia entre estas dos últimas clases son los ligeros tonos morados del DM comparado con el MG, como se muestra en la Figura 2. El otro desafío relacionado a la clasificación de MG y DM es su alta variabilidad de clase. La cantidad de cuarzo presente en el MG y la cantidad de arcilla presente en el DM pueden variar drásticamente en cada roca. Debido a que el cuarzo tiene un color similar a las arcillas presentes en el DM, esto crea dificultades en su clasificación. Cabe resaltar que la clasificación correcta del MG y el DM es crucial debido a que, en promedio, el MG tiene alta ley y el DM tiene baja ley. Por los motivos presentados anteriormente, en este trabajo se

exploran otras alternativas de características aparte del color, como la textura y las curvas espectrales del mineral.

Para resolver el problema de visión computacional se requiere un flujo de procesamiento compuesto por varias etapas, como se muestra en la Figura 4. En la primera etapa, las imágenes a color e imágenes hiperespectral son segmentadas para encontrar los píxeles pertenecientes a la roca y luego la imagen a color es partida en subimágenes de menor tamaño. La segunda etapa consiste en la extracción de características de color y textura de cada subimagen a color y la extracción de curvas espectrales de la imagen hiperespectral segmentada. Luego, en la tercera etapa se usan redes neuronales para producir un primer mapa de clasificación a partir de las características de color y textura y máquinas de vectores soporte (SVM) para producir un segundo mapa de clasificación a partir de las curvas espectrales. Finalmente, en la cuarta etapa se usa un sistema de votación que decide la clase final de la roca a partir de los mapas de clasificación.

### 3.2. Preprocesamiento de imágenes

El primer paso de la etapa de preprocesamiento es la segmentación de la imagen a color y la imagen hiperespectral. La segmentación de una imagen consiste en crear una máscara binaria que separe los píxeles que corresponden a la roca, de los píxeles que corresponden al fondo de la imagen. La ventaja de este método es que permite que solamente las regiones relevantes de la imagen sean procesadas, reduciendo así el tiempo necesario para clasificar la imagen. Para ello, se usa un umbral binario, en el cual se le asigna un valor de 1 a los píxeles de la roca y un valor de 0 a los píxeles del fondo. Este método de segmentación es aplicado tanto a la imagen a color como la imagen hiperespectral usando la siguiente fórmula

$$M(m, n) = \begin{cases} 1, & \text{si } I(m, n, C) \geq T_M \\ 0, & \text{si } I(m, n, C) < T_M' \end{cases}$$

donde  $M(m, n)$  es la máscara binaria,  $I(m, n, C)$  representa la imagen a color o la imagen hiperespectral,  $T_M$  representa un umbral binario,  $m$  y  $n$  son las coordenadas espaciales de la imagen y  $C$  representa un canal de la imagen escogido manualmente por prueba y error. En este caso,  $C$  es el canal que representa el color verde, tanto en la imagen hiperespectral como en la imagen a color.

#### 3.2.2. Partición de la imagen a color

Luego de segmentar las imágenes, el segundo paso de la etapa de preprocesamiento consiste en partir la imagen a color en subimágenes. Muchas de las rocas de la base de datos son heterogéneas, lo cual quiere decir que contienen más de un tipo de mineral. El caso más común es de las rocas de andesita con vetas angostas de cuarzo, las cuales pueden llegar a tener una ley media mientras que las rocas de andesita pura siempre tienen una ley baja. Por este motivo, es importante saber cuál es la distribución de minerales en la roca.

En el caso de las imágenes hiperespectrales, la clasificación se da a nivel de píxel, lo cual permite crear mapas de distribución de minerales con una resolución muy alta. Sin embargo, en el caso de las imágenes a color, las características de textura son calculadas usando regiones de  $64 \times 64$  píxeles ( $5.25 \times 5.25$  mm) llamadas subimágenes. Debido a que la imagen a color tiene una resolución de  $1836 \times 2448$  píxeles, en total se generan 1064 subimágenes por cada imagen completa de la base de datos. En este trabajo, las subimágenes son representadas por  $S_p(m, n, c)$ , donde  $p$  es un número entero entre 1 y 1064.

Cada subimagen  $S_p(m, n, c)$  tiene información local sobre el color y la textura de la roca. Esto quiere decir que el fragmento de roca correspondiente a una subimagen tiene una alta probabilidad de contener un solo tipo de roca, lo cual ayuda a tener colores y texturas homogéneas. Además, el uso de subimágenes para la clasificación tiene otra ventaja, la cual es que al entrenar los algoritmos de clasificación con subimágenes en vez de imágenes completas se llega a crear una base de datos mucho más extensa, lo cual permite que los algoritmos de clasificación sean más robustos.

Luego de partir la imagen a color, el último paso de la etapa de preprocesamiento consiste en analizar las subimágenes para determinar cuáles de ellas contienen fragmentos de roca y cuales contienen parte del fondo. Para ello, se utiliza la máscara binaria creada en la etapa de segmentación y se cuenta el número de píxeles con valor igual a 1 dentro de la subimagen. Si al menos el 90% de los píxeles de la subimagen son parte de la máscara, entonces se considera que esta es válida y debe ser procesada. Por el contrario, si menos del 90% de píxeles son parte de la máscara, entonces el algoritmo asume que la subimagen es parte del fondo de la imagen y la descarta. Este proceso es mostrado de manera gráfica en la Figura 5.

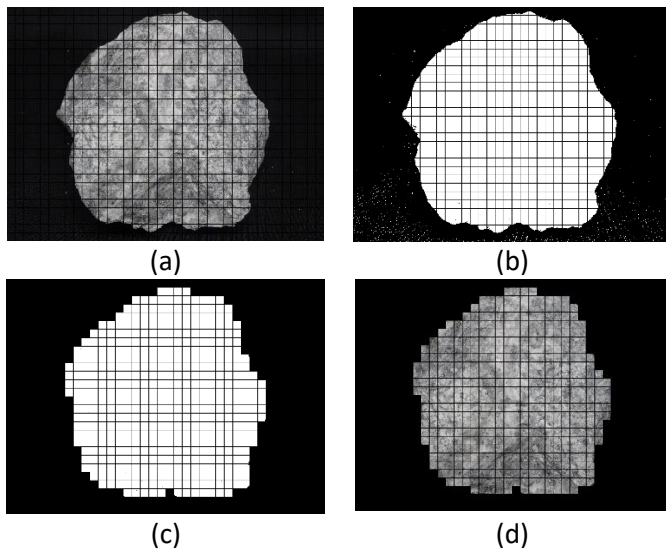


Figura 5. Etapa de segmentación y partición de imágenes a color. (a) La imagen  $I_{RGB}(m, n, c)$  es partida en subimágenes con dimensiones de  $64 \times 64$  píxeles. (b) Se crea una máscara binaria  $M(m, n)$  a partir de la imagen original. (c) Las submáscaras que contienen menos del 90% de píxeles válidos son descartadas. (d) El algoritmo crea las subimágenes a partir de las submáscaras válidas.

### 3.1. Extracción de características

Una vez identificadas las subimágenes válidas de la imagen a color y las curvas espectrales de la imagen hiperespectral, la siguiente etapa del algoritmo consiste en extraer vectores de características de ambas imágenes.

#### 3.1.1. Características de color

El primer paso para extraer las características de color consiste en transformar las subimágenes válidas del espacio de color rojo-verde-azul (RGB, por sus siglas en inglés) al espacio tono-saturación-valor (HSV, por sus siglas en inglés). El espacio de color HSV trata de representar el color de la imagen de manera más similar a como lo hacen las personas y es muy usado en aplicaciones de visión computacional, como en Indriani et al (2017), Bora et al (2017) y Zhang et al (2018). Las ecuaciones necesarias para transformar una imagen del espacio RGB al espacio HSV son conocidas en la literatura y pueden ser encontradas en Ibraheem et al (2012). Las características de color están compuestas por valores estadísticos de primer orden y los vectores de carga de los dos primeros componentes principales de las subimágenes en los espacios de color RGB y HSV. Tanto los valores estadísticos como los vectores de carga son obtenidos usando el algoritmo de análisis de componentes principales (PCA, por sus siglas en inglés).

Las imágenes a color en los espacios RGB y HSV contienen, en total, 6 canales de color que son representados por las imágenes monocromáticas  $S_R(m, n)$ ,  $S_G(m, n)$ ,  $S_B(m, n)$ ,  $S_H(m, n)$ ,  $S_S(m, n)$  y  $S_V(m, n)$ . La intensidad de los píxeles de estas imágenes tiene cierta distribución que puede ser caracterizada parcialmente por sus momentos estadísticos (John et al, 2007). El algoritmo de extracción de características de color utiliza los dos primeros momentos estadísticos de cada canal de color como descriptores del color de la roca, produciendo así 12 características de color. La razón principal por la cual se usan solamente los dos primeros momentos estadísticos es que su cálculo es computacionalmente eficiente y se realiza en el algoritmo de PCA.

Los componentes principales de las intensidades de píxeles en imagen contienen información acerca de las direcciones ortogonales de mayor varianza en cierto espacio de color, ya sea el espacio RGB o HSV. La Figura 6 muestra una representación gráfica de este proceso para un espacio de dos dimensiones. A diferencia de los parámetros estadísticos como la media y la varianza, los componentes principales toman en cuenta la correlación que existe entre los diferentes canales, lo cual los hace buenos descriptores del color y el contraste de la imagen (Yu et al, 2003). El uso de componentes principales en conjunto con parámetros estadísticos permite extraer características de color por canal y entre canales, lo cual sirve para describir el color de la roca de manera más completa.

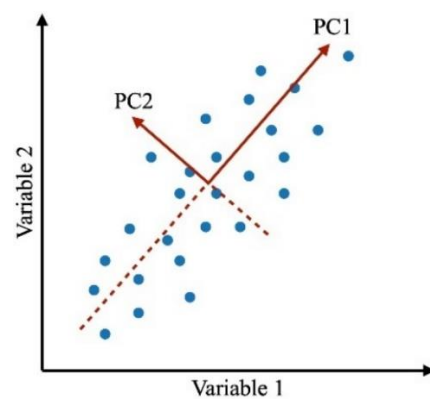


Figura 6. Representación gráfica de los componentes principales (PC1 y PC2) en un espacio de dos dimensiones.

Para poder hallar los componentes principales de cada subimagen, el algoritmo propuesto utiliza tres pasos principales. En el primer paso, las subimágenes en el espacio de color RGB y HSV, cuyas dimensiones son de  $64 \times 64 \times 3$ , deben ser reorganizadas en matrices de datos con dimensiones de  $4096 \times 3$ . En estas matrices, cada fila contiene los valores de intensidad de los tres canales de cada píxel en la subimagen. El segundo paso consiste en calcular la matriz de



covarianza de las dos matrices de datos, la cual está dada por

$$C = X_C^T X_C,$$

donde  $C$  es la matriz de covarianza y  $X_C$  es la matriz de datos centrada con respecto a la media de los tres canales de color. Finalmente, en el tercer paso se deben hallar los autovectores de la matriz de covarianza y ordenarlos de mayor a menor de acuerdo con la magnitud de sus autovalores. Los autovectores en el orden resultante corresponden a los componentes principales de la subimagen.

Aplicar el algoritmo PCA a las subimágenes en los espacios RGB y HSV produce en total 6 componentes principales (tres por cada espacio de color), donde cada componente es un vector de tres dimensiones. El algoritmo de extracción de características de color utilizado en este trabajo solo utiliza los dos primeros componentes principales, ya que se observó que estos representan, en promedio, el 99.93% de la varianza para el espacio de color RGB y el 99.54% en el espacio HSV. Debido a que los cuatro componentes principales seleccionados son vectores de tres dimensiones y además se calculó la media y la varianza de cada canal de color, en total se tienen 24 características de color por cada subimagen.

### 3.1.2. Características de textura

La textura visual de una imagen está definida por las variaciones locales de intensidad generadas por la rugosidad o los desniveles de la superficie de un objeto (Davies, 2008). La descomposición por *wavelets* es un método usado comúnmente para analizar texturas que consiste en descomponer imágenes monocromáticas en un conjunto de imágenes de menor resolución que contienen información frecuencial en diferentes escalas (Gonzalez et al, 2017). El análisis por *wavelets* descompone las imágenes usando bancos de filtros pasa bajos y pasa altos, los cuales deben cumplir con una serie de requisitos para que la imagen pueda ser reconstruida de manera perfecta (Strang, 1989). Luego de ser filtradas, las imágenes son decimadas por un factor de dos para reducir su resolución a la mitad y eliminar la información redundante. Los filtros usados para descomponer la imagen provienen de una familia específica de *wavelets* y son escogidos de acuerdo con la aplicación específica.

Al analizar una imagen en escala de grises se producen cuatro nuevas matrices. La primera matriz, llamada la imagen de aproximación, contiene las

frecuencias bajas de la imagen original. Por el contrario, la segunda, tercera y cuarta matriz, llamadas las imágenes de detalle horizontal, vertical y diagonal respectivamente, contienen información de alta frecuencia de la imagen original en sus respectivas direcciones. Debido a que la imagen de aproximación es simplemente una versión de menor resolución de la imagen original, el análisis por *wavelets* puede ser aplicado a esta imagen de forma recursiva un número arbitrario de veces para producir un análisis multirresolución (Bovik, 2009). La Figura 7 muestra el resultado del análisis por *wavelets* en tres niveles para una imagen de ejemplo.



Figura 7. Descomposición por *wavelets* en tres niveles para una imagen de ejemplo usando el *wavelet* Haar de dos coeficientes.

En el algoritmo propuesto, los filtros usados para la descomposición por *wavelets* están asociados al *wavelet* Haar de dos coeficientes. A pesar de que existen muchos tipos y familias de *wavelets*, el *wavelet* Haar es el más fácil de implementar y el menos costoso desde el punto de vista computacional (Sun et al, 2002), lo cual es deseable en algoritmos de *ore sorting*. Los filtros asociados a este tipo de *wavelet* están dados por  $h_\phi(n) = \frac{1}{2}\{\sqrt{2}, -\sqrt{2}\}$  y  $h_\psi(n) = \frac{1}{2}\{\sqrt{2}, -\sqrt{2}\}$ , donde  $h_\phi(n)$  es el filtro pasa bajos y  $h_\psi(n)$  es el filtro pasa altos. La etapa del algoritmo encargada de extraer las características de textura usa estos filtros para generar el análisis por *wavelets* en tres niveles, produciendo así cuatro imágenes de aproximación y ocho imágenes de detalle.

El análisis de textura por *wavelets* (WTA, por sus siglas en inglés) es un método usado para extraer información sobre la textura de una imagen usando las imágenes de detalle y aproximación obtenidas por medio de la descomposición por *wavelets*. El método más común para extraer información de textura es calculando la energía ( $E$ ) de cada matriz, la cual está definida por

$$E = \sum_{m=1}^M \sum_{n=1}^N |S_{EG}(m, n)|^2,$$

donde  $S_{EG}(m, n)$  es una de las imágenes en escala de grises producidas por la descomposición por *wavelets* y  $M$  y  $N$  son el número filas y columnas de la imagen, respectivamente. El método de WTA está basado en el supuesto de que los vectores de características de texturas similares forman grupos en el espacio de características, lo cual los separa de otros grupos asociados a texturas distintas. Por este motivo, el algoritmo propuesto usa la energía de las 12 imágenes creadas en el proceso de descomposición como el vector de características que representa la textura de cada subimagen.

### 3.1.3. Características hiperespectrales

Las imágenes hiperespectrales capturan información de diferentes partes del espectro electromagnético, para lo cual se necesitan sensores individuales o colecciones de sensores. En el caso de las cámaras hiperespectrales que operan en el espectro infrarrojo cercano (NIR, por sus siglas en inglés), se usa un arreglo lineal de sensores que capturan luz en diferentes longitudes de onda con una resolución espectral alta, lo cual produce imágenes de una dimensión. Al agrupar varias de estas imágenes de una dimensión, desplazadas espacialmente, es posible construir imágenes hiperespectrales completas de dos dimensiones, las cuales son representadas por  $I_{HS}(m, n, \lambda)$ . La ventaja principal de las imágenes hiperespectrales es que cada píxel contiene decenas o cientos de canales espectrales, a comparación con las imágenes a color que solo tienen tres canales. El uso de un número grande de canales permite identificar la firma espectral de los diferentes minerales en la roca y ver diferencias en regiones del espectro que no son visibles para los humanos o las cámaras a color convencionales. Por ejemplo, dos materiales que tienen el mismo color en el espectro visible (380-750 nm) podrían ser diferenciados en cierto rango de longitudes de onda del espectro infrarrojo cercano (750-2500 nm). La razón por la cual ocurre esto es que los materiales interactúan de forma distinta con cada frecuencia (o longitud de onda) del espectro electromagnético, ya sea absorbiendo, reflejando o refractando la onda. Esta interacción está correlacionada con la composición química del material.

El sistema de clasificación basado en las características NIR de la roca utiliza la firma espectral de cada píxel válido, es decir, que es parte de la

máscara binaria, como vector de característica al sistema de clasificación. Es decir, todas las curvas hiperespectrales  $h(\lambda)$  que son parte de la roca son concatenadas en una matriz de datos  $X_{HSI}$  con dimensiones  $N_\lambda \times N_p$ , donde  $N_\lambda$  es la cantidad de canales espectrales y  $N_p$  es el número de píxeles válidos de la imagen. La cámara usada en el sistema de visión computacional propuesto tiene 204 canales espectrales con longitudes de onda entre 400-1000 nm. La Figura 8 muestra una curva espectral de ejemplo para cada una de las clases de mineral que pueden ser identificadas por el algoritmo propuesto.

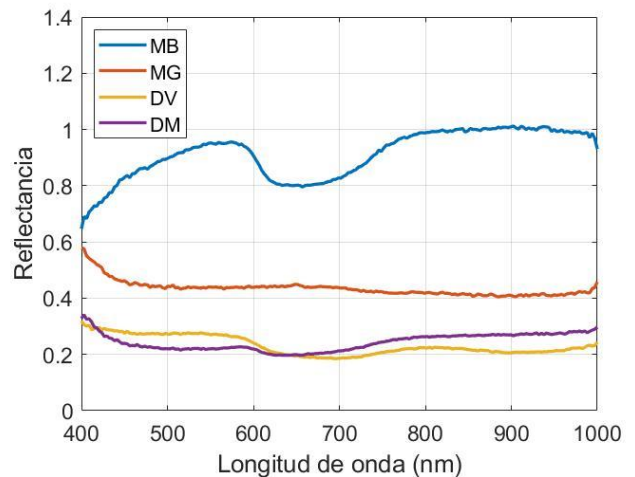


Figura 8. Curvas espectrales de ejemplo para los cuatro tipos de minerales: mineral blanco (MB), mineral gris (MG), desecho verde (DV) y desecho morado (DM).

Los patrones espectrales describen las características del material en una resolución a nivel de píxel, la cual en este caso corresponde a un área de  $454 \times 454 \mu\text{m}$ . El algoritmo propuesto puede usar patrones del espectro visual, el espectro NIR o solamente algunas bandas de interés. Las características espectrales más resaltante de cada mineral no necesariamente se encuentran a lo largo de todo el espectro, sino que muchas veces se encuentran en un rango específico de longitudes de onda. Por ejemplo, en una aplicación donde las características más resaltantes del mineral se encuentran en el espectro NIR, las bandas del espectro visible no serían útiles como vectores de características para un problema de clasificación de minerales. Usar un grupo reducido de bandas espectrales es recomendado porque permite reducir el tiempo de transferencia de datos entre la cámara y el procesador y el tiempo de procesamiento que toma el algoritmo en procesar y clasificar la imagen.

En este sentido, cada imagen hiperespectral  $I(m, n, \lambda)$  de la base de datos fue dividida en grupos limitados por un conjunto de longitudes de onda específicas. Luego, se entrenaron y probaron distintos clasificadores usando imágenes con el grupo limitado

de longitudes de onda. Finalmente, un nuevo clasificador unificado agrupa los rangos del espectro que obtuvieron los mejores resultados de clasificación, eliminando así la información del espectro que no es relevante para la clasificación. Esto ayuda a reducir el tiempo de procesamiento y a su vez mejora el desempeño de clasificación del algoritmo, como se demuestra en secciones posteriores.

### 3.2. Algoritmos de clasificación

Luego de extraer las características de color y textura de cada subimagen, así como las curvas espectrales, la siguiente etapa del algoritmo consiste en usar modelos de clasificación para crear mapas de distribución de minerales, los cuales son combinados en una etapa posterior para encontrar la clase final de la roca.

#### 3.1.3. Clasificación con características de color y textura

El primer mapa de distribución de minerales es creado a partir de las características de color y textura usando redes neuronales artificiales. Las redes neuronales son una familia de algoritmos de clasificación y regresión usadas para aproximar funciones desconocidas a partir de una colección de datos de entrada y de salida. Una de las ventajas principales de las redes neuronales sobre otros algoritmos de clasificación y regresión es que no requieren conocer la distribución de datos de manera previa, lo cual es especialmente útil cuando se trabaja con datos con un gran número de variables (Bishop, 2006).

Las redes neuronales están compuestas por unidades básicas de procesamiento, llamadas neuronas artificiales o unidades neuronales. Estas unidades neuronales son funciones no lineales que toman como parámetros de entrada un vector de características  $\vec{x} \in \mathbb{R}^d$ , un vector de pesos  $\vec{w} \in \mathbb{R}^d$  y un sesgo  $b \in \mathbb{R}$ . La salida de la unidad neuronal está dada por

$$\hat{y} = g(\vec{w}^T \vec{x} + b),$$

donde  $g(\cdot)$  es una función no lineal conocida como la función de activación.

Para entrenar una red neuronal a partir de un conjunto de datos de entrada y de salida, el algoritmo debe hallar los pesos que maximicen la función de costo de la red neuronal, lo cual se hace usualmente con el algoritmo de descenso de gradiente (Murphy, 2012). Este algoritmo es un método de optimización

numérica que calcula la gradiente de la función de costo con respecto a los pesos de la red y toma pequeños pasos en la dirección con mayor pendiente hasta encontrar los pesos óptimos. El método de retropropagación (*backpropagation*, en inglés) usa la regla de la cadena para descomponer la gradiente en varias derivadas más simples basadas en funciones conocidas. Este proceso es ampliamente conocido y se explica con mayor detalle en otras fuentes, como Gonzalez et al (2017).

El algoritmo de clasificación basado en características de color y textura consiste en un conjunto de redes neuronales operando en paralelo, donde cada una de ellas se especializa en la clasificación de un mineral en particular. En el caso de la mina seleccionada, se usan cuatro redes neuronales debido a los cuatro tipos principales de roca. Cada red neuronal está compuesta por una capa de entrada, dos capas ocultas y una capa de salida. El uso de dos o más capas ocultas permite que el algoritmo encuentre fronteras de decisión arbitrariamente complejas, a diferencia del uso de una sola capa oculta que se limita a fronteras convexas (Gonzalez et al, 2017). Cada capa oculta contiene 200 unidades neuronales con la función de activación ReLU (*Rectified Linear Unit*, en inglés). La capa de salida de cada red neuronal tiene solo una neurona con la función de activación logística, la cual mapea la salida de la red neuronal a un valor entre [0,1] que puede interpretarse como la probabilidad pertenencia a una clase.

Cada una de las redes neuronales en la etapa de clasificación tiene la misma entrada, la cual es una matriz  $X_{CT}$ , donde el subíndice CT se refiere al color y la textura. La matriz  $X_{CT}$  tiene dimensiones  $N_s \times 36$ , donde  $N_s$  es el número de subimágenes válidas de la roca y 36 es el número de características de color y textura (24 de color y 12 de textura). Cabe resaltar que antes de pasar por las redes neuronales, la matriz de características es normalizada usando la puntuación  $z$  (*z-score*, en inglés), la cual tiene una media igual a cero y desviación estándar igual a uno. Normalizar la matriz de características reduce el número de iteraciones necesarias para que los pesos de la red neuronal converjan en la etapa de retropropagación (LeCun et al, 2012). Luego de ser normalizada, las cuatro redes neuronales procesan la matriz de características y cada una de ellas produce un vector de probabilidades  $\hat{y}_{CT,m}$  con dimensiones  $N_s \times 1$ . Cada elemento del vector es un número entre [0,1] que representa la probabilidad de que la subimagen correspondiente pertenezca a la clase de mineral  $m$ , que en este caso puede ser MB, MG, DV o DM.

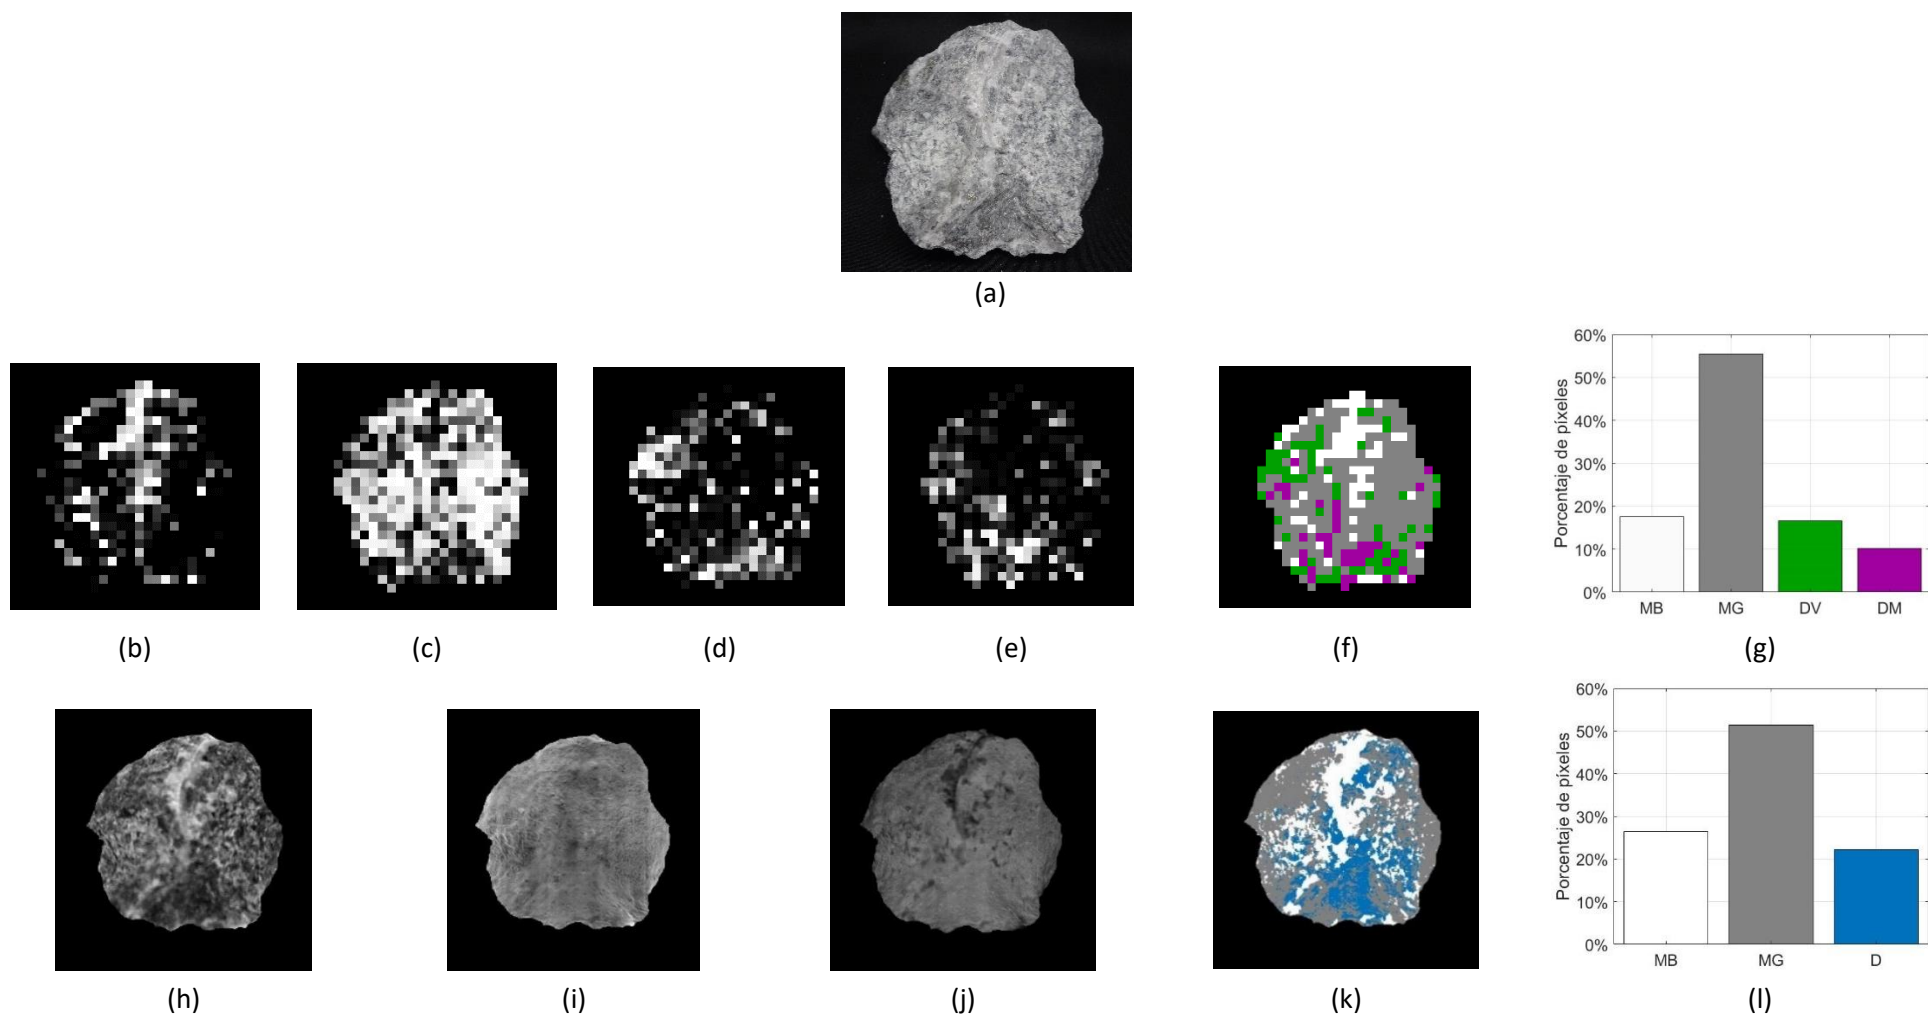


Figura 9. Mapas de distribución de minerales generados por los algoritmos de clasificación. (a) Imagen a color de una roca de tipo mineral gris (MG). (b-e) Mapas de probabilidades para las clases MB, MG, DV y DM, generados a partir de las características de color y textura. (f) Mapa de distribución de minerales generado a partir de las características de color y textura. (g) Distribución de minerales en la roca según las características de color y textura. (h-j) Mapas de probabilidades para las clases MB, MG y D (combinación de ambos tipos de desecho), generados a partir de las curvas espectrales. (k) Mapa de distribución de minerales generado a partir de las curvas espectrales. (l) Distribución de minerales en la roca según las curvas espectrales

### 3.1.3. Clasificación de curvas hiperespectrales

El segundo mapa de distribución de minerales es creado a partir de las curvas espectrales usando máquinas de vectores soporte. Las máquinas de vectores soporte (SVM, por sus siglas en inglés) son algoritmos de clasificación y regresión que tienen como objetivo encontrar la frontera de decisión que maximice la separación entre dos clases, en el caso de la clasificación, o encontrar la curva que mejor se ajuste a la tendencia de un grupo de datos, en el caso de la regresión. Para encontrar la frontera de decisión, la SVM utiliza los puntos del conjunto de entrenamiento que están en el límite entre las dos clases, los cuales son llamados los vectores de soporte (Murphy et al, 2012). La distancia entre los vectores de soporte y el plano se conoce como el margen y está dada por

$$\gamma = \frac{\|\vec{w}\|}{\vec{w}^T \vec{w}} = \frac{1}{\|\vec{w}\|},$$

donde  $\gamma$  es el margen y  $\vec{w}$  es el vector normal al plano  $\vec{w}^T \vec{x} + b = 0$ . Debido a que el margen está definido como la inversa del módulo del vector  $\vec{w}$ , el problema de maximización del margen puede ser redefinido como la minimización del módulo del vector  $\vec{w}$  de la siguiente manera:

$$\min_w \frac{1}{2} \|\vec{w}\|^2$$

sujeto a las condiciones de frontera

$$y^{(i)}(\vec{w}^T \vec{x}^{(i)} + b) \geq 1 - \zeta^{(i)},$$

donde  $y^{(i)}$  es la clase real correspondiente al vector  $\vec{x}^{(i)}$ ,  $(\vec{w}^T \vec{x}^{(i)} + b)$  es la predicción del clasificador y  $\zeta^{(i)} = \max(0, 1 - y^{(i)}(\vec{w}^T \vec{x}^{(i)} + b))$ .

En el caso de regresión, el proceso producido por la SVM depende solo de un grupo reducido de muestras, ya que el modelo no considera las muestras que se encuentran fuera del margen. En este caso, el entrenamiento es muy parecido al de la clasificación, con la diferencia que en el problema de optimización las condiciones de frontera están dadas por

$$|y^{(i)} - (\vec{w}^T \vec{x}^{(i)} + b)| \leq \varepsilon,$$

donde  $\varepsilon$  es una variable libre que indica que todos los puntos predichos tienen que estar a una distancia  $\varepsilon$  del valor real.

Una modificación importante que se suele usar en SVM es el truco del *kernel*, el cual se usa cuando los datos no son linealmente separables. Esta modificación consiste en proyectar los datos en un espacio con un mayor número de dimensiones donde se pueda encontrar un hiperplano que los separe de manera adecuada (Bishop et al, 2006). Los *kernels* más usados son los lineales, polinomiales, gaussianos y sigmoides.

Teniendo esto en cuenta, el algoritmo de clasificación basado en curvas espectrales está compuesto por modelos de regresión SVM en paralelo, de manera similar al algoritmo basado en las características de color y textura. La principal diferencia es que en esta etapa se usan tres SVM en vez de cuatro redes neuronales. La razón para usar tres modelos es que las curvas espectrales del DV y DM son muy parecidas entre sí, como se observa en la Figura 8, y por ello es conveniente agruparlas en una sola clase de desecho (D). Las SVM escogidas son modelos de regresión, ya que se busca que la salida de los modelos sea un número real que pueda ser comparado para determinar el grado de certeza con la que las curvas espectrales están siendo clasificadas. El *kernel* de la regresión es de tipo Gaussiano, ya que este tiene las siguientes propiedades: (i) garantiza que el modelo sea un predictor global óptimo, (ii) no se necesita conocer la distribución de los datos previamente y (iii) soportan modelos arbitrariamente complejos.

Cada una de las SVM usadas en la etapa de clasificación tiene como entrada una matriz de curvas hiperespectrales  $X_{\text{HSI}}$ . Las dimensiones de esta matriz son  $N_c \times N_b$ , donde  $N_c$  representa el número de curvas espectrales que pertenecen a la roca y  $N_b$  representa el número de bandas espectrales seleccionadas. En este caso, los vectores de características también son normalizados y luego procesados por las SVM, produciendo así tres vectores de probabilidades  $\hat{y}_{\text{HSI},m}$  con dimensiones  $N_c \times 1$ .

### 3.1.4. Mapas de distribución de minerales

Mediante el seguimiento de la ubicación espacial de las subimágenes y las curvas espectrales, el algoritmo propuesto ordena los vectores de probabilidades en mapas de predicción, representados por  $M_{\text{CT},m}$  y  $M_{\text{HSI},m}$ , donde  $m$  es una de las clases de roca. Las Figuras 9b-e y 9h-j muestran los mapas de probabilidades generados para una roca de tipo MG. Luego de crear los mapas basados en color y textura y los mapas basados en curvas espectrales, el siguiente paso es comparar los mapas de probabilidades para

determinar cuál es la clase de mineral es más probable para cada subimagen y para cada curva espectral respectivamente. Con ello, se construyen dos mapas nuevos, representados por  $M_{CT,DM}$  y  $M_{HSI,DM}$ , que muestran la distribución de minerales en la roca, como se muestra en las Figuras 9f y 9k. Finalmente, el algoritmo cuenta el número de subimágenes y curvas espectrales que pertenecen a cada clase de mineral y con ello genera dos vectores de distribución de minerales. Estos vectores representan el porcentaje de subimágenes y curvas espectrales clasificadas para cada tipo de mineral en la roca y funcionan como descriptores generales de la roca.

### 3.2. Algoritmo de votación

La etapa final del algoritmo de clasificación de minerales consiste en combinar los vectores de probabilidades creados usando las características de color y textura y aquellos creados usando las curvas espectrales para producir una sola clasificación final para toda la roca. Para ello, ambos vectores de probabilidades son concatenados en un nuevo vector de características, el cual es representado por  $\vec{x}_c$  y tiene dimensiones  $7 \times 1$ . Debido a que cada vector  $\vec{x}_c$  corresponde a las características de una roca, en total se tienen 90 vectores. Asimismo, las 90 rocas fueron enviadas a un laboratorio químico para estimar sus leyes de oro y plata, las cuales luego son combinadas en un solo valor de plata equivalente. Por lo tanto, cada vector  $\vec{x}_c$  está asociado a un valor de plata equivalente  $L_{AgEq}$ .

Los valores de plata equivalente son binarizados usando un umbral que es equivalente a la ley de corte, la cual en este caso es de 93 ppm. Es decir, a los valores de plata equivalente mayores a la ley de corte se le asigna un valor de uno y a los menores se les asigna un valor de cero. Estos nuevos valores binarizados son representados por  $y_{AgEq}$ .

Finalmente, para crear un modelo que aprenda a asociar los vectores de características  $\vec{x}_c$  a los valores binarizados  $y_{AgEq}$ , se entrena una SVM de regresión adicional. Esta SVM, al igual que las usadas en la etapa de clasificación de curvas espectrales, utiliza un *kernel* Gaussiano. La salida de este modelo es un número real que necesita un umbral binario para decidir si la roca en la imagen es mineral o desecho. Este umbral es hallado usando métodos de optimización, que tratan de maximizar la precisión del algoritmo.

## 4. Resultados y discusión

### 4.1. Entrenamiento de los modelos de clasificación para generar mapas de distribución de minerales

Los modelos de clasificación usados para crear los mapas de distribución de minerales fueron entrenados usando imágenes de rocas que fueron clasificadas por un geólogo pero que no fueron analizadas en un laboratorio geoquímico. Debido a que realizar análisis químicos de leyes es costoso, el uso de rocas clasificadas solamente por un geólogo permite crear una base de datos más extensa para el entrenamiento de los modelos que generan los mapas de distribución de minerales. Sin embargo, es importante resaltar que el modelo de SVM usando en el sistema de votación sí debe ser entrenado con data obtenida de los ensayos químicos, ya que este asocia la distribución de minerales obtenida en cada mapa a un único valor que indica si la roca es mineralizada o estéril. Teniendo esto en cuenta, las redes neuronales fueron entrenadas con las características de color y textura de subimágenes provenientes de 375 imágenes a color y las SVM fueron entrenadas con curvas espectrales provenientes de 175 imágenes hiperespectrales.

Como se explicó en secciones anteriores, el modelo usado para crear el mapa de distribución de minerales a partir de las curvas espectrales no necesariamente utiliza todas las bandas disponibles. Esto se debe a que muchas de ellas son bandas redundantes, que no tienen un beneficio en la precisión del algoritmo y que aumentan el tiempo de procesamiento. Por ello, en la etapa de entrenamiento del algoritmo, se entrenaron modelos con rangos reducidos de bandas espectrales, lo cual permite identificar con cuáles de ellas se obtiene un mayor desempeño. Los modelos de bandas reducidas son creados tomando una longitud de onda central y un ancho de banda de 20 nm, es decir, 10 nm por debajo y por encima de la longitud de onda central. Para cubrir todo el espectro, se entrenaron un total de 59 modelos. Entre dos modelos adyacentes siempre se tiene una separación de 20 nm, lo cual implica que siempre hay una superposición de 10 nm. Adicionalmente, se entrenó un modelo que usa todas las bandas espectrales disponibles para tomarlo de referencia. A diferencia del mapa basado en curvas espectrales, para el mapa basado en color y textura solo se entrenó un modelo que usa todas las características disponibles. Esto se debe a que solo se tienen 36 características de color y textura a diferencia de las 204 bandas espectrales. Por lo tanto, no es necesario reducirlas para mejorar el tiempo de procesamiento ni la precisión del algoritmo.

## 4.2. Entrenamiento y prueba del algoritmo de votación

El objetivo del entrenamiento del algoritmo de votación es encontrar el modelo que logre relacionar con mayor precisión la distribución de minerales con el estado de mineralización de la roca. Para encontrar la selección de características que producen el algoritmo de clasificación más preciso, se entrenaron en total 62 modelos: un modelo que usa solamente las 36 características de color y textura, un modelo que usa solamente las 204 bandas espectrales, un modelo que usa las 36 características de color y las 204 bandas espectrales y, finalmente, 59 modelos que combinan las características de color y textura con un rango reducido de bandas espectrales. Estos modelos fueron entrenados usando las 90 imágenes de rocas que fueron fotografiadas con la cámara a color y la cámara hiperespectral y que luego fueron enviadas a un laboratorio geoquímico para estimar su ley de plata equivalente.

Para poder entrenar y luego evaluar los modelos del algoritmo de votación, las 90 imágenes fueron divididas en un conjunto de entrenamiento y otro de evaluación. El conjunto de entrenamiento se forma seleccionando el 80% de las imágenes de la base de datos de manera aleatoria. Luego, para la etapa de evaluación se escoge el 20% de imágenes restantes y estas son analizadas por el algoritmo, produciendo un valor de clasificación para cada una de ellas. Debido a que en este caso solo se tenía una base de datos con 90 imágenes, para poder tener resultados estadísticamente significativos se realizaron 100 iteraciones, donde en cada una de ellas se escogen nuevos grupos de entrenamiento y prueba de manera aleatoria. El desempeño real del algoritmo luego fue estimado tomando la media y la desviación estándar de los resultados en las 100 iteraciones.

La métrica de evaluación principal usada en este trabajo es el coeficiente de correlación de Matthews (MCC, por sus siglas en inglés), el cual es útil cuando se tiene un número distinto de clases positivas y negativas (en este caso, rocas mineralizadas y no mineralizadas respectivamente). El MCC produce un valor real entre  $-1$  y  $+1$  de acuerdo con la precisión del clasificador. Un valor de  $+1$  indica que todas las imágenes son clasificadas correctamente, un valor de  $0$  indica que las imágenes son clasificadas de manera aleatoria y un valor de  $-1$  indica que todas las imágenes son clasificadas incorrectamente. El MCC es calculado a partir del número de imágenes clasificadas como verdaderos positivos (VP), verdaderos negativos (VN),

falsos positivos (FP) y falsos negativos (FN) de la siguiente manera

$$MCC = \frac{VP/N - S \times P}{\sqrt{P \times S \times (1 - S) \times (1 - P)}}$$

donde

$$N = VN + VP + FN + FP,$$

$$S = (VP + FN)/N$$

y

$$P = (VP + FP)/N.$$

La Tabla 2 muestra el MCC promedio para seis modelos de interés, donde los primeros tres son modelos de referencia y los últimos tres son aquellos que obtuvieron el mejor desempeño. En la tabla, se puede observar que el uso de las características de color y textura junto con las bandas espectrales entre 620-640 nm producen el mayor MCC promedio (0.9787). Esto representa que, en promedio, el 98.4% de rocas mineralizadas y el 98.6% de rocas estériles fueron bien clasificadas. Otros modelos que obtuvieron un MCC promedio alto son los que usan bandas entre 630-650 nm (0.9716) y 420-440 nm (0.9636). Al comparar los mejores modelos con los modelos de referencia, se notó que el peor de ellos es aquel que solamente usa características de color y textura, seguido por el modelo que solo usa bandas espectrales y luego el que combina las características de color y textura con las 204 bandas espectrales. Esto demuestra dos cosas importantes: (i) que es necesario combinar características de color, textura y curvas espectrales para alcanzar los mejores resultados y (ii) que la mayoría de las bandas espectrales son redundantes, lo cual reduce el desempeño del algoritmo.

Tabla 2. Comparación de los modelos de clasificación de minerales según los parámetros estadísticos del coeficiente de correlación de Matthews (MCC) para 100 iteraciones de entrenamiento y evaluación. Los parámetros estadísticos usados son la media ( $\mu$ ), desviación estándar ( $\sigma$ ), el valor mínimo (mín) y el valor máximo (máx).

Modelo	$\mu$	$\sigma$	mín	máx
RGB	0.8246	0.1437	0.3698	1
HSI	0.8931	0.1111	0.5470	1
RGB+400-1000nm	0.8955	0.1273	0.4462	1
RGB+420-440nm	0.9636	0.0839	0.6518	1
RGB+620-640nm	<b>0.9787</b>	<b>0.0608</b>	<b>0.7077</b>	<b>1</b>
RGB+630-650nm	0.9716	0.0864	0.6518	1

Adicionalmente, para observar con mayor detalle la robustez del algoritmo de clasificación de minerales, se hizo un análisis de la distribución de resultados para el mejor modelo de clasificación y se comparó con aquel que usa todas las bandas espectrales. La figura 10 muestra que el modelo de color, textura y bandas espectrales entre 620-640 nm es más consistente, ya que su distribución es menos dispersa. Esto se puede medir de manera numérica usando la desviación estándar, la cual tiene un valor de 0.0608 para el modelo con bandas espectrales entre 620-640 nm y de 0.1437 para el modelo que usa todas las bandas espectrales.

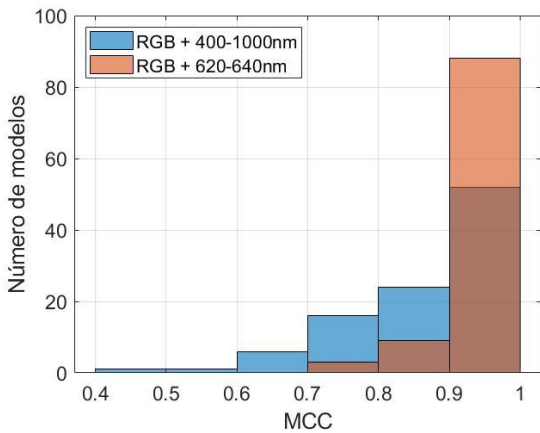


Figura 10. Distribución del coeficiente de correlación de Matthews en 100 iteraciones de entrenamiento y evaluación para un modelo de referencia (color, textura y bandas espectrales entre 400-1000 nm) y el mejor modelo obtenido (color, textura y bandas espectrales entre 620-640 nm).

### 4.3. Cálculo de recuperación y reducción de masa

Luego de seleccionar el mejor modelo de clasificación, es decir, aquel que utiliza las características de color, textura y curvas espectrales entre 620-640 nm, se realizó una simulación para estimar la recuperación de mineral y el porcentaje (*mass pull*, en inglés) de masa que tendría el algoritmo de *ore sorting* si estuviera operando en la mina seleccionada. La recuperación ( $R$ ) representa la cantidad de oro y plata que contienen las rocas clasificadas como mineral con respecto al total. De manera similar, la proporción de masa ( $MP$ ) representa la cantidad de masa de las rocas clasificadas como mineral con respecto al total. Estas dos métricas de evaluación son calculadas de la siguiente manera:

$$R = \frac{\sum_{m=1}^M W_m L_m}{\sum_{t=1}^T W_t L_t}$$

y

$$MP = \frac{\sum_{m=1}^M W_m}{\sum_{t=1}^T W_t}$$

donde  $M$  es el total de rocas clasificadas como mineral,  $m$  es el índice del conjunto de rocas clasificadas como mineral,  $T$  es el número total de rocas,  $t$  es el índice del conjunto total de rocas,  $W$  es el peso de la roca en gramos y  $L$  es la ley de plata equivalente de la roca en gramos por tonelada.

Al igual que para el entrenamiento y prueba del algoritmo de votación, para hallar la proporción de masa y la recuperación del algoritmo, se hicieron 100 pruebas, seleccionando grupos de rocas de manera aleatoria para entrenar modelos de clasificación usando las bandas seleccionadas (620-640 nm) y luego usando el resto de las rocas para calcular la recuperación y la proporción de masa. Sin embargo, debido a que los grupos de roca son seleccionados de manera aleatoria, esto no garantiza que tengan la misma proporción de mineral y desecho que se encuentra en la mina seleccionada. Por ello, se debe hacer una normalización, en la cual se encuentra el desempeño de clasificación por cada tipo de mineral y luego se usa esto para calcular la recuperación y la proporción de masa usando las proporciones reales de minerales.

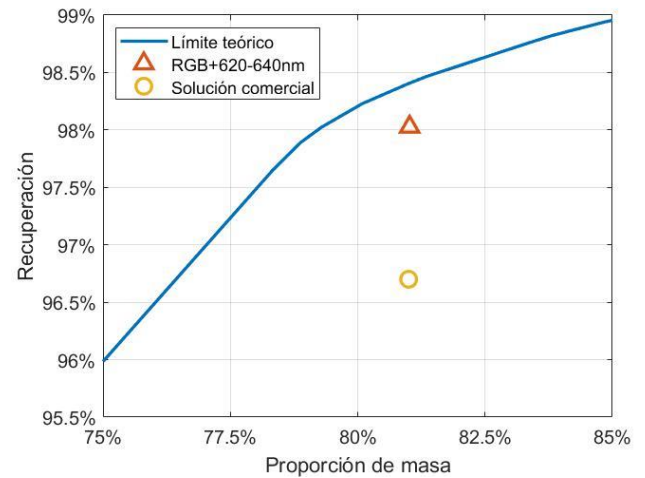


Figura 11. Resultados de recuperación y proporción de masa para el algoritmo seleccionado (naranja). Los resultados se comparan con pruebas realizadas con una solución comercial (amarillo) y con el límite teórico (azul).

La Figura 11 muestra los resultados de proporción de masa y recuperación para el algoritmo propuesto y se comparan con los resultados obtenidos usando una máquina de *ore sorting* comercial. Además, se muestra el límite teórico, obtenido cuando se clasifican todas las rocas de manera perfecta. Es decir, este límite representa la recuperación máxima que se puede alcanzar para cada valor de proporción de masa cuando se varían los parámetros del algoritmo. Con el algoritmo propuesto, se logró alcanzar una recuperación del 98.0% para una proporción de masa del 81.0%, mientras que en las pruebas con la solución



comercial se obtuvo una recuperación del 96.7% para una proporción de masa del 81.0%. Esto demuestra que el algoritmo propuesto es superior para el problema de clasificación de minerales de la mina seleccionada, ya que permite recuperar hasta 1.3% más de mineral sin tener que aumentar la cantidad de masa enviada a la planta de procesamiento. Es decir, al ser implementado en la mina seleccionada, el algoritmo permitiría producir una mayor cantidad de concentrado de mineral sin necesidad de aumentar los costos de procesamiento.

## 5. Conclusiones

En este trabajo se propuso un algoritmo novedoso de *ore sorting* para la clasificación de rocas de una mina de oro y plata usando inteligencia artificial y análisis de color, textura y curvas espectrales. El algoritmo fue entrenado con una base de datos de imágenes a color e imágenes hiperespectrales de rocas extraídas de una mina subterránea ubicada en los andes peruanos. Las imágenes en la base de datos fueron clasificadas manualmente por un geólogo experto y luego enviadas a un laboratorio geoquímico para estimar su ley de oro y plata. El problema de clasificación de minerales para esta mina es particularmente desafiante porque las características visuales de las rocas de alta ley son muy parecidas a las de las rocas de baja ley.

El desempeño del algoritmo de clasificación fue evaluado usando el coeficiente de correlación de Matthews (MCC). Bajo esta métrica, se encontró que el mejor modelo utiliza las características de color y textura de la imagen a color y bandas espectrales entre 620 y 640 nm de la imagen hiperespectral, obteniendo un MCC promedio de 0.9787 puntos. Asimismo, se estimó que, al ser implementado en la mina seleccionada, el algoritmo tiene el potencial de aumentar la recuperación del mineral en 1.3% sin tener que aumentar la cantidad de mineral enviado a la planta de procesamiento. Es decir, el algoritmo propuesto podría llegar a optimizar el uso de recursos para la producción de oro y plata, reduciendo así los costos y el impacto ambiental de la operación.

La parte del algoritmo que utiliza solamente cámaras a color fue parte de una tesis de pregrado, la cual fue sustentada con honores y ganó un premio de investigación otorgado por la Universidad de Ingeniería y Tecnología (UTEC). Asimismo, debido a los resultados sobresalientes en comparación con una máquina comercial de un proveedor internacional, el sistema de *ore sorting* completo se encuentra en proceso de patente y podrá ser implementado en una de las minas

de la empresa Hochschild Mining en el futuro. Esta invención ha sido desarrollada completamente en Perú y sobresale por encima de métodos actuales internacionales.

## Agradecimientos

Agradecemos a la empresa Hochschild Mining por haber brindado las muestras de roca para realizar este trabajo. Asimismo, agradecemos a los geólogos Chrystian Pajares y Jhon Fernández, quienes prestaron su tiempo para realizar la clasificación de rocas y para enseñarnos algunos conceptos de geología.

## Referencias

- Priester M., Ericsson, M., Dolega, P., Löf, O. (2019). Mineral grades: an important indicator for environmental impact of mineral exploitation. *Mineral Economics*, 32(1), 49-73.
- Cho, K., Kim, H., Myung, E., Purev, O., Choi, N., Park, C. (2020). Recovery of gold from the refractory gold concentrate using microwave assisted leaching. *Metals*, 10(5), 571.
- Calvo, G., Palacios, J. L., Valero, A. (2022). The influence of ore grade decline on energy consumption and ghg emissions: The case of gold. *Environmental Development*, 41, 100683.
- Elliott, R., Barati, M. 2020. A review of the beneficiation of low-grade manganese ores by magnetic separation. *Canadian Metallurgical Quarterly*, 59(1), 1-16.
- Ulrich, S., Trench, A., Hagemann, S. 2019. Grade-cost relationships within Australian underground gold mines—A 2014–2017 empirical study and potential value implications. *Resources Policy*, 61, 29-48.
- La Brooy, S. R., Linge, H. G., Walker, G. S. (1994). Review of gold extraction from ores. *Minerals Engineering*, 7(10), 1213-1241.
- Lee, S., Gibson, C. E., Ghahreman, A. (2021). The Separation of Carbonaceous Matter from Refractory Gold Ore Using Multi-Stage Flotation: A Case Study. *Minerals*, 11(12), 1430.
- Lessard, J., de Bakker, J., McHugh, L. (2014). Development of ore sorting and its impact on mineral processing economics. *Minerals Engineering*, 65, 88-97.
- Lessard, J., Sweetser, W., Bartram, K., Figueroa, J., McHugh, L. (2016). Bridging the gap: Understanding the economic impact of ore sorting on a mineral processing circuit. *Minerals Engineering*, 91, 92-99.
- Robben, C., Wotruba, H. (2019). Sensor-based ore sorting technology in mining—past, present and future. *Minerals*, 9(9), 523.

- Simmons, S. F., White, N. C., John, D. A. (2005). Geological characteristics of epithermal precious and base metal deposits.
- Siani, M. G., Mehrabi, B., Nazarian, M., Lotfi, M., Corfu, F. (2022). Geology and genesis of the Chomalu polymetallic deposit, NW Iran. *Ore Geology Reviews*, 143, 104763.
- Tessier, J., Duchesne, C., Bartolacci, G. (2007). A machine vision approach to on-line estimation of run-of-mine ore composition on conveyor belts. *Minerals Engineering*, 20(12), 1129-1144.
- Zhang, M., Shi, H., Zhang, Y., Yu, Y., & Zhou, M. (2021). Deep learning-based damage detection of mining conveyor belt. *Measurement*, 175, 109130.
- Singh, V., Rao, S. M. (2005). Application of image processing and radial basis neural network techniques for ore sorting and ore classification. *Minerals Engineering*, 18(15), 1412-1420.
- McCoy, J. T., Auret, L. (2019). Machine learning applications in minerals processing: A review. *Minerals Engineering*, 132, 95-109.
- Perez, C. A., Estévez, P. A., Vera, P. A., Castillo, L. E., Aravena, C. M., Schulz, D. A., Medina, L. E. (2011). Ore grade estimation by feature selection and voting using boundary detection in digital image analysis. *International Journal of Mineral Processing*, 101(1-4), 28-36.
- Perez, C. A., Saravia, J. A., Navarro, C. F., Schulz, D. A., Aravena, C. M., Galdames, F. J. (2015). Rock lithological classification using multi-scale Gabor features from sub-images, and voting with rock contour information. *International Journal of Mineral Processing*, 144, 56-64.
- Dalm, M., Buxton, M. W. N., Van Ruitenbeek, F. J. A. (2015, August). Applicability of near-infrared hyperspectral imagery (NIR-HI) for sensor based sorting of an epithermal Au-Ag ore. In *Proc. 54th Annu. Conf. Metallurgists* (pp. 1-12).
- Robben, M. R., Knapp, H., Wotruba, H. (2012). Applicability of near infrared sorting in the minerals industry. *NIR news*, 23(6), 15-17.
- Dalm, M., Buxton, M. W. N., Van Ruitenbeek, F. J. A. (2017). Discriminating ore and waste in a porphyry copper deposit using short-wavelength infrared (SWIR) hyperspectral imagery. *Minerals engineering*, 105, 10-18.
- Gülcan, E., Gülsoy, Ö. Y. (2018). Evaluation of complex copper ore sorting: Effect of optical filtering on particle recognition. *Minerals Engineering*, 127, 208-223.
- Tuşa, L., Kern, M., Khodadadzadeh, M., Blannin, R., Gloaguen, R., Gutzmer, J. (2020). Evaluating the performance of hyperspectral short-wave infrared sensors for the pre-sorting of complex ores using machine learning methods. *Minerals Engineering*, 146, 106150.
- Liu, Y., Zhang, Z., Liu, X., Wang, L., Xia, X. (2021). Deep learning-based image classification for online multi-coal and multi-class sorting. *Computers & Geosciences*, 157, 104922.
- Liu, Y., Zhang, Z., Liu, X., Wang, L., Xia, X. (2021). Performance evaluation of a deep learning based wet coal image classification. *Minerals Engineering*, 171, 107126.
- Liu, Y., Zhang, Z., Liu, X., Wang, L., Xia, X. (2021). Ore image classification based on small deep learning model: Evaluation and optimization of model depth, model structure and data size. *Minerals Engineering*, 172, 107020.
- Wang, X., Zhou, J., Wang, Q., Liu, D., Lian, J. (2022). An unsupervised method for extracting semantic features of flotation froth images. *Minerals Engineering*, 176, 107344.
- Okada, N., Maekawa, Y., Owada, N., Haga, K., Shibayama, A., Kawamura, Y. (2020). Automated identification of mineral types and grain size using hyperspectral imaging and deep learning for mineral processing. *Minerals*, 10(9), 809.
- Corbett, G. (2002). Epithermal gold for explorationists. *AIIG News*, 67, 1-8.
- Sillitoe, R. H. (2000). Styles of high-sulphidation gold, silver and copper mineralization in porphyry and epithermal environments. In *Proceedings of the Australasian Institute of Mining and Metallurgy*, 305(1), 19-34.
- Gibson, H. L., Watkinson, D. H., Comba, C. D. A. (1983). Silicification; hydrothermal alteration in an Archean geothermal system within the Amulet Rhyolite Formation, Noranda, Quebec. *Economic Geology*, 78(5), 954-971.
- Rawat, W., Wang, Z. (2017). Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*, 29(9), 2352-2449.
- Indriani, O. R., Kusuma, E. J., Sari, C. A., Rachmawanto, E. H. (2017, November). Tomatoes classification using K-NN based on GLCM and HSV color space. In *2017 international conference on innovative and creative information technology (ICITech)* (pp. 1-6). IEEE.
- Bora, D. J. (2017). A novel approach for color image edge detection using multidirectional Sobel filter on HSV color space. *Int. J. Comput. Sci. Eng.*, 5(2), 154-159.
- Zhang, T., Hu, H. M., Li, B. (2018). A naturalness preserved fast dehazing algorithm using HSV color space. *IEEE Access*, 6, 10644-10649.
- Ibraheem, N. A., Hasan, M. M., Khan, R. Z., Mishra, P. K. (2012). Understanding color models: a review. *ARPN Journal of science and technology*, 2(3), 265-275.

- John, V., Angelov, I., Öncül, A. A., Thévenin, D. (2007). Techniques for the reconstruction of a distribution from a finite number of its moments. *Chemical Engineering Science*, 62(11), 2890-2904.
- Yu, H., MacGregor, J. F. (2003). Multivariate image analysis and regression for prediction of coating content and distribution in the production of snack foods. *Chemometrics and Intelligent Laboratory Systems*, 67(2), 125-144.
- Davies, E. R. (2008). Introduction to texture analysis. In *Handbook of texture analysis* (pp. 1-31).
- Gonzalez, R., Woods, R. (2017). *Digital Image Processing*. Pearson.
- Strang, G. (1989). Wavelets and dilation equations: A brief introduction. *SIAM review*, 31(4), 614-627.
- Bovik, A. C. (2009). *The essential guide to image processing*. Academic Press.
- Sun, Z., Miller, R., Bebis, G., DiMeo, D. (2002, dicembre). A real-time precrash vehicle detection system. En *Sixth IEEE Workshop on Applications of Computer Vision, 2002. (WACV 2002). Proceedings.* (pp. 171-176). IEEE.
- Bishop, C. M., Nasrabadi, N. M. (2006). *Pattern recognition and machine learning*. Springer.
- Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*. MIT press.
- LeCun, Y., Bottou, L., Orr, G. B., Müller, K. R. (1998). *Neural networks: Tricks of the trade*. Springer Lecture Notes in Computer Sciences, 1524(5-50), 6.

David G. Shatwell  
Ingeniero de Innovación  
Hochschild Mining PLC  
[david.shatwell@hocplc.com](mailto:david.shatwell@hocplc.com)

+51 961944700

Calle La Colonia 180, Urb. El Vivero, Santiago de Surco,  
Lima, Perú

Ingeniero Electrónico de la universidad de Ingeniería y Tecnología - UTEC (titulado 2021). Actualmente Ingeniero de Innovación en Hochschild Mining (2019-2022). Practicante de Investigación y Desarrollo en el Instituto Geofísico del Perú (2019). Asistente de Laboratorio de Circuitos Digitales en UTEC (2018). Sus áreas de investigación incluyen procesamiento de imágenes y *machine learning* en el sector minero y salud.

Victor Murray  
Associate  
Harvard University  
[victormurray@seas.harvard.edu](mailto:victormurray@seas.harvard.edu)

+1 551 3270323

33 Oxford St, Cambridge, MA 02138, Estados Unidos

PhD en Ingeniería Electrónica por la University of New Mexico (UNM, EE.UU.), Asociado en Harvard University, EE.UU., Profesor Investigador en UNM, y actualmente Senior Research Scientist en el Memorial Sloan Kettering Cancer Center, EE.UU. Sus áreas de investigación en la industria y en la academia incluyen procesamiento de imágenes y videos digitales, hardware reconfigurable, y educación en ingeniería.

Augusto Barton  
Corporativo de Innovación  
Hochschild Mining PLC  
[augusto.barton@hocplc.com](mailto:augusto.barton@hocplc.com)

+51 1 317-2000 x2312

Calle La Colonia 180, Urb. El Vivero, Santiago de Surco,  
Lima, Perú

MSc. Ingeniería Mecánica de Massachusetts Institute of Technology (2005). Actualmente Gerente Corporativo de Innovación en Hochschild Mining (2018-actual). Gerente de Ingeniería en Tesla (2011-2018). Investigador Científico en el Centro de Innovación de Xerox (2005-2011). Asistente de Investigación en el "Precision Motion Control Lab" en MIT (2003-2005). Ingeniero Piping y Mecánico en GMI (2001-2003).