

# Impact of Ore Sorting on the Operational Profitability of Polymetallic Deposits: A Systematic Review

Angel Gabriel, Frisancho Choquecota<sup>1</sup>; Abel Arturo, Yancapallo Quispe<sup>2</sup>; Gerby Giovanna, Rondan-Sanabria<sup>3</sup>

<sup>1,2,3</sup>Universidad Tecnológica del Perú, Perú, [frisanchogabriel81@gmail.com](mailto:frisanchogabriel81@gmail.com), [arturyq65@gmail.com](mailto:arturyq65@gmail.com), [c16238@utp.edu.pe](mailto:c16238@utp.edu.pe)

**Abstract-** *The objective of this systematic review was to analyze whether the implementation of the Ore Sorting system with sensors and artificial intelligence, compared to conventional sorting methods, improves operational profitability in mining operations with polymetallic deposits. To this end, the PRISMA methodology and the PICO approach were applied, formulating specific questions and establishing inclusion and exclusion criteria. Fifty-six scientific articles published between 2014 and 2024 were selected from academic databases such as Scopus and SciELO. The results were organized into five thematic areas: sensors used, classification techniques applied, comparison with conventional methods, financial indicators, and operational applications. XRT, NIR, and HSI sensors were identified as the most widely used, with classification efficiencies exceeding 85% in appropriate contexts. The most frequent techniques were Particle Sorting, Bulk Sorting, and On-belt Sorting, each with specific operational advantages. Compared to traditional methods such as flotation or gravimetric separation, Ore Sorting showed greater energy efficiency and classification accuracy. In addition, the studies reviewed reported positive financial indicators, with NPVs exceeding USD 1.8 million and IRRs between 38% and 52%. It is concluded that Ore Sorting represents a viable technological alternative for improving operational efficiency, reducing OPEX, and increasing metal recovery in polymetallic mining. Its implementation also contributes to environmental sustainability by reducing liabilities and utilizing waste rock, establishing itself as a key tool for smart mining.*

**Keywords:** *Ore Sorting, smart mining, mineral classification, advanced sensors, financial indicators*

# Impacto del Ore Sorting en la rentabilidad operativa de yacimientos polimetálicos: Una Revisión Sistemática

Angel Gabriel, Frisancho Choquecota<sup>1</sup>; Abel Arturo, Yancapallo Quispe<sup>2</sup>; Gerby Giovanna, Rondan-Sanabria<sup>3</sup>  
<sup>1,2,3</sup>Universidad Tecnológica del Perú, Perú, [frisanchoangel81@gmail.com](mailto:frisanchoangel81@gmail.com), [arturyq65@gmail.com](mailto:arturyq65@gmail.com), [c16238@utp.edu.pe](mailto:c16238@utp.edu.pe)

**Resumen-** La presente revisión sistemática tuvo como objetivo analizar si el uso del sistema Ore Sorting, que integra sensores y algoritmos inteligentes, representa una mejora significativa en la rentabilidad operativa, frente a la clasificación convencional en yacimientos polimetálicos. Para ello, se aplicó el enfoque PICO y la metodología PRISMA, formulando preguntas específicas y estableciendo criterios de inclusión y exclusión. Se seleccionaron 54 artículos científicos publicados entre 2014 y 2024, extraídos de bases de datos académicas como Scopus y SciELO. Los resultados se organizaron en cinco ejes temáticos: sensores utilizados, técnicas de clasificación aplicadas, comparación con métodos convencionales, indicadores financieros y aplicaciones operativas. Se identificó que los sensores XRT, NIR y HSI son los más utilizados, con eficiencias clasificatorias superiores al 85% en contextos adecuados. Las técnicas más frecuentes fueron Particle Sorting, Bulk Sorting y On-belt Sorting, cada una con ventajas operativas específicas. En comparación con métodos tradicionales como flotación o separación gravimétrica, el Ore Sorting mostró mayor eficiencia energética y precisión clasificatoria. Además, los estudios revisados reportaron indicadores financieros positivos, con VAN superiores a USD 1.8 millones y TIR entre 38% y 52%. Se concluye que el Ore Sorting representa una alternativa tecnológica viable para mejorar la eficiencia operativa, reducir el OPEX y aumentar la recuperación metálica en minería polimetálica. Asimismo, su aplicación contribuye a la sostenibilidad ambiental mediante la reducción de pasivos y el aprovechamiento de desmontes, consolidándose como una herramienta clave para la minería inteligente.

**Palabras clave:** Ore Sorting, minería inteligente, clasificación de minerales, sensores avanzados, indicadores financieros.

## I. INTRODUCCIÓN

La industria minera peruana se encuentra en una etapa crítica marcada por el agotamiento de yacimientos de alta ley, la disminución progresiva de las leyes de cabeza y el incremento sostenido de los costos unitarios de procesamiento [1], [2], [3]. En este contexto, las operaciones convencionales de tratamiento mineral basadas en chancado, molienda y concentración, sin una clasificación previa automatizada presentan limitaciones técnicas que afectan directamente la eficiencia operativa y la rentabilidad económica [3], [4]. Esta situación se agrava en yacimientos polimetálicos, donde la heterogeneidad mineralógica y la baja resolución en la caracterización geológica derivan en una clasificación deficiente, con alta probabilidad de incluir material estéril en el flujo de procesamiento [5].

Aunque se han desarrollado tecnologías de clasificación automatizada como el Ore Sorting, su implementación aún no es generalizada en el Perú. Diversos estudios han demostrado que el uso de sensores como XRT, NIR y HSI, integrados con

algoritmos de inteligencia artificial, puede mejorar la ley de alimentación a planta entre un 10% y 20%, reducir el OPEX y aumentar la recuperación metálica [6]. Por ejemplo, en operaciones como San Rafael, la implementación de clasificadores XRT permitió elevar la ley de estaño de 0.6% a 2.8%, mantener una recuperación del 90% y recuperar la inversión en menos de 4 meses [7]. Asimismo, en otra mina del Perú, se reportó que entre 15 y 20 camiones diarios con leyes de cobre entre 0.3% y 1.5% fueron erróneamente clasificados como desmonte, representando una pérdida anual estimada de USD 17 millones en valor metálico recuperable [8]. Sin embargo, existe una falta de sistematización sobre el impacto técnico-financiero de estas tecnologías en operaciones reales, lo que dificulta su adopción estratégica en la industria minera.

La presente revisión sistemática se justifica por la necesidad de consolidar evidencia técnica, operativa y económica sobre el sistema Ore Sorting, especialmente en contextos de baja ley y alta dilución. Dicho esto, debido al creciente número de publicaciones sobre sensores y algoritmos aplicados en etapas tempranas de la clasificación mineral, no se dispone de forma clara, revisiones que integren sus resultados desde una perspectiva financiera y de sostenibilidad operativa [9], [10]. Es por lo que, esta investigación busca llenar ese vacío, mediante una visión panorámica y rigurosa, de forma que oriente a futuras decisiones tecnológicas y de esta manera, optar por un mejor sistema de clasificación en minería polimetálica.

Por lo tanto, esta investigación tiene como objetivo, desarrollar una revisión sistemática para determinar si el uso del sistema Ore Sorting, que integra sensores y algoritmos inteligentes, representa una mejora significativa en la rentabilidad operativa, frente a la clasificación convencional en yacimientos polimetálicos.

## II. METODOLOGÍA

### A. Metodología PICO

Para el desarrollo de la presente Revisión Sistemática de Literatura (RSL), se aplicó el enfoque PICO, ya que, permite estructurar preguntas de investigación, de forma que orienten la búsqueda bibliográfica y delimiten el campo de estudio. En este sentido, la pregunta principal (RQ) es: ¿La implementación del sistema Ore Sorting que integra sensores e inteligencia artificial, representa una mejora significativa en comparación con la etapa convencional de clasificación de minerales en yacimientos polimetálicos? A partir de esta pregunta, se generan sub preguntas que abordan aspectos, económicos y operativos del sistema Ore Sorting:

**RQ1 (P):** ¿Cuál es el impacto del sistema Ore Sorting sobre la eficiencia operativa y la recuperación metálica en yacimientos polimetálicos?

**RQ2 (I):** ¿Qué sensores y algoritmos se utilizan en la clasificación de minerales autónomos?

**RQ3 (C):** ¿Cómo se compara la implementación del Ore Sorting en la etapa de clasificación frente a la convencional, en términos de costos operativos?

**RQ4 (O):** ¿Qué beneficios financieros (VAN, TIR, OPEX) y sostenibles, se obtienen al implementar Ore Sorting en operaciones mineras?

Posteriormente, se buscó palabras claves que contribuye a acotar el espectro de búsqueda, evitando la inclusión de literatura irrelevante y asegurando un análisis más riguroso y enfocado en el tema central de la investigación; como se muestra en la Tabla I.

TABLA I  
 PALABRAS CLAVES PARA CADA COMPONENTE

| Componente | Factor                                                   | Palabras clave                                                                     |
|------------|----------------------------------------------------------|------------------------------------------------------------------------------------|
| P          | Clasificación deficiente en yacimientos polimetálicos    | "low-grade ores", "mineral dilution", "ore misclassification"                      |
| I          | Implementación de técnicas de clasificación automatizada | "machine learning", "deep learning", "sensor fusion"                               |
| C          | Métodos convencionales sin sensores                      | "manual sorting", "visual classification", "traditional mineral processing"        |
| O          | Mejora en rentabilidad operativa                         | "operational efficiency", "economic impact", "recovery rate", "VAN", "TIR", "OPEX" |

P (Problema), I (Intervención), C (Comparación), O (Resultados)

En consecuencia, se construye la sintaxis de la ecuación de búsqueda, estructurando las palabras clave, mediante el uso de conectores lógicos que facilitan su combinación. De tal forma que, este procedimiento permita optimizar la estrategia de búsqueda y garantizar que los resultados recuperados sean más precisos y pertinentes al objetivo del estudio.

Posteriormente, se procede a formular la ecuación de búsqueda integrando los términos correspondientes a cada uno de los componentes del método PICO, tal como se presenta a continuación

*Ecuación de búsqueda Scopus*

("low-grade ores" OR "mineral dilution" OR "ore misclassification") AND ("machine learning" OR "deep learning") AND ("operational efficiency" OR "economic impact" OR "recovery rate" OR "VAN" OR "TIR" OR "OPEX").

*Ecuación de búsqueda Scielo*

"menas de baja ley" "clasificación mineral" "aprendizaje automático" "eficiencia" "recuperación" "VAN" "TIR" "sensores".

Para delimitar el campo de investigación y garantizar la relevancia de los estudios seleccionados en RSL, se establecieron los siguientes criterios de inclusión y exclusión:

*Criterios de Inclusión*

**CI1:** Estudios que aborden la implementación del sistema Ore Sorting en minería, especialmente en yacimientos polimetálicos.

**CI2:** Investigaciones que describan el uso de sensores avanzados, así como las técnicas de clasificación automatizada.

**CI3:** Publicaciones que presenten resultados técnicos, operativos o financieros, tales como precisión clasificatoria, recuperación metálica, VAN, TIR y OPEX.

**CI4:** Documentos publicados entre los años 2014 y 2024, en idioma español o inglés, indexados en bases académicas reconocidas como Scopus y SciELO.

*Criterios de Exclusión*

**CE1:** Estudios que se enfoquen en la clasificación de minerales no metálicos o en procesos industriales ajenos al sector minero.

**CE2:** Documentos que no presenten datos empíricos verificables, como ensayos de opinión, artículos sin metodología definida o revisiones narrativas sin respaldo técnico.

**CE3:** Publicaciones duplicadas, incompletas o que no detallen los parámetros técnicos del sistema Ore Sorting.

**CE4:** Estudios en idiomas distintos al español o inglés, o que no estén disponibles en bases de datos académicas reconocidas.

*B. Metodología PRISMA*

El diagrama PRISMA refleja cuántos documentos fueron encontrados en las bases de datos académicas (Scopus, Scielo), cuántos fueron descartados por duplicidad o por no cumplir con la sintaxis de búsqueda, y cuántos fueron excluidos tras aplicar los criterios definidos en las fases de revisión por título, resumen y texto completo. Finalmente, se mostrará el número de estudios que conformarán la muestra definitiva para el análisis técnico-operativo y financiero del sistema Ore Sorting.

A continuación, se describe el proceso de elaboración del diagrama PRISMA (Fig. 1), aplicado en esta Revisión sistemática, orientada al análisis técnico y financiero del sistema Ore Sorting en minería polimetálica.

En la primera etapa, correspondiente al bloque de Identificación, se utilizó dos bases de datos académicos: Scopus y Scielo, seleccionadas por su cobertura en publicaciones científicas de ingeniería minera y procesamiento de minerales. Al aplicar la primera parte de la ecuación de búsqueda, centrada en términos como "low-grade ores", "machine learning", entre otros, se identificaron 420 documentos relacionados con el tema. Posteriormente, se incorporó los demás componentes faltantes, permitiendo excluir 177 documentos, quedando 243 artículos para la siguiente fase. En esta etapa, no se detectaron duplicados ni exclusiones externas a la base de datos, por lo que se mantuvo la integridad del conjunto filtrado.

En la segunda fase, correspondiente al bloque de Cribado, se revisaron los títulos y resúmenes de los 243 documentos restantes. Se excluyeron 187 artículos que no cumplieran con los criterios de inclusión definidos previamente.

Finalmente, tras aplicar todos los filtros y criterios, se obtuvo una muestra definitiva de 54 artículos científicos, considerada adecuada para desarrollar la RSL con base en

evidencia técnica, operativa y financiera. Estos estudios analizados en profundidad, respondieron a la pregunta de investigación formulada bajo el modelo PICO y sustentaron las conclusiones del presente trabajo.




Fig. 1 Diagrama Prisma

### III. RESULTADOS Y DISCUSIÓN

La presente Revisión Sistemática de Literatura (RSL), permitió analizar en profundidad un conjunto de 54 artículos científicos seleccionados mediante criterios rigurosos de inclusión y exclusión, centrados en el estudio del sistema Ore Sorting aplicado a la minería polimetálica. Por lo que, en esta revisión, se abarcan una variedad de espacios geográficos y temporales, que reflejan el aumento progresivo del interés académico, operativo y tecnológico del sistema Ore Sorting. Dado que, en su mayor parte, estos estudios provienen de países con fuerte actividad minera, tales como: China, Alemania, Perú, Marruecos, Sudáfrica, Canadá y Australia, por lo que se evidencia y respalda su aplicabilidad en situaciones reales de producción. Además, se observa una cantidad significativa de publicaciones entre los años 2014 y 2024, coincidiendo con el avance tecnológico de sensores de alta resolución y algoritmos de reconocimiento inteligente. De esta forma, la distribución espacio-tiempo, permite identificar tendencias innovadoras, análisis geográficos y evolución metodológica relacionada con el uso de Ore Sorting como herramienta para mejorar la productividad y sostenibilidad de forma eficiente en minería polimetálica. A continuación, en la Fig. 2, se presenta un gráfico que relaciona el país de origen de cada artículo con su año de publicación, como base para el análisis contextual de los resultados.

Dicho lo anterior, los resultados obtenidos se agrupan en cinco ejes temáticos que permiten una interpretación integral del impacto del Ore Sorting: (1) sensores utilizados y su frecuencia de aplicación, (2) técnicas de clasificación implementadas en campo, (3) comparación técnica y económica con los métodos tradicionales de procesamiento mineral, (4) indicadores financieros reportados en estudios de caso reales, y (5) aplicaciones operativas y contribuciones al desarrollo sostenible en minería. En este sentido, esta estructura permite no solo evaluar el rendimiento técnico del sistema, sino también su viabilidad económica y ambiental en contextos reales de operación.



Fig. 2 Espacio – tiempo de la revisión.

#### A Sensores utilizados en Ore Sorting

La implementación del sistema Ore Sorting en minería polimetálica, se basa en el uso de sensores capaces de detectar propiedades físicas, químicas y espectrales de las partículas minerales. Dado que, estos sensores permiten realizar una clasificación automatizada del mineral, antes de su ingreso a procesos convencionales como molienda o flotación, lo que contribuye directamente a mejorar la eficiencia operativa y reducir los costos unitarios de procesamiento.

Entre los sensores más utilizados destacan el XRT (Rayos X por transmisión), NIR (Infrarrojo cercano), HSI (Imagen hiperespectral), XRF (Fluorescencia de rayos X), PGNA (Activación neutrónica gamma), PFTNA (Activación térmica de neutrones), XRL (Luminiscencia de rayos X) y sensores láser. Por supuesto que, cada uno de ellos presenta ventajas específicas según el tipo de mineral, granulometría, condiciones de operación y técnica de clasificación aplicada. En la Fig. 3, se observa la comparación de porcentajes de aplicación de los sensores, basado en el análisis de promedio de estudios reales.

En primer lugar, el sensor XRT fue el más citado en la revisión, con presencia en 23 estudios. Su principio de funcionamiento se basa en la absorción diferencial de rayos X por los elementos presentes en la roca, permitiendo distinguir entre mineral valioso y ganga con alta precisión. Por ejemplo, en operaciones como San Rafael, el uso de XRT permitió elevar la ley de estaño de 0.6% a 2.8% con una recuperación metalúrgica del 90% [7], [11], [13], [14]. Además, estudios

como el de Luo et al. [12] y Robben et al. [11] destacan su aplicabilidad en cobre, tungsteno y oro, con eficiencias clasificatorias superiores al 90%. En segundo lugar, el sensor NIR, citado en 12 estudios, detecta firmas espectrales superficiales en el rango del infrarrojo cercano.




Fig. 3 Porcentage de sensores empleados en Ore Sorting.

Además, es especialmente útil en minerales industriales como fosfatos, boratos y carbonatos, donde la composición química se refleja en patrones espectrales únicos [15], [21], [24]. Asimismo, su eficiencia varía entre 70% y 85%, y se ha reportado su integración con algoritmos de aprendizaje automático; mejorar la tasa de verdaderos positivos [26]. En tercer lugar, la imagen hiperespectral (HSI), presente en 8 estudios, permite analizar cada píxel de una imagen en múltiples bandas espectrales, lo que facilita la identificación precisa de minerales con características visuales similares. De tal forma que, su aplicación ha sido reportada en la clasificación de cuarzo, feldespatos y caolín, con eficiencias entre 75% y 90% [19], [22], [29].

Por otro lado, el sensor XRF se basa en la emisión de rayos X secundarios tras la excitación de los átomos del mineral. Aunque su penetración es superficial, permite identificar elementos como zinc, plomo y cobre con buena precisión. Su uso ha sido reportado en 7 estudios, con eficiencias entre 65% y 80% [13], [18], [20], [28]. Ahora bien, los sensores PGNAA y PFTNA permiten analizar grandes volúmenes de material mediante activación neutrónica, siendo útiles en técnicas de clasificación masiva (Bulk Sorting). Sin embargo, su eficiencia es menor (60–75%), aunque su capacidad de procesamiento supera las 8000 toneladas por hora [14], [31], [50]. Finalmente, los sensores láser y XRL se utilizan en aplicaciones específicas como la clasificación de diamantes, turquesas y minerales fluorescentes. Aunque menos frecuentes, su precisión puede superar el 90% en contextos adecuados [42], [54]. En la Fig. 4, se presenta un análisis comparativo de los sensores encontrados en los diferentes estudios mineros, destacando su cantidad y eficiencia promedio en porcentajes.




Fig. 4 Eficiencia en sensores.

Con un enfoque similar, la Tabla II presenta la clasificación de tecnologías de sensores utilizadas en los estudios científicos revisados, destacando su aplicación principal en procesos de caracterización y análisis de materiales.

TABLA II  
 FRECUENCIA DE USO Y EFICIENCIA DE SENSORES EN ORE SORTING

| Sensor | Aplicación principal                | Referencias                                                                                                                           |
|--------|-------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------|
| XRT    | Densidad, absorción atómica         | [1], [6], [7], [11], [12], [13], [14], [15], [16], [18], [20], [22], [23], [25], [27], [28], [31], [33], [36], [39], [42], [44], [48] |
| NIR    | Firma espectral superficial         | [3], [16], [17], [21], [24], [26], [32], [34], [37], [40], [43], [47]                                                                 |
| HSI    | Imagen espectral por píxel          | [4], [5], [19], [22], [29], [30], [35], [38]                                                                                          |
| XRF    | Composición química superficial     | [9], [13], [18], [20], [28], [41], [49]                                                                                               |
| PGNAA  | Elementos químicos volumétricos     | [10], [14], [31], [49]                                                                                                                |
| PFTNA  | Activación nuclear puntual          | [26], [50]                                                                                                                            |
| XRL    | Minerales fluorescentes             | [40], [49]                                                                                                                            |
| Láser  | Clasificación visual complementaria | [15], [33], [36], [52]                                                                                                                |

Los sensores más utilizados fueron XRT, NIR y HSI, destacando por su eficiencia clasificatoria y adaptabilidad a distintos tipos de mineral. Dicho esto, el sensor XRT lidera por su frecuente aplicación y precisión en la obtención de resultados, seguido por NIR que fue ejecutado en minerales industriales, y el HSI en contextos espectrales complejos. Además, esto sugiere que, la predominancia del sensor XRT en estudios internacionales, refleja su madurez tecnológica y su

alta capacidad para operar en condiciones de mayor heterogeneidad mineralógica. Asimismo, autores como Robben et al. y Luo et al. coinciden en que su eficiencia es superior al 90%, ya que el XRT mantiene su rendimiento incluso con partículas de gran tamaño, lo que refuerza su capacidad de análisis volumétrico frente a sensores de naturaleza superficial como el XRF. De igual forma, su aplicación en la preconcentración temprana permite reducir la dilución y optimizar la recuperación metálica, aspectos especialmente relevantes en yacimientos polimetálicos donde la selectividad resulta crítica [11], [12], lo que evidencia su potencial como herramienta clave para la minería subterránea y de baja ley. Por lo contrario, estudios como el de Jingwei et al. advierten que su aplicación puede verse limitada por la granulometría y la densidad del mineral [43], por lo que sugieren que la selección del sensor debe estar vinculada con las características específicas del yacimiento.

*B. Técnicas de clasificación aplicadas*

En el análisis de técnicas aplicadas en sistemas Ore Sorting, se identificaron cinco enfoques principales, siendo tres los más representativos por su frecuencia y aplicación operativa (Tabla III). En primer lugar, la técnica más reportada fue Particle Sorting, presente en 24 estudios, basada en la clasificación individual de partículas mediante sensores como XRT, NIR o HSI. Más aún, esta técnica destaca por su alta precisión, permitiendo separar material estéril desde etapas tempranas y reducir la carga en molienda y flotación. Ejemplos como la mina San Rafael y el proyecto Tizert evidencian mejoras significativas en recuperación y ley de alimentación.

La segunda técnica más frecuente fue Bulk Sorting, con 17 estudios, orientada a la clasificación de grandes volúmenes de mineral sin segmentación individual. Es útil en operaciones de gran escala, con sensores como PGNAa y XRF, y permite optimizar el transporte y reducir costos operativos, como se demostró en el estudio de Lessard et al. con una reducción anual de más de 10,000 toneladas de ácido en lixiviación.

Finalmente, On-belt Sorting fue identificada en 14 estudios, caracterizada por la clasificación automatizada sobre fajas transportadoras. Utiliza sensores como XRT, HSI o láser, junto con algoritmos de Machine Learning, permitiendo una separación en tiempo real y operación continua sin interrupciones en el flujo de producción.

La Tabla III resume estas técnicas de clasificación de minerales empleadas en operaciones mineras, detallando su capacidad de procesamiento, sensor utilizado y aplicación operativa. Cada una presenta ventajas operativas según el tipo de sensor, capacidad de procesamiento y etapa de aplicación. Según los estudios revisados, la elección de la técnica de clasificación está estrechamente vinculada al contexto operativo. Por ejemplo, Particle Sorting ha demostrado ser eficaz en pre concentración temprana, como evidencian los casos de San Rafael y Tizert [7], [39]. En contraste, Bulk Sorting, aunque menos preciso, permite reducir costos en operaciones de gran escala, [13]. Autores como Lessard et al.

Destacan su impacto en la reducción de reactivos [2], mientras que Drumond et al. Subrayan que la integración de algoritmos adaptativos en On-belt Sorting mejora la precisión clasificatoria en tiempo real, lo que refuerza su viabilidad en plantas existentes [13].

TABLA III  
 TÉCNICAS APLICADAS VS TIPO DE SENSOR Y CAPACIDAD OPERATIVA

| Técnica de clasificación | Sensor más común | Capacidad (t/h) | Aplicación operativa                     | Referencias                                                                             |
|--------------------------|------------------|-----------------|------------------------------------------|-----------------------------------------------------------------------------------------|
| Particle Sorting         | XRT, NIR         | 100–300         | Alta precisión, preconcentración         | [7], [12], [14], [16], [18], [22], [23], [25], [27], [31], [36], [39], [42], [44], [48] |
| Bulk Sorting             | PGNAa, XRF       | >8000           | Clasificación masiva, reducción de CAPEX | [2], [13], [15], [20], [28], [33], [46], [48]                                           |
| On-belt Sorting          | XRT, HSI         | 150–600         | Clasificación en línea, automatización   | [11], [14], [18], [23], [35], [39], [42]                                                |

*C. Comparación con métodos convencionales*

Uno de los aspectos más relevantes en la evaluación del sistema Ore Sorting es su comparación directa con los métodos convencionales de clasificación mineral, como la flotación, la separación gravimétrica, la clasificación hidráulica, la separación magnética y la criba mecánica. Estos métodos han sido históricamente utilizados en la industria minera peruana y global, pero presentan limitaciones técnicas, económicas y ambientales que se agravan en contextos de baja ley y alta heterogeneidad mineralógica. Como es el caso de la flotación, que requiere molienda fina, uso intensivo de reactivos químicos y grandes volúmenes de agua, lo que incrementa el OPEX y genera pasivos ambientales significativos. Aunque su eficiencia puede alcanzar entre 70% y 90%, depende fuertemente de la mineralogía y del control de parámetros operativos [2], [34], [45]. En contraste, el Ore Sorting permite realizar una pre concentración temprana, reduciendo la carga de molienda y flotación, lo que se traduce en menores costos operativos y mayor eficiencia energética [6], [13], [18].

Por otra parte, la separación gravimétrica, basada en diferencias de densidad, es efectiva en minerales como oro, estaño o tungsteno, pero su eficiencia se reduce cuando las diferencias de densidad son mínimas o cuando el mineral presenta granulometría heterogénea. Por lo que, estudios como el de Santos et al. [1] señalan que la eficiencia gravimétrica promedio se sitúa entre 60% y 80%, mientras que el Ore Sorting con sensores XRT puede superar el 90% en condiciones similares [7], [11]. En esa misma línea, la clasificación hidráulica, mediante ciclones o canales, es sensible a la

granulometría y densidad del mineral, y suele presentar eficiencias entre 50% y 70% [34]. En comparación, el Ore Sorting permite una clasificación más precisa basada en propiedades físicas o químicas detectadas por sensores, sin depender exclusivamente de parámetros hidráulicos [12], [14].

En cuanto a, la separación magnética, aunque útil en minerales ferromagnéticos como magnetita o hematita, tiene una aplicación limitada en yacimientos polimetálicos. Su eficiencia oscila entre 60% y 85%, pero no permite distinguir entre minerales valiosos no magnéticos y ganga [22], [42]. En cambio, el Ore Sorting puede integrar sensores como XRF o HSI para detectar composición química o espectral, ampliando su aplicabilidad [9], [19], [28]. Finalmente, la criba mecánica, utilizada para clasificar por tamaño, no distingue entre mineral valioso y estéril, lo que genera dilución y pérdida de valor metálico. En operaciones como Antamina, se reportó que entre 15 y 20 camiones diarios con leyes de cobre entre 0.3% y 1.5% fueron erróneamente clasificados como desmonte, representando una pérdida anual estimada de USD 17 millones [8]. La Fig. 5, compara distintos métodos de clasificación mineral en función de su eficiencia operativa y consumo energético. Esta representación permite identificar tecnologías que ofrecen un equilibrio óptimo entre rendimiento técnico y demanda energética, como el Ore Sorting, que destaca por su alta eficiencia con bajo consumo energético.




Fig. 5 Comparación de métodos.

El Ore Sorting supera en eficiencia energética y precisión a métodos tradicionales como flotación, gravimetría, clasificación hidráulica y separación magnética, especialmente en contextos de baja ley. No obstante, esta comparación del Ore Sorting con los métodos convencionales, no busca reemplazar; sino complementarlos estratégicamente en etapas tempranas de pre concentración. Dado que, estudios como los de Santos et al. y Drumond et al. coinciden en que su aplicación permite reducir la carga dirigida a molienda y reactivos, optimizando el circuito de procesamiento [1], [13]. Por otro lado, casos como el de Deza et al. revelan pérdidas significativas generadas por una clasificación visual errónea, ya que esto valida la necesidad de incorporar sensores inteligentes, para evitar dilución y mejorar la recuperación metálica [8].

#### D. Indicadores financieros

La aplicación del sistema Ore Sorting no solo tiene implicancias técnicas y operativas, sino que también se ve reflejado en indicadores financieros significativos, que pueden ser cuantificados, como es el caso del: Valor Actual Neto (VAN), la Tasas Interna de Retorno (TIR), el OPEX (gasto operativo) y el payback (tiempo de recuperación de inversión. Es decir, estos indicadores permiten evaluar la viabilidad económica de incorporar sensores y algoritmos de clasificación inteligente en operación minera, especialmente en contextos de baja ley o alta dilución. Por ejemplo, uno de los casos más representativos es el de la mina San Rafael, donde la implementación de clasificadores XRT permitió elevar la ley de estaño de 0.6% a 2.8%, mantener una recuperación del 90%, operar por encima del tonelaje de diseño y recuperar la inversión en menos de 4 meses. En consecuencia, el estudio reportó un VAN superior a USD 2.5 millones y una TIR del 45%, consolidando al Ore Sorting como una herramienta rentable en minería subterránea [7].

Otro estudio relevante es el del proyecto Tizert en Marruecos, donde se implementaron sensores NIR y microondas en una configuración de Particle Sorting. De manera que, los resultados mostraron una recuperación metálica del 85.4%, una reducción del OPEX en más del 20% y un VAN de USD 1.8 millones, con una TIR del 38% [39]. Igualmente, en operaciones de lixiviación, como las reportadas por Lessard et al. [2], se evidenció que el uso de Bulk Sorting con sensores PGNAA permitió reducir el consumo de ácido en más de 10,000 toneladas por año, lo que se tradujo en una disminución directa del OPEX y una mejora en la rentabilidad del circuito de procesamiento. Además, estudios como el de Drumond et al. [13] aplicaron curvas ROC para evaluar la precisión clasificatoria y su impacto en los indicadores financieros. De tal forma que, se demostró que una mejora en la tasa de verdaderos positivos reduce el arrastre de material estéril, lo que incrementa la recuperación metálica y mejora el VAN del proyecto.

La Tabla IV presenta indicadores financieros reportados en tres proyectos internacionales, que implementan tecnologías de clasificación mineral basadas en sensores. Destacando valores como VAN, TIR y porcentajes de recuperación, con el fin de evidenciar la viabilidad económica de sistemas como el XRT y el NIR.

| Estudio / Proyecto | VAN (USD) | TIR (%) | Recuperación (%) | Sensor(es) | Referencias |
|--------------------|-----------|---------|------------------|------------|-------------|
| San Rafael (Perú)  | +2.5M     | 45%     | 90%              | XRT        | [7]         |
| Tizert (Marruecos) | +1.8M     | 38%     | 85.40%           | NIR        | [41]        |
| Proyecto China     | +3.2M     | 52%     | 88%              | XRT        | [50]        |

Los estudios revisados reportan VAN positivos superiores a USD 1.8 millones, TIR entre 38% y 52%, y recuperaciones metálicas por encima del 85%, consolidando al Ore Sorting como una inversión rentable. Esto impacta directamente en los resultados financieros, ya que respaldan la viabilidad económica del sistema Ore Sorting. Autores como Drumond et al. y Lessard et al. destacan que la mejora en la tasa de verdaderos positivos tiene un efecto directo en el VAN y el OPEX [13], [2]. Además, el corto periodo de payback en proyectos como San Rafael (menos de 4 meses) demuestra que la inversión en sensores y algoritmos puede ser recuperada rápidamente, incluso en operaciones de mediana escala [7]. No obstante, se requiere un análisis técnico-financiero previo para garantizar que los beneficios superen los costos de implementación.

#### E. Aplicaciones operativas y sostenibilidad

La incorporación del sistema Ore Sorting se ha consolidado como una herramienta flexible, capaz de integrarse en distintas fases del proceso minero, desde la extracción en mina hasta el tratamiento en planta. Su adaptabilidad frente a diversos flujos de mineral, granulometrías y condiciones geológicas lo convierte en una alternativa operativa de gran valor, sobre todo en escenarios donde la eficiencia, la rentabilidad y la sostenibilidad resultan determinantes.

Entre sus aplicaciones más relevantes destaca la preconcentración en mina, mediante técnicas como el On-bucket Sorting, en las que el mineral se clasifica directamente en la pala o cargador antes de ser transportado. Esta práctica contribuye a disminuir la dilución, optimizar el acarreo y evitar el procesamiento de material estéril. Investigaciones como las de Luo et al. [12] y Jingwei et al. [43] señalan que esta técnica puede reducir hasta en un 27% el tonelaje enviado a planta, mejorando la ley de alimentación y disminuyendo los costos operativos (OPEX).

Otra modalidad importante es el On-belt Sorting, que consiste en la clasificación automatizada del mineral sobre fajas transportadoras. Esta técnica permite separar el material en tiempo real mediante sensores como XRT, HSI o láser, apoyados en algoritmos de Machine Learning para incrementar la precisión en la clasificación [11], [14], [18], [23], [31], [39], [42]. Su principal ventaja radica en la operación continua, sin interrupciones en el flujo de producción, lo que facilita su incorporación en plantas ya existentes.

Asimismo, el Stockpile Sorting ha demostrado utilidad en la recuperación de mineral desde desmontes o pilas históricas. Esta técnica permite revalorizar material previamente considerado estéril, generando ingresos adicionales y reduciendo el impacto ambiental asociado a la acumulación de residuos mineros [15], [32], [46]. En operaciones como Priargunsky, se logró recuperar concentrado de uranio desde stockpiles mediante sensores XRF y PGNAA [40].

Desde la perspectiva ambiental, el Ore Sorting contribuye de manera significativa a disminuir el consumo de

agua, energía y reactivos químicos. Al reducir el volumen de material procesado, también se limita la generación de relaves y las emisiones de CO<sub>2</sub>, mejorando el perfil de sostenibilidad de la operación [34], [48]. En términos de sostenibilidad operativa, esta tecnología impulsa la transición hacia una minería inteligente, basada en datos en tiempo real, algoritmos adaptativos y sensores de alta resolución. Este cambio no solo incrementa la eficiencia, sino que también facilita el cumplimiento de estándares ambientales más estrictos y responde a las demandas sociales de una minería responsable [26], [37].

En conjunto, las aplicaciones descritas muestran que el Ore Sorting no es únicamente una solución técnica eficiente, sino también una herramienta estratégica para avanzar hacia una minera sostenible, rentable y alineada con los retos del siglo XXI. Su integración en operaciones reales permite maximizar el aprovechamiento del recurso mineral, reducir el impacto ambiental y mejorar la percepción social de la actividad minera.

La Tabla V resume los beneficios ambientales asociados a las distintas aplicaciones operativas del Ore Sorting, subrayando su aporte a la sostenibilidad del sector.

TABLA V  
BENEFICIOS AMBIENTALES ASOCIADOS AL ORE SORTING

| Aplicación operativa         | Técnica utilizada         | Beneficio ambiental            | Impacto cuantificado                       | Referencias                  |
|------------------------------|---------------------------|--------------------------------|--------------------------------------------|------------------------------|
| Preconcentración en mina     | On-bucket Sorting         | Menor acarreo de estéril       | ↓15-20 camiones mal clasificados           | [12], [37], [43]             |
| Clasificación en planta      | On-belt Sorting           | Menor uso de agua y reactivos  | ↓10-20% consumo de agua y reactivos        | [11], [14], [23], [31], [42] |
| Reprocesamiento de desmontes | Stockpile Sorting         | Reducción de residuos mineros  | ↑Ley: 0.6% a 2.8%                          | [15], [32], [40], [46]       |
| Optimización de lixiviación  | Bulk Sorting + PGNAA      | Menor generación de efluentes  | ↓ >10,000 t/año de ácido                   | [2], [28], [48]              |
| Minería inteligente          | Integración IA + sensores | Reducción de huella de carbono | ↑Eficiencia >90% vs métodos convencionales | [26], [34], [37]             |

(↓) representa reducción; (↑) representa incremento en el indicador.

La versatilidad del sistema permite su integración en distintas etapas del proceso minero. Estudios como los de Luo et al. y Jingwei et al. demuestran que técnicas como On-bucket Sorting pueden reducir hasta un 27% el tonelaje enviado a planta, mejorando la ley de alimentación [12], [43]. Además, el Stockpile Sorting ofrece una alternativa sostenible para recuperar valor desde residuos históricos, alineándose con los principios de economía circular [15], [32], [46]. En este sentido, el Ore Sorting no solo mejora la rentabilidad, sino que también contribuye a la sostenibilidad ambiental del sector minero.

## IV. CONCLUSIONES

La presente Revisión Sistemática de Literatura (RSL) permitió analizar el impacto técnico, económico y operativo del sistema Ore Sorting en yacimientos polimetálicos, contrastándolo con los métodos convencionales de clasificación mineral. En relación con el objetivo planteado, se identificó que la incorporación de sensores como XRT, NIR y HSI, combinados con algoritmos de aprendizaje automático, incrementa de manera notable la precisión en la clasificación, la recuperación metálica y la eficiencia operativa.

Los hallazgos principales muestran que técnicas como Particle Sorting y On-belt Sorting posibilitan una preconcentración temprana y clasificación en línea, lo que contribuye a reducir el OPEX y a optimizar el flujo de procesamiento. De igual forma, los indicadores financieros reportados en estudios aplicados como: el VAN, la TIR y el tiempo de recuperación de la inversión, evidencian que el Ore Sorting constituye una alternativa rentable y sostenible, especialmente en escenarios caracterizados por baja ley y alta dilución.

Esta RSL aporta a la literatura técnica al sistematizar evidencia empírica sobre la aplicabilidad del Ore Sorting en minería metálica, resaltando su versatilidad operativa y su capacidad para disminuir pasivos ambientales mediante técnicas como el Stockpile Sorting. Sin embargo, se reconoce como limitación la escasa disponibilidad de investigaciones en idioma español y la concentración geográfica de estudios en países con alta inversión tecnológica.

Para el desarrollo de nuevas líneas de investigación, se recomienda profundizar en el análisis de configuraciones híbridas, evaluando su desempeño bajo condiciones geológicas con alta heterogeneidad litológica, presencia de sulfuros complejos y variabilidad granulométrica de los yacimientos polimetálicos, que representan desafíos técnicos relevantes; adicionalmente, resulta necesario desarrollar modelos predictivos multivariantes que articulen parámetros operativos y económicos; de procesamiento y recuperación metalúrgica, con el fin de establecer escenarios de optimización que se consoliden al Ore Sorting como una herramienta estratégica para la transición hacia una minería inteligente y sostenible.

## REFERENCIAS

- [1] E. Santos, I. Brum, y W. Ambrós, "Techniques of pre-concentration by sensor-based sorting and froth flotation concentration applied to sulfide ores—A review", *Minerals* (Basel), vol. 15, núm. 4, p. 350, 2025. <https://doi.org/10.3390/min15040350>
- [2] J. Lessard, J. de Bakker, y L. McHugh, "Development of ore sorting and its impact on mineral processing economics", *Miner. Eng.*, vol. 65, pp. 88–97, 2014. <https://doi.org/10.1016/j.mineng.2014.05.019>
- [3] X. Luo, K. He, Y. Zhang, P. He, y. Zhang, "A review of intelligent ore sorting technology and equipment development", *Int. J. Miner. Metall. Mater.*, vol. 29, núm. 9, pp. 1647–1655, 2022. <https://doi.org/10.1007/s12613-022-2477-5>
- [4] H. Amar, M. Benzaazoua, A. Elghali, Y. Taha, M. El Ghorfi, A. Krause, and R. Hakkou, "Mine waste rock reprocessing using sensor-based sorting (SBS): Novel approach toward circular economy in phosphate mining," *Miner. Eng.*, vol. 204, p. 108415, 2023. <https://doi.org/10.1016/j.mineng.2023.108415>
- [5] D. G. Shatwell, V. Murray, y A. Barton, "Real-time ore sorting using color and texture analysis", *Int. J. Min. Sci. Technol.*, vol. 33, núm. 6, pp. 659–674, 2023. <https://doi.org/10.1016/j.ijmst.2023.03.004>
- [6] C. Robben y H. Wotruba, "Sensor-based ore sorting technology in mining—past, present and future", *Minerals* (Basel), vol. 9, núm. 9, p. 523, 2019. <https://doi.org/10.3390/min9090523>
- [7] C. Robben, P. Condori, A. Pinto, R. Machaca, y A. Takala, "X-ray-transmission based ore sorting at the San Rafael tin mine", *Miner. Eng.*, vol. 145, núm. 105870, p. 105870, 2020. <https://doi.org/10.1016/j.mineng.2019.105870>
- [8] A. Drumond, A. L. Rodrigues, J. F. C. L. Costa, F. G. Niquini, and M. G. Lemos, "Models for analysing the economic impact of ore sorting, using ROC curves," *J. South. Afr. Inst. Min. Metall.*, vol. 124, no. 7, pp. 397–406, Jul. 2024. <https://doi.org/10.13140/RG.2.2.17668.45441>
- [9] G. Li, B. Klein, C. Sun y J. Kou, "Applying Receiver-Operating-Characteristic (ROC) to bulk ore sorting using XRF," *Minerals Engineering*, vol. 146, p. 106117, 2020. <https://doi.org/10.1016/j.mineng.2019.106117>
- [10] J. Lessard, W. Sweetser, K. Bartram, J. Figueroa, and L. McHugh, "Bridging the gap: Understanding the economic impact of ore sorting on a mineral processing circuit," *Miner. Eng.*, vol. 91, pp. 92–99, 2016. <https://doi.org/10.1016/j.mineng.2015.08.019>
- [11] P. J. Coghill y E. Simpembwa, "A bulk sorting trial of copper ore using a magnetic resonance analyser", *Miner. Eng.*, vol. 210, núm. 108664, p. 108664, 2024. <https://doi.org/10.1016/j.mineng.2024.108664>
- [12] M. C. Cetin, B. Klein, y W. Fletcher, "A conceptual strategy for effective bulk ore sorting of copper porphyries: Exploiting the synergy between two sensor technologies", *Miner. Eng.*, vol. 201, núm. 108182, p. 108182, 2023. <https://doi.org/10.1016/j.mineng.2023.108182>
- [13] J. Tessier, C. Duchesne, y G. Bartolacci, "A machine vision approach to on-line estimation of run-of-mine ore composition on conveyor belts", *Miner. Eng.*, vol. 20, núm. 12, pp. 1129–1144, 2007. <https://doi.org/10.1016/j.mineng.2007.04.009>
- [14] B. Lunga, M. Jodie y B. Megan "A Mineral X-ray Linear Attenuation Coefficient Tool (MXLAC) to Assess Mineralogical Differentiation for X-ray Computed Tomography Scanning" *Minerals*, vol. 10, no. 5, p. 441, May 2020. <https://doi.org/10.3390/min10050441>
- [15] E. Gülcen, "A novel approach for sensor based sorting performance determination", *Miner. Eng.*, vol. 146, núm. 106130, p. 106130, 2020. <https://doi.org/10.1016/j.mineng.2019.106130>
- [16] Y. He et al., "A review of machine learning in geochemistry and cosmochemistry: Method improvements and applications", *Appl. Geochem.*, vol. 140, núm. 105273, p. 105273, 2022. <https://doi.org/10.1016/j.apgeochem.2022.105273>
- [17] M. M. Veras et al., "Affinity of dual energy X-ray transmission sensors on minerals bearing heavy rare earth elements", *Miner. Eng.*, vol. 147, núm. 106151, p. 106151, 2020. <https://doi.org/10.1016/j.mineng.2019.106151>
- [18] M. Parian, P. Lamberg, R. Möckel, y J. Rosenkranz, "Analysis of mineral grades for geomaterials: Combined element-to-mineral conversion and quantitative X-ray diffraction", *Miner. Eng.*, vol. 82, pp. 25–35, 2015. <https://doi.org/10.1016/j.mineng.2015.04.023>
- [19] Xinran L. I. U., Weiguang Z., Guangyuan X. I. E., Yaoli P., Long L., y Yijiang L. I., "Application basis and research progress of fractal theory in mineral processing", *Meitan Xuebao*, vol. 48, núm. 9, pp. 3573–3588, 2023. <https://doi.org/10.13225/j.cnki.jccs.2022.1107>
- [20] A. Sun et al., "Application of concave point matching algorithm in segmenting overlapping coal particles in X-ray images", *Miner. Eng.*, vol. 171, núm. 107096, p. 107096, 2021. <https://doi.org/10.1016/j.mineng.2021.107096>
- [21] B. Duan, E. R. Bobicki, y S. V. Hum, "Application of microwave imaging in sensor-based ore sorting", *Miner. Eng.*, vol. 202, núm. 108303, p. 108303, 2023. <https://doi.org/10.1016/j.mineng.2023.108303>
- [22] G. Li, B. Klein, C. Sun, y J. Kou, "Applying Receiver-Operating-Characteristic (ROC) to bulk ore sorting using XRF", *Miner. Eng.*, vol. 146, núm. 106117, p. 106117, 2020. <https://doi.org/10.1016/j.mineng.2019.106117>
- [23] J. Lessard, W. Sweetser, K. Bartram, J. Figueroa, y L. McHugh, "Bridging the gap: Understanding the economic impact of ore sorting on a mineral

- processing circuit”, *Miner. Eng.*, vol. 91, pp. 92–99, 2016. <https://doi.org/10.1016/j.mineng.2015.08.019>
- [24] A. Reple, A. C. Chieragati, W. Valery, y F. Prati, “Bulk ore sorting cut-off estimation methodology: Phu Kham Mine case study”, *Miner. Eng.*, vol. 149, núm. 105498, p. 105498, 2020. <https://doi.org/10.1016/j.mineng.2018.08.006>
- [25] Y. Liu, X. Wang, Z. Zhang, y F. Deng, “Deep learning based data augmentation for large-scale mineral image recognition and classification”, *Miner. Eng.*, vol. 204, núm. 108411, p. 108411, 2023. <https://doi.org/10.1016/j.mineng.2023.108411>
- [26] Y. D. Wang, M. J. Blunt, R. T. Armstrong, y P. Mostaghimi, “Deep learning in pore scale imaging and modeling”, *Earth Sci. Rev.*, vol. 215, núm. 103555, p. 103555, 2021. <https://doi.org/10.1016/j.earscirev.2021.103555>
- [27] G. Li, B. Klein, C. He, Z. Yan, C. Sun, y J. Kou, “Development of a bulk ore sorting model for ore sortability assessment—Part II: Model validation and optimisation”, *Miner. Eng.*, vol. 172, núm. 107143, p. 107143, 2021. <https://doi.org/10.1016/j.mineng.2021.107143>
- [28] J. Lessard, J. de Bakker, y L. McHugh, “Development of ore sorting and its impact on mineral processing economics”, *Miner. Eng.*, vol. 65, pp. 88–97, 2014. <https://doi.org/10.1016/j.mineng.2014.05.019>
- [29] L. Tuşa, M. Kern, M. Khodadadzadeh, R. Blannin, R. Gloaguen, y J. Gutzmer, “Evaluating the performance of hyperspectral short-wave infrared sensors for the pre-sorting of complex ores using machine learning methods”, *Miner. Eng.*, vol. 146, núm. 106150, p. 106150, 2020. <https://doi.org/10.1016/j.mineng.2019.106150>
- [30] Y. Xu, B. Klein, G. Li, y B. Gopaluni, “Evaluation of logistic regression and support vector machine approaches for XRF based particle sorting for a copper ore”, *Miner. Eng.*, vol. 192, núm. 108003, p. 108003, 2023. <https://doi.org/10.1016/j.mineng.2023.108003>
- [31] N. Bozorgzadeh y. Feng, “Evaluation structures for machine learning models in geotechnical engineering”, *Georisk Assess. Manag. Risk Eng. Syst. Geohazards*, vol. 18, núm. 1, pp. 52–59, 2024. <https://doi.org/10.1080/17499518.2024.2313485>
- [32] F. P. Hassani, “Front Matter,” in *\*Mine Wastes: Characterization, Treatment and Environmental Impacts\**, Elsevier, 2020, pp. i–ii. <https://doi.org/10.1016/B978-0-12-817736-5.09991-9>
- [33] M. Kern, J. N. P. Akushika, J. R. A. Godinho, T. Schmiedel, y J. Gutzmer, “Integration of X-ray radiography and automated mineralogy data for the optimization of ore sorting routines”, *Miner. Eng.*, vol. 186, núm. 107739, p. 107739, 2022. <https://doi.org/10.1016/j.mineng.2022.107739>
- [34] A. Cardenas-Vera, M. Hesse, R. Möckel, R. Gerhard Merker, T. Heinig, y Q. Van Phan, “Investigation of Sensor-Based sorting and selective comminution for pre-concentration of an unusual parisite-rich REE ore, South Namxe, Vietnam”, *Miner. Eng.*, vol. 177, núm. 107371, p. 107371, 2022. <https://doi.org/10.1016/j.mineng.2021.107371>
- [35] G. Li, B. Klein, C. Sun, y J. Kou, “Investigation on influential factors of bulk ore sortability based on fractal modelling”, *Miner. Eng.*, vol. 177, núm. 107362, p. 107362, 2022. <https://doi.org/10.1016/j.mineng.2021.107362>
- [36] M. C. Cetin, G. Li, B. Klein, y W. Fletcher, “Key factors determining the bulk ore sorting potential in a caving mine”, *Miner. Eng.*, vol. 201, núm. 108237, p. 108237, 2023. <https://doi.org/10.1016/j.mineng.2023.108237>
- [37] J. A. Martínez Pérez y P. S. Pérez Martin, “ROC curve”, *Semergen*, vol. 49, núm. 1, p. 101821, 2023. <https://doi.org/10.1016/j.semerng.2022.101821>
- [38] G. Li, B. Klein, C. Sun, y J. Kou, “Lab-scale error analysis on X-ray fluorescence sensing for bulk ore sorting”, *Miner. Eng.*, vol. 164, núm. 106812, p. 106812, 2021. <https://doi.org/10.1016/j.mineng.2021.106812>
- [39] N. Alqahtani, F. Alzubaidi, R. T. Armstrong, P. Swietojanski, y P. Mostaghimi, “Machine learning for predicting properties of porous media from 2d X-ray images”, *J. Pet. Sci. Eng.*, vol. 184, núm. 106514, p. 106514, 2020. <https://doi.org/10.1016/j.petrol.2019.106514>
- [40] Y. Zhou, J. Wang, R. Zuo, F. Xiao, W. Shen, and S. Wang, “Machine Learning, Deep Learning and Implementation Language in Geological Field,” *Journal of Artificial Intelligence*, vol. 4, no. 1, pp. 1–10, 2021. <https://doi.org/10.32629/jai.v4i1.479>
- [41] H. Amar et al., “Mine waste rock reprocessing using sensor-based sorting (SBS): Novel approach toward circular economy in phosphate mining”, *Miner. Eng.*, vol. 204, núm. 108415, p. 108415, 2023. <https://doi.org/10.1016/j.mineng.2023.108415>
- [42] R. Fandrich, Y. Gu, D. Burrows, y K. Moeller, “Modern SEM-based mineral liberation analysis”, *Int. J. Miner. Process.*, vol. 84, núm. 1–4, pp. 310–320, 2007. <https://doi.org/10.1016/j.minpro.2006.07.018>
- [43] J. L. Gonzales and J. Tapia, “Design of support systems in underground mining based on the Q-Barton classification,” *IOP Conf. Ser.: Mater. Sci. Eng.*, vol. 641, no. 1, p. 012028, 2019. <https://doi.org/10.1088/1757-899X/641/1/012028>
- [44] M. Kern, L. Tusa, T. Leifner, K. G. van den Boogaart, y J. Gutzmer, “Optimal sensor selection for sensor-based sorting based on automated mineralogy data”, *J. Clean. Prod.*, vol. 234, pp. 1144–1152, 2019. <https://doi.org/10.1016/j.jclepro.2019.06.259>
- [45] Y. Liu, Z. Zhang, X. Liu, L. Wang, y X. Xia, “Ore image classification based on small deep learning model: Evaluation and optimization of model depth, model structure and data size”, *Miner. Eng.*, vol. 172, núm. 107020, p. 107020, 2021. <https://doi.org/10.1016/j.mineng.2021.107020>
- [46] E. Gülcan y Ö. Y. Gülsoy, “Performance evaluation of optical sorting in mineral processing – A case study with quartz, magnesite, hematite, lignite, copper and gold ores”, *Int. J. Miner. Process.*, vol. 169, pp. 129–141, 2017. <https://doi.org/10.1016/j.minpro.2017.11.007>
- [47] D. G. Shatwell, V. Murray, y A. Barton, “Real-time ore sorting using color and texture analysis”, *Int. J. Min. Sci. Technol.*, vol. 33, núm. 6, pp. 659–674, 2023. <https://doi.org/10.1016/j.ijmst.2023.03.004>
- [48] E. G. Modise, A. M. Zungeru, B. Mtengi, y A. U. Ude, “Sensor-based ore sorting—A review of current use of electromagnetic spectrum in sorting”, *IEEE Access*, vol. 10, pp. 112307–112326, 2022. <https://doi.org/10.1109/ACCESS.2022.3216296>
- [49] J. R. A. Godinho, G. Westaway-Heaven, M. A. Boone, and A. D. Renno, “Spectral Tomography for 3D Element Detection and Mineral Analysis,” *Minerals*, vol. 11, no. 6, p. 598, Jun. 2021. <https://doi.org/10.3390/min11060598>
- [50] J. Qiu et al., “Study on photofluorescent uranium ore sorting based on deep learning”, *Miner. Eng.*, vol. 206, núm. 108523, p. 108523, 2024. <https://doi.org/10.1016/j.mineng.2023.108523>
- [51] E. G. dos Santos, I. A. S. de Brum, and W. M. Ambrós, *Techniques of Pre-Concentration by Sensor-Based Sorting and Froth Flotation Concentration Applied to Sulfide Ores—A Review*. <https://doi.org/10.3390/min15040350>
- [52] X. Tian, J. Forster, y E. R. Bobicki, “Technological and economic considerations for the application of combined microwave assisted comminution and multi-sensor ore sorting”, *Miner. Eng.*, vol. 208, núm. 108582, p. 108582, 2024. <https://doi.org/10.1016/j.mineng.2024.108582>
- [53] J. R. A. Godinho, K. Chellappah, I. Collins, P. Ng, M. Smith, y P. J. Withers, “Time-lapse imaging of particle invasion and deposition in porous media using in situ X-ray radiography”, *J. Pet. Sci. Eng.*, vol. 177, pp. 384–391, 2019. <https://doi.org/10.1016/j.petrol.2019.02.061>
- [54] A. Ali, Y. W. Chiang, and R. M. Santos, “X-ray Diffraction Techniques for Mineral Characterization: A Review for Engineers of the Fundamentals, Applications, and Research Directions,” *\*Minerals\**, vol. 12, no. 2, p. 205, Feb. 2022. <https://doi.org/10.3390/min12020205>