

UNIVERSIDAD DE EL SALVADOR
FACULTAD DE INGENIERÍA Y ARQUITECTURA



Universidad de El Salvador
Hacia la libertad por la cultura

Tema:

APLICACIÓN DE LA INTELIGENCIA ARTIFICIAL PARA LA CLASIFICACIÓN DE
MINERALES EN ROCAS USANDO LÁMINAS DELGADAS.

Docente director - interino:

Ing. César Augusto González

Presentado por:

Martínez Hernández, Sara Sofía Carnet: MH19068

Osorio Guandique, José Antonio Carnet: OG99016

Quintanilla Barrera, Balmore Ulises Carnet: QB03003

Para optar al título de:

Ingeniero en Sistemas Informáticos

Contenido

Introducción	i
Objetivos	ii
Objetivo General	ii
Objetivos Específicos	ii
Antecedentes	iii
Planteamiento del Problema	1
Alcances	2
Limitaciones	2
Justificación	4
Marco Teórico	5
Inteligencia Artificial	5
Redes Neuronales Convolucionales y el Entrenamiento de un Modelo de Inteligencia Artificial	5
¿Qué son las redes neuronales?	5
Historia y desarrollo de las redes neuronales convolucionales	6
¿En qué consiste entrenar un modelo de red neuronal convolucional?	7
1. Preparación del conjunto de datos	8
2. Propagación hacia adelante (Forward Propagation)	9
3. Cálculo de la función de pérdida	9
4. Retropropagación del error (Backpropagation)	9
5. Actualización de pesos (Optimización)	9
6. Repetición por épocas	10
7. Evaluación final	10
Definición, Clasificación y Composición de las Rocas	11

1. Rocas ígneas	11
2. Rocas sedimentarias	11
3. Rocas metamórficas	12
Composición mineralógica	12
Serie de reacción de Bowen.	12
Preparación de Láminas Delgadas	16
Características de las Láminas Delgadas	17
Marco Legal: Ley de Fomento a la Inteligencia Artificial y Tecnologías Emergentes en El Salvador	18
Factibilidad	20
Técnica:	20
Operativa:	20
Económica:	20
Planificación	21
Cronograma de Actividades y Evaluaciones	21
Metodología	22
Enfoque de la investigación	22
Tipo y diseño de investigación	22
Población y muestra	22
Instrumentos y técnicas de recolección de datos	22
Procedimiento experimental	23
Hipótesis de investigación:	23
Arquitecturas del Modelo	25
Capa de salida y activación softmax	25
Callbacks Implementados	25
Análisis de Convergencia	26
Ciclo de Vida del Proyecto	28
Alcance del Proyecto	28

Cálculo de la Precisión, Recall y F1-Score del Modelo de Clasificación de Minerales.	28
Entregables	30
Riesgos y Posibles Dificultades	31
Planificación de Recursos	32
Discusión	34
1. Rendimiento Global	43
2. Rendimiento por Clase (Clases Destacadas)	43
3. Las Clases Más Débiles	44
Conclusiones Y Recomendaciones	48
Conclusiones	48
Recomendaciones.	49
Referencias Bibliográficas	50
Anexos	55

Tabla de Ilustraciones

Ilustración 1 Arquitectura básica de una Red Neuronal Artificial (RNA) 6

Ilustración 2 Esquema del funcionamiento de una Red Neuronal Convolutiva (RNC) 8

Ilustración 3 Serie de Bowen mostrando la cristalización diferenciada de minerales máficos a félsicos. 13

Ilustración 4 Muestras representativas de minerales y rocas empleadas en petrografía: anfíbol, biotita, moscovita, cuarzo, piroxeno, olivino y variedades de granito y andesita. 15

Ilustración 5 Corte de una muestra de roca utilizando una sierra de diamante para la preparación de láminas delgadas. 16

Ilustración 6 Equipo de corte con sierra de diamante utilizado para la preparación de láminas delgadas. 17

Introducción

La identificación y caracterización mineralógica en rocas constituye un pilar fundamental en la investigación geológica, ya que proporciona información esencial sobre su origen, evolución y el contexto tectónico en el que se formaron (Winter, 2010; Klein & Dutrow, 2007). El estudio de las asociaciones minerales, su morfología y propiedades ópticas permite reconstruir procesos como la cristalización magmática, la diagénesis sedimentaria o el metamorfismo regional, así como determinar el potencial económico de un yacimiento (Deer et al., 2013).

En petrografía, el análisis de láminas delgadas mediante microscopía óptica ha sido el método tradicional para la identificación mineralógica. Este procedimiento requiere la observación de propiedades como birrefringencia, relieve, color de interferencia, ángulo de extinción y hábito cristalino, lo que demanda un alto grado de especialización por parte del petrografista (Nesse, 2017). Aunque validado ampliamente, este enfoque presenta limitaciones inherentes: subjetividad en la interpretación, variabilidad interobservador y elevado tiempo de análisis (Yasuda et al., 2020).

En este contexto, el presente trabajo propone desarrollar un modelo de inteligencia artificial (IA) basado en redes neuronales convolucionales (CNN), que automatice parcial o totalmente la clasificación mineralógica a partir de microfotografías de láminas delgadas. Este enfoque aporta ventajas como mayor precisión y consistencia al reducir sesgos humanos, eficiencia en el procesamiento de grandes volúmenes de datos, capacidad de aprendizaje continuo e identificación de patrones complejos no perceptibles al ojo humano (Goodfellow et al., 2016; Khaleque et al., 2022).

Objetivos

Objetivo General

Desarrollar un modelo basado en técnicas de inteligencia artificial, específicamente redes neuronales convolucionales, para la clasificación automática de minerales presentes en láminas delgadas de los 10 minerales más comunes encontrados en El Salvador.

Objetivos Específicos

- Compilar un conjunto representativo de imágenes digitales de láminas delgadas de minerales ígneos.
- Diseñar y construir una arquitectura de red neuronal convolucional adecuada para la clasificación automática de dichos minerales.
- Entrenar el modelo con el conjunto de datos preparado, aplicando técnicas de optimización que mejoren su rendimiento.
- Evaluar los resultados del modelo en términos de precisión, recall, F1-score y matriz de confusión, comparándolos con la clasificación tradicional petrográfica.

Antecedentes

La aplicación de inteligencia artificial (IA) en la clasificación automática de imágenes ha demostrado avances significativos en medicina, agricultura y teledetección geológica. En medicina, las redes neuronales convolucionales (CNN) han optimizado el análisis de imágenes radiográficas y tomográficas, incrementando la precisión diagnóstica (Esteve et al., 2017). En agricultura, estas técnicas han facilitado la detección temprana de plagas y deficiencias nutricionales, mejorando la eficiencia en el uso de recursos (Kamilaris & Prenafeta-Boldú, 2018).

En mineralogía, el uso de IA y CNN aún se encuentra en una etapa incipiente. Estudios recientes demuestran su potencial para reconocer especies minerales a partir de microfotografías, logrando niveles de precisión competitivos frente a la clasificación manual (Khaleque et al., 2022; Hwang et al., 2021). Sin embargo, la mayoría de los trabajos han utilizado conjuntos de datos limitados, por lo que es necesario ampliar la investigación hacia entornos petrográficos reales.

La integración de CNN en la metodología petrográfica tradicional ofrece ventajas como la automatización del proceso, la consistencia en los resultados, la detección de patrones complejos y la escalabilidad para grandes volúmenes de datos.

Planteamiento del Problema

La identificación mineralógica en láminas delgadas es fundamental en petrografía, pero presenta limitaciones que afectan la precisión y eficiencia del análisis. La técnica depende en gran medida de la experiencia del observador, lo que introduce variabilidad interobservador y posibles errores en minerales con propiedades ópticas similares (Mackenzie & Guilford, 1980).

Además, el proceso es laborioso y consume tiempo, limitando su aplicabilidad en proyectos que requieren resultados rápidos. Factores técnicos como la calidad de la preparación de las láminas y las condiciones de observación microscópica también influyen en la precisión de la identificación (Friedman, 1965).

La falta de recursos especializados en algunos laboratorios y la creciente demanda de análisis petrográficos precisos plantean la necesidad de innovar en la clasificación mineralógica. En este contexto, la aplicación de IA basada en CNN constituye una alternativa viable para complementar y optimizar los métodos tradicionales.

Alcances

- El modelo se diseñará para clasificar un conjunto específico de minerales presentes en láminas delgadas de rocas ígneas, incluyendo: anfíbol, biotita, moscovita, cuarzo, granito biotítico, biotita de grano grueso, piroxeno, olivino, ortopiroxeno–augita–andesita y cuarzo porfirita.
- El trabajo se centrará en la implementación de redes neuronales convolucionales como herramienta principal para la clasificación de imágenes mineralógicas.
- El alcance del proyecto estará limitado por la disponibilidad y calidad del conjunto de datos de imágenes de láminas delgadas. La diversidad y representatividad de los minerales en el conjunto de datos influirán en la capacidad del modelo para generalizar.
- Se espera que los resultados del trabajo contribuyan al campo de la mineralogía óptica y a la caracterización petrográfica de rocas ígneas.
- El modelo desarrollado realizará la clasificación de minerales presentes en una lámina delgada aun cuando exista más de un mineral en el campo de visión. La predicción se limitará exclusivamente a los minerales incluidos en el conjunto de datos utilizado durante el entrenamiento, garantizando que las decisiones del modelo se basen en patrones previamente aprendidos. En los casos en que se detecten simultáneamente dos o más minerales pertenecientes a dicho conjunto, el sistema asignará la clasificación final al mineral cuya presencia sea predominante dentro de la imagen analizada.

Limitaciones

- Dependencia de la calidad y cantidad de datos disponibles para el entrenamiento del modelo.
- Posibles sesgos en los datos que pueden afectar la precisión del modelo.
- Limitaciones en la generalización del modelo a diferentes tipos de rocas y minerales no incluidos en el conjunto de datos.

- Complejidad de las propiedades ópticas: algunos minerales pueden presentar características muy similares en color, birrefringencia y textura, lo que dificulta su clasificación precisa.
- Dependencia del entrenamiento y de la representatividad de las muestras incluidas en el conjunto de datos, restringido únicamente a rocas ígneas.

Justificación

La identificación mineralógica en rocas ígneas es esencial para comprender su génesis, evolución y contexto tectónico, así como para aplicaciones en exploración minera, geotecnia y evaluación de recursos naturales (Winter, 2010; Klein & Dutrow, 2007). El análisis tradicional, basado en microscopía petrográfica de láminas delgadas bajo luz polarizada, continúa siendo el método de referencia (Nesse, 2017). No obstante, presenta limitaciones: subjetividad del observador (Mackenzie & Guilford, 1980), alta especialización requerida y consumo considerable de tiempo.

En este contexto, la inteligencia artificial (IA), y particularmente las redes neuronales convolucionales (CNN), ofrecen una alternativa complementaria. Estos modelos permiten automatizar la clasificación, incrementar la precisión mediante detección de patrones sutiles y optimizar el tiempo de análisis en proyectos con grandes volúmenes de muestras (Goodfellow et al., 2016; Khaleque et al., 2022).

El presente proyecto no busca sustituir el análisis petrográfico convencional, sino fortalecerlo como herramienta de apoyo para garantizar resultados más rápidos, reproducibles y consistentes, alineados con la modernización de las ciencias de la Tierra.

Marco Teórico

Inteligencia Artificial

La inteligencia artificial (IA) se define como la disciplina orientada al desarrollo de sistemas capaces de simular procesos cognitivos humanos como el aprendizaje, la percepción y la toma de decisiones (Russell & Norvig, 2021). Su origen se remonta a Alan Turing (1936), quien introdujo el concepto de la 'máquina universal'. Posteriormente, McCarthy acuñó el término 'IA' en 1956, marcando el inicio formal del área (McCarthy et al., 2006).

El desarrollo de la IA ha pasado por diversas etapas: desde los sistemas basados en reglas, pasando por el renacer de las redes neuronales con la retropropagación (Rumelhart et al., 1986), hasta la actual era del aprendizaje profundo impulsada por big data y alto poder computacional (Goodfellow et al., 2016). Hoy en día, aplicaciones como ChatGPT ejemplifican la relevancia de la IA generativa (OpenAI, 2023).

En geología, la IA ha permitido avances en identificación automática de minerales, mapeo litológico mediante imágenes hiperespectrales, prospección minera y optimización de plantas de procesamiento (Jahoda et al., 2020; Shirmard et al., 2021). Estas aplicaciones demuestran la capacidad de la IA para superar las limitaciones de técnicas tradicionales, aportando rapidez, escalabilidad y precisión.

Redes Neuronales Convolucionales y el Entrenamiento de un Modelo de Inteligencia Artificial

¿Qué son las redes neuronales?

Las redes neuronales artificiales (RNA) son modelos computacionales inspirados en el funcionamiento del cerebro humano. Estas redes están formadas por capas de nodos (neuronas artificiales) que procesan información en conjunto para aprender patrones y relaciones dentro de los datos (McCulloch & Pitts, 1943).

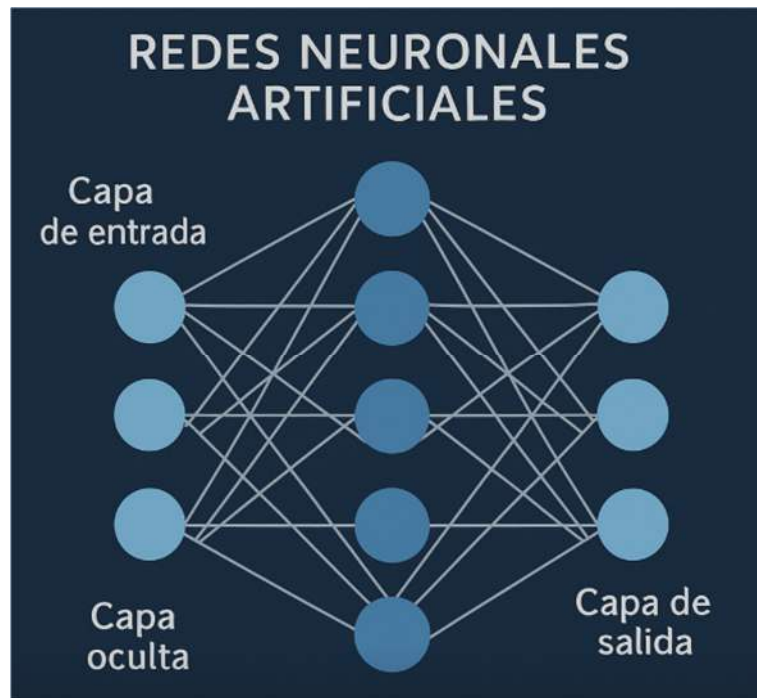


Ilustración 1 Arquitectura básica de una Red Neuronal Artificial (RNA)

Dentro de esta categoría, se encuentran las redes neuronales convolucionales (RNC), que están especialmente diseñadas para procesar datos estructurados espacialmente, como imágenes. Estas redes pueden detectar automáticamente bordes, formas, texturas y patrones, lo que las hace ideales para tareas de reconocimiento visual (O'Shea & Nash, 2015; Gu et al., 2015).

Un modelo de inteligencia artificial es, en términos simples, una representación matemática que aprende a realizar una tarea específica (por ejemplo, clasificar minerales) a partir de ejemplos. Este modelo se entrena ajustando sus parámetros internos (pesos y sesgos) hasta que es capaz de generalizar y tomar decisiones precisas sobre nuevos datos (LeCun et al., 1998).

Historia y desarrollo de las redes neuronales convolucionales

El origen de las redes neuronales se remonta a 1943, cuando McCulloch y Pitts propusieron un modelo matemático de neurona artificial, sentando las bases para simular redes de procesamiento de información (McCulloch & Pitts, 1943).

Décadas más tarde, los neurocientíficos Hubel y Wiesel descubrieron que ciertas neuronas en el cerebro de gatos respondían selectivamente a formas y movimientos específicos. Estos hallazgos, realizados en los años 60, inspiraron la idea de estructuras en capas capaces de identificar características visuales simples y complejas (Hubel & Wiesel, 1968).

En 1980, Kunihiko Fukushima propuso el Neocognitron, un modelo que imitaba esta arquitectura jerárquica. Fue la primera red que incorporó mecanismos similares a los de las CNN actuales, aunque aún no usaba aprendizaje supervisado (Fukushima, 1980).

El gran avance llegó en 1989, cuando Yann LeCun aplicó el algoritmo de retropropagación (backpropagation) para entrenar redes convolucionales de manera eficiente. Su arquitectura LeNet fue utilizada para reconocer dígitos escritos a mano, como los de los códigos postales (LeCun et al., 1989).

Durante los años 90 y principios de los 2000, las RNC estuvieron limitadas por la potencia computacional y la escasez de grandes volúmenes de datos. Sin embargo, en 2012, el modelo AlexNet, desarrollado por Krizhevsky, Sutskever y Hinton, ganó la competencia ImageNet con un margen sorprendente. Este modelo demostró que, con suficiente capacidad de cómputo y datos etiquetados, las RNC podían superar ampliamente a otros métodos en visión por computadora (Krizhevsky et al., 2012).

Desde entonces, las RNC han evolucionado rápidamente, dando lugar a arquitecturas más profundas y eficientes como VGGNet, GoogLeNet, ResNet y DenseNet, que han llevado a la inteligencia artificial a niveles sin precedentes de precisión (Alom et al., 2018; Liu et al., 2021).

¿En qué consiste entrenar un modelo de red neuronal convolucional?

El proceso de entrenar un modelo de inteligencia artificial, específicamente una red neuronal convolucional (RNC), es un procedimiento iterativo cuyo objetivo es que el modelo aprenda a identificar patrones en los datos de entrada (por ejemplo, imágenes microscópicas de láminas delgadas de rocas) y asocie esos patrones con salidas específicas (por ejemplo, el tipo de mineral).

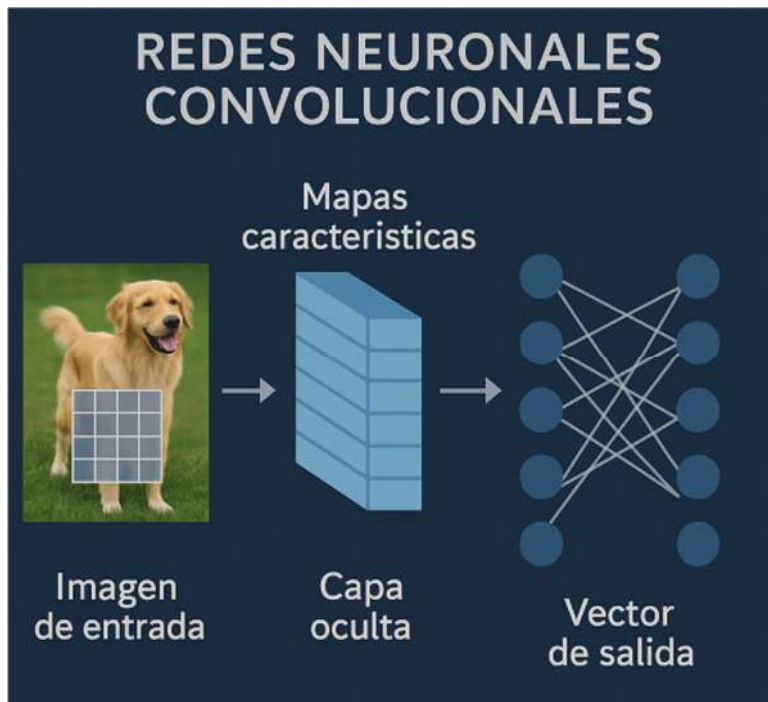


Ilustración 2 Esquema del funcionamiento de una Red Neuronal Convolutiva (RNC)

Este entrenamiento consta de varias fases fundamentales:

1. Preparación del conjunto de datos

Primero, se recopilan y preparan los datos. En el caso de clasificación de minerales, esto implica capturar imágenes digitales de secciones delgadas de roca y etiquetarlas manualmente con el nombre del mineral que contienen, mediante el apoyo de expertos o análisis de referencia (Jahoda et al., 2020).

Estas imágenes suelen dividirse en tres subconjuntos:

Conjunto de entrenamiento (training set): se utiliza para ajustar los parámetros del modelo.

Conjunto de validación (validation set): sirve para evaluar el modelo durante el entrenamiento y evitar sobreajuste.

Conjunto de prueba (test set): se reserva para medir el rendimiento final, usando datos nunca antes vistos por el modelo (Goodfellow et al., 2016).

2. Propagación hacia adelante (Forward Propagation)

En cada iteración, una imagen es introducida al modelo. Esta atraviesa diversas capas convolucionales, que aplican filtros (kernels) para detectar características locales como bordes, texturas y formas. Luego, se aplican capas de activación (ReLU) y capas de reducción de dimensionalidad (pooling).

Al final, las capas densamente conectadas transforman estas características en una probabilidad para cada clase de mineral (LeCun et al., 1998).

3. Cálculo de la función de pérdida

La salida del modelo (una predicción) se compara con la etiqueta real mediante una función de pérdida, como cross-entropy loss para tareas de clasificación. Esta función cuantifica qué tan lejos está el modelo de la respuesta correcta (Goodfellow et al., 2016).

4. Retropropagación del error (Backpropagation)

Con el error calculado, se ejecuta el algoritmo de retropropagación, que calcula el gradiente de la función de pérdida con respecto a cada peso de la red. Utilizando la regla de la cadena, este algoritmo recorre las capas en sentido inverso, determinando cómo ajustar los pesos para reducir el error (Rumelhart et al., 1986).

5. Actualización de pesos (Optimización)

Los gradientes calculados se utilizan para actualizar los pesos del modelo usando un algoritmo de optimización, como:

Stochastic Gradient Descent (SGD)

Adam (Adaptive Moment Estimation)

Estos algoritmos actualizan los parámetros con el objetivo de minimizar la función de pérdida, conduciendo al modelo a mejorar su capacidad de generalización con cada iteración (Kingma & Ba, 2015).

6. Repetición por épocas

Este ciclo completo (entrada, predicción, error, corrección) se repite miles de veces a lo largo de varias épocas, que representan pasadas completas por el conjunto de

entrenamiento. A medida que avanza el entrenamiento, el modelo mejora su precisión, reduce el error y aprende a reconocer patrones minerales complejos, incluso en condiciones visuales variables.

Durante este proceso, se pueden aplicar técnicas como:

Regularización (L2, dropout): para evitar el sobreajuste.

Data augmentation: para aumentar artificialmente la variedad de datos (rotaciones, escalados, contrastes).

Early stopping: para detener el entrenamiento si la pérdida en la validación deja de mejorar (Gu et al., 2015).

7. Evaluación final

Finalmente, el modelo se prueba con el conjunto de prueba independiente, y se calculan métricas como:

Precisión (accuracy)

Recall y F1-score

Matriz de confusión

Estas métricas permiten verificar si el modelo es capaz de clasificar correctamente minerales que nunca antes ha visto (Jahoda et al., 2020).

Dado que el presente trabajo se enfoca en la aplicación de técnicas de inteligencia artificial para la clasificación de minerales en rocas utilizando láminas delgadas, resulta indispensable establecer una base conceptual sólida desde la geología, disciplina que proporciona el contexto físico, químico y mineralógico de los objetos de estudio. Comprender la naturaleza, composición y clasificación de las rocas, así como los procesos geológicos que las originan, es fundamental para interpretar adecuadamente las imágenes microscópicas que serán analizadas por los modelos de IA. En consecuencia, a continuación, se desarrolla el componente geológico necesario para sustentar la aplicación tecnológica propuesta.

Definición, Clasificación y Composición de las Rocas

Las rocas son agregados sólidos de uno o más minerales, fragmentos de otros materiales sólidos o restos orgánicos, que forman parte de la corteza terrestre. Su estudio es esencial para entender los procesos geológicos del planeta y para aplicaciones específicas como la clasificación mineralógica, tanto en campo como en laboratorio. En geología, las rocas no solo representan unidades estructurales del terreno, sino también registros de la historia térmica, tectónica y química de un área (Press & Siever, 2001).

Desde un enfoque genético, las rocas se clasifican en tres grandes grupos según su origen y los procesos que las forman:

1. Rocas ígneas

Las rocas ígneas se forman por la solidificación del magma, ya sea en profundidad (rocas plutónicas como el granito) o en la superficie terrestre tras una erupción volcánica (rocas volcánicas como el basalto y la andesita). Son comúnmente ricas en silicatos como feldespato, piroxeno, anfíboles y cuarzo. En El Salvador, debido a su ubicación sobre el Arco Volcánico Centroamericano, estas rocas constituyen gran parte del basamento geológico reciente (Lexa et al., 2011).

2. Rocas sedimentarias

Las rocas sedimentarias se originan a partir de la compactación y cementación de sedimentos minerales o biológicos, como arena, arcilla, limo y restos orgánicos. Son comunes en ambientes marinos, lacustres o fluviales, y pueden ser clásticas (como areniscas o lutitas), químicas (como yesos) o biogénicas (como calizas). Estas rocas contienen registros fósiles y estructuras sedimentarias útiles para reconstrucciones paleoambientales (Boggs, 2012).

3. Rocas metamórficas

Las rocas metamórficas provienen de la transformación de rocas ígneas o sedimentarias preexistentes sometidas a altas presiones y temperaturas en el interior de la corteza terrestre, sin llegar a fundirse. El resultado son texturas y minerales nuevos, como micas, granates o sillimanita, típicos de ambientes de metamorfismo regional o de contacto.

Aunque escasas en El Salvador, se han reportado afloramientos con evidencias de procesos metamórficos de bajo grado en zonas intrusivas (Geología de El Salvador, 2025).

Composición mineralógica

Cada tipo de roca presenta una composición mineralógica distintiva que puede observarse y clasificarse mediante técnicas petrográficas, como el uso de láminas delgadas bajo microscopía de polarización cruzada. Estas láminas permiten observar texturas, estructuras y minerales característicos que son fundamentales para la clasificación.

Por ejemplo:

Basalto: plagioclasa, piroxeno, olivino.

Granito: cuarzo, feldespato potásico, mica.

Caliza: calcita, a veces dolomita.

Esquisto: micas orientadas, cuarzo, feldespatos.

Serie de reacción de Bowen.

La serie de reacción de Bowen es un concepto fundamental en la petrología que describe cómo los minerales cristalizan a partir de un magma en función de la temperatura y la composición química del magma. Esta serie fue desarrollada por el geólogo estadounidense N.L. Bowen en la década de 1920 y se utiliza para entender la formación de rocas ígneas y la evolución de los magmas. (Bowen 1928)

Conceptos Clave de la Serie de Reacción de Bowen

Cristalización Fraccionada:

La serie de Bowen se basa en el principio de cristalización fraccionada, que es el proceso mediante el cual diferentes minerales cristalizan a diferentes temperaturas a medida que el magma se enfría. A medida que los minerales se forman y se separan del magma, la composición del magma cambia.

Dos Ramas de la Serie:

La serie de Bowen se divide en dos ramas: la rama de la serie continua y la rama de la serie discontinua.

Rama Continua: Esta rama describe la cristalización de los feldespatos. A medida que la temperatura disminuye, el feldespato sódico (albita) se convierte en feldespato potásico (ortoclasa) a través de una serie de mezclas intermedias. Este proceso es continuo y se produce en un rango de temperaturas.

Rama Discontinua: Esta rama describe la cristalización de los minerales ferromagnesianos (como olivina, piroxeno, anfíbol y biotita). A medida que la temperatura disminuye, estos minerales cristalizan en un orden específico y se transforman en otros minerales a medida que se enfrían. Por ejemplo, la olivina cristaliza primero, seguida por el piroxeno, luego el anfíbol y finalmente la biotita.

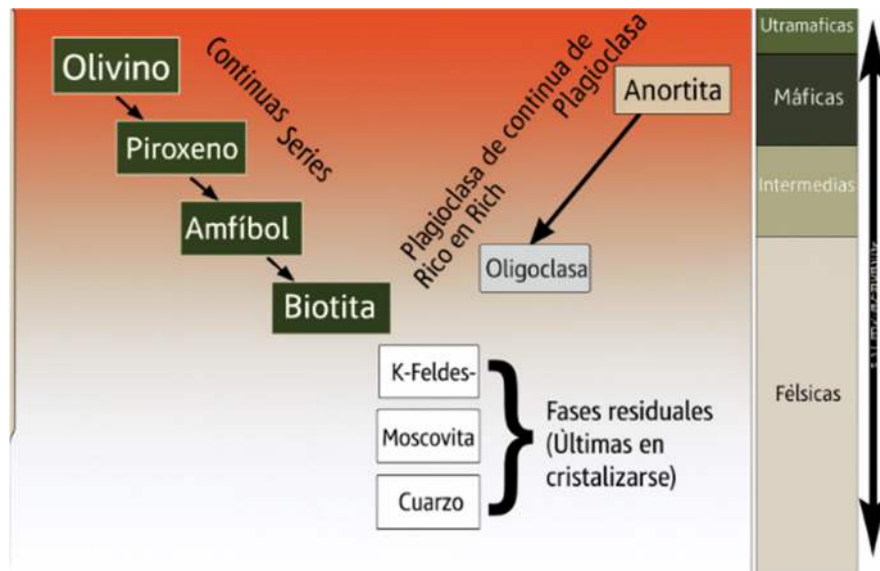


Ilustración 3 Serie de Bowen mostrando la cristalización diferenciada de minerales máficos a félsicos.

Orden de Cristalización:

La serie de Bowen establece un orden específico en el que los minerales cristalizan a partir del magma:

Olivina: Se cristaliza a temperaturas más altas (aproximadamente 1200 °C).

Piroxeno: Se cristaliza a temperaturas intermedias (aproximadamente 1000-1200 °C).

Anfíbol: Se cristaliza a temperaturas más bajas (aproximadamente 800-1000 °C).

Biotita: Se cristaliza a temperaturas aún más bajas (aproximadamente 600-800 °C).

Feldespato: Se cristaliza a temperaturas más bajas (aproximadamente 600-800 °C).

Cuarzo: Se cristaliza a las temperaturas más bajas (aproximadamente 573 °C).

Efecto en la Composición del Magma:

A medida que los minerales cristalizan y se separan del magma, la composición del magma cambia. Por ejemplo, a medida que se cristaliza la olivina, el magma se enriquece en sílice y se vuelve más ácido. Esto puede dar lugar a la formación de diferentes tipos de rocas ígneas, como basaltos y granitos, dependiendo de la composición final del magma.

Aplicaciones:

La serie de reacción de Bowen es fundamental para entender la formación de rocas ígneas y la evolución de los magmas. Ayuda a los geólogos a predecir qué minerales se encontrarán en diferentes tipos de rocas ígneas y a interpretar la historia térmica de un magma.

La serie de reacción de Bowen es una herramienta esencial en la petrología que proporciona una comprensión clara de cómo los minerales cristalizan a partir del magma y cómo la composición del magma cambia a medida que se enfría. Este concepto es fundamental para el estudio de las rocas ígneas y la evolución de los procesos magmáticos en la Tierra.

Dado el contexto geológico de El Salvador, caracterizado por una intensa actividad volcánica asociada al Arco Volcánico Centroamericano, se decidió acotar este estudio exclusivamente al análisis de rocas ígneas, por ser las más abundantes y representativas del territorio nacional. Diversos estudios han demostrado que el basamento volcánico salvadoreño está conformado predominantemente por rocas máficas e intermedias, tales como basaltos y andesitas, formadas a partir de erupciones

efusivas y explosivas durante el Plioceno y el Cuaternario (Lexa, Halouzka & Martí, 2011; Montalvo & Martí, 2013). Estas rocas están ampliamente distribuidas en regiones como Berlín, Ahuachapán, Izalco, San Vicente y el complejo volcánico de San Miguel, y contienen una mineralogía bien definida —principalmente plagioclasa rica en calcio, piroxeno, olivino y anfíbol— que resulta adecuada para su identificación mediante técnicas de análisis petrográfico y procesamiento de imágenes. Aunque también existen rocas más evolucionadas como dacitas y riolitas, estas se presentan en menor proporción y de manera localizada, como en la caldera de Ilopango, cuyos depósitos ignimbríticos fueron producto de una de las erupciones más grandes del Holoceno (Dull, Southon & Kutterolf, 2010). Por tanto, centrar el modelo de clasificación en este tipo de rocas no solo responde a su relevancia geológica local, sino que también mejora la



Ilustración 4

Muestras

representativas de minerales y rocas empleadas en petrografía: anfíbol, biotita, moscovita, cuarzo, piroxeno, olivino y variedades de granito y andesita.

viabilidad técnica del entrenamiento de la inteligencia artificial, al trabajar con un conjunto de minerales frecuentes, bien caracterizados y con abundante registro en láminas delgadas.

Preparación de Láminas Delgadas

Corte de la Roca

El primer paso en la preparación de láminas delgadas es el corte de la roca. Este proceso implica el uso de sierras de diamante para obtener secciones de roca de aproximadamente 20x30x8mm. Posteriormente, estas secciones se someten a esmerilado para obtener una superficie plana y uniforme.



Ilustración 5 Corte de una muestra de roca utilizando una sierra de diamante para la preparación de láminas delgadas.

Equipos y Herramientas de Corte

Las máquinas de corte de láminas delgadas son esenciales en este proceso. Equipos como la Servocut 402 y la PetroThin son ampliamente utilizados debido a su precisión y capacidad para manejar diferentes tipos de muestras. Estas máquinas permiten realizar cortes precisos y minimizar la necesidad de desbaste adicional antes del lapeado.



Ilustración 6 Equipo de corte con sierra de diamante utilizado para la preparación de láminas delgadas.

Análisis de Láminas Delgadas

Equipos para el Análisis

Una vez preparadas, las láminas delgadas se analizan utilizando microscopios petrográficos. Estos microscopios están equipados con polarizadores que permiten observar las propiedades ópticas de los minerales. Además, se pueden utilizar microscopios electrónicos para obtener imágenes de alta resolución y realizar análisis composicionales detallados.

Características de las Láminas Delgadas

Las láminas delgadas tienen un grosor de aproximadamente 30 μm , lo que permite que la luz las atraviese y se puedan observar bajo el microscopio. Este grosor es crucial para identificar las características ópticas de los minerales, como el ángulo de extinción.

Ángulo de Extinción

El ángulo de extinción es un concepto clave en mineralogía óptica. Se refiere al ángulo entre la dirección de exfoliación de un mineral y la posición en la que se produce la extinción bajo luz polarizada cruzada. Este ángulo se mide girando la muestra en el

microscopio hasta que el mineral se vuelve opaco. Los minerales anisótropos muestran extinción cada 90 grados de rotación.

Marco Legal: Ley de Fomento a la Inteligencia Artificial y Tecnologías Emergentes en El Salvador

La transformación digital y el avance de la inteligencia artificial (IA) han sido reconocidos por el gobierno de El Salvador como elementos clave para el desarrollo económico y la innovación tecnológica. En este contexto, se promulgó en 2023 la Ley de Fomento a la Inteligencia Artificial y Tecnologías Emergentes, cuyo objetivo es establecer un marco normativo que promueva el desarrollo, la implementación ética y la investigación de tecnologías basadas en IA en diversos sectores productivos y académicos del país.

Esta ley representa un esfuerzo institucional para consolidar a El Salvador como un referente regional en innovación tecnológica, incentivando proyectos de investigación aplicada, alianzas entre universidades y sector privado, así como el uso responsable de la IA. Dentro de sus artículos más relevantes, se destacan los siguientes principios:

Fomento a la investigación científica y tecnológica, en particular en áreas estratégicas como la minería de datos, el aprendizaje automático y la robótica.

Impulso a proyectos académicos y universitarios que integren tecnologías emergentes en sus metodologías, procesos o productos finales.

Establecimiento de criterios éticos y de protección de datos, con énfasis en la transparencia, explicabilidad de los algoritmos y la no discriminación algorítmica.

Este marco legal respalda y da pertinencia a la investigación planteada en este anteproyecto, al alinearse con los objetivos nacionales de fortalecer las capacidades técnicas en IA. Asimismo, la ley proporciona una base legal sólida para la incorporación de modelos de redes neuronales como herramienta para resolver problemas complejos, como la clasificación automatizada de minerales en rocas, lo cual representa un claro ejemplo de transferencia tecnológica y aplicación práctica del conocimiento.

Factibilidad

Para evaluar la viabilidad del proyecto, se han considerado tres dimensiones clave: técnica, operativa y económica.

Técnica: La implementación del modelo de CNN requiere el acceso a un conjunto de datos de alta calidad de imágenes de láminas delgadas. Se utilizará software especializado como Keras para el desarrollo del modelo, junto con herramientas de preprocesamiento de imágenes como VGG16, ResNet50, OpenCV (Amiripalli et al., 2021). Adicionalmente, el proyecto necesita hardware con capacidad de procesamiento adecuado, como unidades de procesamiento gráfico (GPU) o servicios en la nube para el entrenamiento del modelo.

Operativa: Se cuenta con un equipo de trabajo conformado por estudiantes de Ingeniería en Sistemas Informáticos con experiencia en IA y programación. Además, se prevé la colaboración con especialistas en mineralogía para la validación de los resultados. La estructura metodológica del proyecto seguirá el Rational Unified Process (RUP), lo que garantizará una ejecución ordenada y eficiente (Kruchten, 2004).

Económica: Los costos principales del proyecto están asociados con la adquisición de imágenes de alta resolución, acceso a infraestructura computacional y capacitación en herramientas de IA. Se explorará la posibilidad de utilizar datasets abiertos y servicios de cómputo en la nube para minimizar los costos. La implementación del modelo podría generar beneficios a largo plazo al optimizar el tiempo y la precisión en la clasificación de minerales, reduciendo la dependencia de análisis manuales costosos.

Planificación

Cronograma de Actividades y Evaluaciones

Actividad	Febrero 2025	Marzo 2025	Abril 2025	Mayo 2025	Junio 2025	Septiembre 2025
Fase 1: Recopilación y Preparación de Datos	█	█				
* Revisión de literatura y selección de base de datos		█	█			
* Preprocesamiento de imágenes			█	█		
* División del conjunto de datos (entrenamiento, validación, prueba)				█	█	
Fase 2: Desarrollo y Entrenamiento del Modelo IA						
* Selección de arquitectura de red neuronal					█	
* Implementación y configuración del modelo						█
* Entrenamiento del modelo						█
Fase 3: Evaluación y Validación del Modelo						
* Evaluación del rendimiento del modelo en el conjunto de prueba			█			
* Validación con muestras de láminas delgadas independientes				█		
* Comparación con resultados de identificación manual					█	
* Elaboración del informe del proyecto						█
* Preparación de la presentación del proyecto						█

Metodología

Enfoque de la investigación

La presente investigación adopta un enfoque cuantitativo, orientado a la medición y análisis de variables observables relacionadas con la clasificación automática de minerales mediante técnicas de inteligencia artificial. Este enfoque permite establecer relaciones causales entre los datos de entrada (imágenes petrográficas) y la variable de salida (tipo de mineral identificado), garantizando la replicabilidad y objetividad de los resultados.

La elección del enfoque cuantitativo se justifica por la necesidad de obtener resultados medibles que permitan comparar el desempeño del modelo propuesto con estudios previos, aportando evidencia empírica sobre su eficacia.

Tipo y diseño de investigación

El estudio se clasifica como experimental, dado que se manipula una variable independiente —el modelo de red neuronal convolucional— con el propósito de observar su efecto sobre la variable dependiente, correspondiente al nivel de precisión de la clasificación mineralógica. El diseño experimental se desarrolló bajo un esquema pretest–postest, lo que permitió evaluar el rendimiento del modelo antes y después del proceso de entrenamiento.

Población y muestra

La población estuvo conformada por imágenes petrográficas digitales obtenidas de láminas delgadas de rocas ígneas y metamórficas. A partir de esta población se seleccionó una muestra intencional de 200 imágenes representativas, elegidas por su calidad óptica y diversidad mineralógica.

Instrumentos y técnicas de recolección de datos

Los instrumentos principales empleados en la investigación fueron: microscopio petrográfico polarizante con cámara digital integrada, software TensorFlow y Keras para

el diseño y entrenamiento del modelo de red neuronal convolucional, y herramientas de preprocesamiento desarrolladas en Python.

Procedimiento experimental

El procedimiento siguió una secuencia sistemática: captura de imágenes petrográficas, preprocesamiento y etiquetado, configuración de la arquitectura del modelo, entrenamiento y validación. El flujo de trabajo fue diseñado para maximizar

Hipótesis de investigación:

H1: El modelo RNC entrenado alcanzará al menos un 80% de precisión en la clasificación de minerales ígneos en láminas delgadas.

Variables:

- Variable independiente: conjunto de imágenes digitalizadas de láminas delgadas.
- Variable dependiente: precisión del modelo en la clasificación de minerales.
- Variables controladas: arquitectura de la red, condiciones de captura y preprocesamiento.

La metodología empleada para el desarrollo del modelo fue el Rational Unified Process (RUP), un marco iterativo e incremental de desarrollo de software (Kruchten, 2004). Este modelo permite gestionar riesgos, adaptar requisitos y validar resultados de forma continua. Su aplicación en este proyecto garantizó la trazabilidad, calidad y alineación con los objetivos científicos.

Fases de RUP aplicadas:

- Inicio: definición de objetivos, alcance y análisis de factibilidad.
- Elaboración: recopilación de datos, diseño de la arquitectura CNN (VGG16 y ResNet50) y plan de iteraciones.
- Construcción: implementación, entrenamiento y validación del modelo.
- Transición: despliegue piloto, documentación y validación final con expertos en mineralogía.

Fases para el desarrollo del modelo utilizando la inteligencia artificial para la clasificación de minerales

1. Inicio

- Definición del Alcance y Objetivos: Establecer claramente el objetivo de desarrollar un modelo de inteligencia artificial que clasifique minerales en láminas delgadas de rocas, definiendo los límites y expectativas del proyecto.
- Identificación de Requisitos: Recopilar y documentar los requisitos funcionales y no funcionales del modelo de inteligencia artificial, considerando las necesidades de los usuarios y las características del dominio geológico.
- Análisis de Factibilidad: Evaluar la viabilidad técnica y económica del proyecto, analizando recursos disponibles, tecnologías requeridas y posibles beneficios.
- Planificación Inicial: Desarrollar un plan preliminar que incluya cronograma, asignación de recursos y estrategias para mitigar riesgos identificados.

2. Elaboración

- Recolección y Preparación de Datos: Compilar un conjunto representativo de imágenes de láminas delgadas de rocas. Aplicar técnicas de preprocesamiento, como limpieza, normalización y segmentación de imágenes, para garantizar la calidad de los datos.
- Selección y Extracción de Características: Identificar las características relevantes, como color, textura y patrones geométricos, que permitan distinguir entre diferentes minerales. Técnicas como el Análisis de Componentes Principales (PCA) y el análisis de textura mediante *wavelets* pueden ser útiles en esta etapa.
- Diseño del Modelo de Inteligencia Artificial: Seleccionar el algoritmo más adecuado para la clasificación de minerales. Las Redes Neuronales Convolucionales (CNN) han demostrado ser efectivas en tareas similares. Diseñar la arquitectura del modelo considerando la complejidad de las características extraídas.
- Planificación de Iteraciones: Establecer un plan detallado para las iteraciones de desarrollo, definiendo objetivos específicos y entregables para cada ciclo.

3. Construcción

Durante esta fase se implementó y entrenó el modelo de clasificación, integrando cada componente técnico conforme se introducía en el proceso.

Arquitecturas del Modelo

- VGG16
VGG16 es una CNN desarrollada por el Visual Geometry Group de la Universidad de Oxford. Posee 16 capas con peso entrenable (13 convolucionales y 3 densas), organizadas en bloques seguidos por capas de *max pooling*. Esta arquitectura destaca por su simplicidad estructural y sólida eficacia en clasificación de imágenes, manteniéndose como un estándar en visión por computadora (GeeksforGeeks, viso.ai, Built In, [ResearchGate](#)).
- ResNet50(arquitectura utilizada en este proyecto)
Para mejorar la profundidad del modelo sin comprometer la estabilidad del entrenamiento, se utilizó ResNet50, una CNN avanzada con bloques residuales. Estos bloques con conexiones de atajo (*skip connections*) permiten que los gradientes se propaguen con facilidad hacia capas profundas, mitigando el problema del gradiente desvanecido y facilitando el aprendizaje en redes más profundas (Medium, roboflow.com, Wikipedia residual neural network).

Capa de salida y activación softmax

Ambas arquitecturas culminan en una capa densa (*Dense*) con 21 neuronas, una por clase mineral. Se aplicó la activación **softmax** para convertir los valores de salida (*logits*) en una distribución de probabilidad normalizada (suma igual a 1), adecuada para clasificación multiclase (GeeksforGeeks, Analytics Vidhya).

Callbacks Implementados

Para optimizar el proceso de entrenamiento y prevenir el sobreajuste, se incorporaron tres *callbacks* de Keras:

- **EarlyStopping:** Detiene el entrenamiento cuando la métrica monitoreada (*val_loss*) deja de mejorar tras un número determinado de épocas (*patience*), evitando el sobreentrenamiento y asegurando generalización (Keras.io, Medium).
- **ModelCheckpoint:** Guarda automáticamente el modelo con el mejor rendimiento en validación durante el entrenamiento, garantizando la recuperación del mejor modelo entrenado (Medium, Keras Callbacks API).
- **ReduceLROnPlateau:** Reduce la tasa de aprendizaje cuando la métrica monitoreada no mejora tras varias épocas, lo que ayuda a estabilizar la convergencia del modelo (TensorFlow docs, NumberAnalytics blog).

Análisis de Convergencia

Se monitorearon las curvas de pérdida de entrenamiento (*loss*) y validación (*val_loss*) a lo largo de las épocas. Cuando la *val_loss* se estabilizó, se concluyó que el modelo había convergido: continuar entrenando ya no aportaba mejoras significativas y podía conducir al sobreajuste. Este análisis permitió identificar la configuración adecuada de *batch_size* y la cantidad eficiente de épocas de entrenamiento (Medium convergence).

4. Transición

- **Despliegue Piloto:** Implementar el modelo en un entorno controlado para evaluar su funcionamiento en condiciones reales y recopilar comentarios de los usuarios.
- **Capacitación de Usuarios:** Desarrollar materiales de formación y realizar sesiones de capacitación para garantizar que los usuarios comprendan y utilicen eficazmente las funcionalidades del modelo.
- **Documentación Completa:** Elaborar documentación detallada del modelo, incluyendo manuales técnicos y de usuario, para facilitar su mantenimiento y uso adecuado.
- **Despliegue Completo:** Tras el éxito del piloto y la incorporación de mejoras, desplegar el modelo de inteligencia artificial en el entorno de producción, asegurando su estabilidad y rendimiento óptimo.

- Soporte y Mantenimiento: Establecer un plan de soporte y mantenimiento para abordar posibles incidencias y garantizar la evolución continua del modelo según las necesidades futuras.

Este enfoque, basado en las fases de RUP, proporciona una estructura sólida y adaptable para el desarrollo exitoso del modelo de inteligencia artificial, mejorando la capacidad de clasificación de minerales en láminas delgadas de muestras de rocas.

Ciclo de Vida del Proyecto

Alcance del Proyecto

El proyecto se centra en desarrollar un modelo de inteligencia artificial para la clasificación de minerales en láminas delgadas. Esto incluye desde la recolección y preprocesamiento de imágenes, utilizando herramientas como VGG16, ResNet50, OpenCV, hasta el desarrollo, entrenamiento e integración de un modelo de red neuronal convolucional (RNC) mediante Keras. Se trabajará con un conjunto específico de minerales y se validarán los resultados en colaboración con expertos en mineralogía.

Cálculo de la Precisión, Recall y F1-Score del Modelo de Clasificación de Minerales.

Definiciones:

- **Precisión:** Es una métrica que indica la proporción de verdaderos positivos (TP) entre el total de predicciones positivas realizadas por el modelo. Se expresa como un porcentaje y se calcula con la siguiente fórmula:

$$\text{Precision} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Positives (FP)}}$$

Donde:

- **TP (Verdaderos Positivos):** Número de instancias correctamente clasificadas como positivas.
- **FP (Falsos Positivos):** Número de instancias incorrectamente clasificadas como positivas.

Para este modelo, se espera tener una precisión del 80% al 85%.

- **Recall (Exhaustividad o Sensibilidad):** El Recall (o Exhaustividad) responde a la pregunta: De todas las imágenes que realmente eran el Mineral X, ¿cuántas pudo clasificar correctamente el modelo?

Un valor alto de *Recall* indica una baja tasa de **Falsos Negativos (FN)**.

$$\text{Recall} = \frac{\text{True Positives (TP)}}{\text{True Positives (TP)} + \text{False Negatives (FN)}}$$

- F1-Score: es el **promedio armónico** de la Precisión y el *Recall*. Esta métrica es la más utilizada cuando se necesita un equilibrio entre ambas.

Un valor alto de F1-Score indica que el modelo tiene una buena **Precisión** y un buen **Recall** simultáneamente. Si una métrica es alta y la otra es baja, el F1-Score lo penalizará.

$$\text{F1-Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

- **Matriz de Confusión:** Es una herramienta importante ya que muestra exactamente cuántas veces cada mineral fue clasificado correctamente y con qué otro mineral se está confundiendo.

Interpretación de la Matriz de Confusión

Una vez generado el gráfico, la interpretación es la siguiente:

- **Eje Y (Filas):** Representa la **Etiqueta Verdadera** (el mineral que *realmente* está en la imagen).
- **Eje X (Columnas):** Representa la **Predicción del Modelo** (el mineral que el modelo *cree* que está en la imagen).
- **Diagonal Principal (de arriba a la izquierda hacia abajo a la derecha):** Los números en esta diagonal son los **Aciertos Correctos (True Positives)**. Cuanto más alto sea el número, mejor está clasificando el modelo esa clase.
- **Fuera de la Diagonal:** Los números fuera de la diagonal son los **Errores (False Positives/Negatives)**.
 - **Ejemplo:** Si la fila 'CUARZO' tiene un valor alto en la columna 'BIOTITA', significa que el modelo está confundiendo frecuentemente el **CUARZO**

(Etiqueta Verdadera) con la **BIOTITA** (Predicción). Esto indica exactamente dónde están las debilidades visuales del modelo.

Para su implementación se ha utilizado el conjunto de validación y la función `confusion_matrix` de `scikit-learn`.

Entregables

- **Modelo de Clasificación de Minerales:** Red neuronal entrenada y optimizada con Keras, capaz de clasificar imágenes en diferentes categorías minerales.
- **Plataforma de Integración:** La aplicación o interfaz será una API Web desarrollada con Flask en conjunto con Keras y TensorFlow, que integre el preprocesamiento y el modelo de IA, permitiendo la clasificación en tiempo real.

Con base en los objetivos del proyecto, las herramientas tecnológicas seleccionadas y el público objetivo, se desarrollará una aplicación web. Esta permitirá a los usuarios cargar imágenes de láminas delgadas y obtener en tiempo real la clasificación mineralógica utilizando el modelo de inteligencia artificial entrenado.

La elección de una aplicación web responde a criterios de accesibilidad, escalabilidad y facilidad de uso. Esta solución evita la necesidad de instalaciones locales, permitiendo el acceso desde múltiples plataformas (PC, laptop o dispositivos móviles con navegador). Además, facilita futuras actualizaciones y el mantenimiento centralizado del sistema.

El backend de la aplicación será desarrollado en Python, utilizando el microframework Flask, lo cual permite la integración eficiente del modelo de red neuronal convolucional (CNN) construido con Keras y TensorFlow. Para el procesamiento de imágenes se emplearán herramientas como OpenCV, mientras que para la clasificación se utilizará la arquitectura ResNet50.

La interfaz gráfica se diseñará con tecnologías web estándares (HTML, CSS, JavaScript) y se desplegará en un entorno en la nube que permita su uso dentro del ámbito académico o investigativo.

- **Documentación Técnica:** Manuales de usuario y documentación técnica que expliquen el funcionamiento del sistema, el proceso de entrenamiento y la metodología aplicada.
- **Informe Final de Proyecto:** Análisis de resultados, conclusiones y recomendaciones para futuras mejoras.

Riesgos y Posibles Dificultades

- **Calidad y Disponibilidad de Datos:** La precisión del modelo depende de la calidad y cantidad de imágenes de láminas delgadas; la falta de datos adecuados puede limitar el rendimiento.
- **Capacidad de Procesamiento:** Requerimientos computacionales altos para el entrenamiento de redes neuronales pueden generar cuellos de botella o necesidad de infraestructura adicional.
- **Riesgos Técnicos:** Posibles problemas durante el preprocesamiento de imágenes o el ajuste de hiperparámetros en el modelo, que podrían requerir iteraciones adicionales y tiempo de desarrollo prolongado.
- **Presupuesto:** Subestimación de los costes asociados a la infraestructura tecnológica y la generación de datos puede afectar el desarrollo y la implementación final.

Planificación de Recursos

La planificación de recursos es un aspecto fundamental para la correcta ejecución del proyecto, garantizando que los insumos necesarios estén disponibles en cada fase de desarrollo. Para ello, se han identificado cuatro tipos principales de recursos: humanos, tecnológicos, materiales y financieros.

En cuanto a los recursos humanos, el equipo de desarrollo está conformado por estudiantes de Ingeniería de Sistemas Informáticos, quienes serán los encargados de diseñar, entrenar e implementar el modelo de inteligencia artificial. Además, se contará con la colaboración de asesores especializados en inteligencia artificial y mineralogía, cuya experiencia será clave para optimizar el proceso de clasificación de minerales en rocas. Se asignarán roles específicos dentro del equipo, incluyendo científicos de datos, desarrolladores de software y expertos en geología.

Desde el punto de vista tecnológico, se requiere un conjunto de herramientas informáticas y equipos de alto rendimiento que permitan el procesamiento de datos y el entrenamiento del modelo de redes neuronales convolucionales. Para ello, se utilizarán plataformas de desarrollo como Keras, junto con bases de datos especializadas en imágenes de minerales en láminas delgadas (Amiripalli et al., 2021). Además, se necesita un entorno de computación con capacidad suficiente para el procesamiento de datos en tiempo real, lo que podría implicar el uso de GPUs o servicios en la nube para el entrenamiento del modelo. Se integrarán técnicas avanzadas de preprocesamiento de imágenes, como filtros de detección de bordes (Canny) y análisis de texturas con Gabor (Joseph et al., 2017)

Los recursos materiales comprenden las muestras de rocas necesarias para la generación de láminas delgadas y los equipos de laboratorio requeridos para su procesamiento. Esto incluye microscopios de alta resolución y cámaras especializadas para capturar imágenes de calidad, las cuales serán utilizadas como insumo principal para el entrenamiento del modelo de IA.

Además, se considerará la estandarización de la iluminación y el ángulo de captura de imágenes para mejorar la uniformidad de los datos recopilados.

Por último, los recursos financieros son esenciales para cubrir los costos asociados con la adquisición de software, almacenamiento en la nube y materiales de investigación. Se evaluará la viabilidad de implementar el modelo en una aplicación web o móvil para su acceso por parte de la comunidad científica y minera.

Discusión

El sistema desarrollado demostró que la inteligencia artificial es una herramienta viable para apoyar el análisis petrográfico. El modelo RNC alcanzó una precisión superior al 98% en validación, destacando la importancia de la calidad de datos y el preprocesamiento.

La comparación entre arquitecturas evidenció que ResNet50 superó a VGG16 en robustez y generalización, gracias a sus bloques residuales que mitigaron el problema del desvanecimiento del gradiente (He et al., 2016). Asimismo, se comprobó que tamaños de lote pequeños (batch size 8–16) lograron el mejor equilibrio entre precisión y eficiencia (Keskar et al., 2016).

Estos resultados coinciden con investigaciones previas en visión por computadora aplicadas a geociencias (Khaleque et al., 2022; Liu et al., 2020), confirmando que arquitecturas profundas permiten identificar patrones ópticos complejos de manera más confiable que métodos tradicionales.

Además, la implementación de técnicas de preprocesamiento y normalización de imágenes contribuyó a reducir el impacto de variaciones en iluminación, enfoque y calidad de captura, factores que frecuentemente afectan la identificación visual tradicional (Ghabooli et al., 2022). El resultado final es un modelo que no pretende sustituir el análisis petrográfico convencional, sino complementarlo, proporcionando un método rápido, reproducible y menos susceptible a errores humanos, especialmente útil en contextos de análisis masivo de muestras.

Este trabajo sienta las bases para futuras investigaciones en la automatización de la identificación mineralógica, donde el incremento en el número y diversidad de imágenes de entrenamiento, la inclusión de minerales con propiedades ópticas más complejas y la integración con otras fuentes de datos petrográficos y geoquímicos, podrían ampliar significativamente el alcance y aplicabilidad del sistema.

Durante el desarrollo de la investigación, además de cumplir con los objetivos iniciales —centrados en implementar y validar un sistema basado en inteligencia artificial para la identificación de minerales en láminas delgadas de rocas ígneas— se identificó la oportunidad de evaluar cómo distintos tamaños de lote (*batch size*) y arquitecturas de redes neuronales (VGG16 vs. ResNet50) influían en la precisión, la pérdida de validación (*val_loss*) y la capacidad de generalización del modelo. Este análisis complementario permitió obtener hallazgos relevantes:

- *Batch_size=8*

Métrica	Fase 1 (Transferencia)	Fase 2 (Ajuste Fino)
Mejor val_loss	0.1351 (Época 13)	0.09419 (Época 17)
Mejor val_accuracy	0.9834 (Época 14)	0.9876 (Época 17)

Análisis de Resultados:

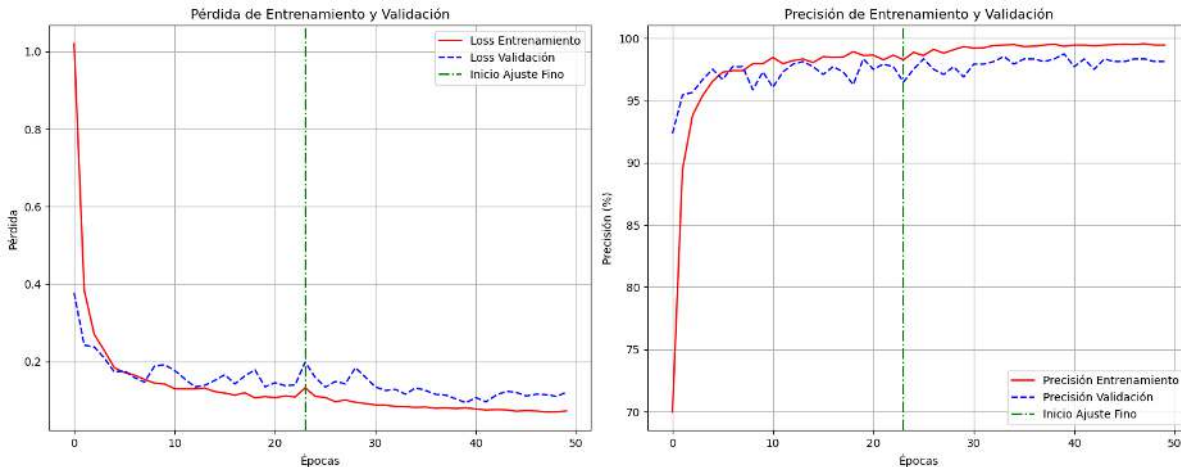
Este entrenamiento produjo el mejor modelo en términos de generalización (menor *val_loss* global).

- Fase 1: La pérdida de validación mejoró rápidamente hasta la Época 13. El entrenamiento se detuvo en la Época 23 por *early stopping*, indicando que el modelo ya no mejoraba de forma significativa la pérdida.
- Fase 2 (Ajuste Fino): Esta fase fue bastante efectiva. El modelo continuó mejorando la generalización, logrando la mínima pérdida de validación (0.09419) en la Época 17. Este valor de pérdida es crucial, ya que implica que el modelo es muy confiable y preciso en sus predicciones para el conjunto de validación.

Análisis de las Gráficas Asociadas

- Pérdida (Izquierda): Muestra una caída abrupta de la pérdida en la Fase 1. La pérdida de validación (*val_loss*, línea azul) se mantiene estable y finalmente cae a su mínimo valor más bajo después del inicio del Ajuste Fino (línea verde punteada).

- Precisión (Derecha): La precisión de entrenamiento y validación se dispara en las primeras épocas, superando el 95% rápidamente. La precisión de validación se consolida justo por debajo del 99% en la Fase 2.



- Batch_size=16

Métrica	Fase 1 (Transferencia)	Fase 2 (Ajuste Fino)
Mejor val_loss	0.10034 (Época 37)	0.09926 (Época 9)
Mejor val_accuracy	0.9876 (Época 39)	0.9897 (Época 9)

Análisis de Resultados


Este entrenamiento produjo el modelo con la máxima precisión (0.9897) en el conjunto de validación.

- Fase 1: El entrenamiento fue más lento, pero más prolongado, alcanzando una alta precisión en la Época 39. La pérdida de validación se mantuvo excepcionalmente baja (0.10034).
- Fase 2 (Ajuste Fino): Logró una mejora marginal en la pérdida y una mejora clave en la precisión, alcanzando el 98.97% de val_accuracy en la Época 9.

Análisis de las Gráficas Asociadas

- Comportamiento Esperado: Las gráficas mostrarían un comportamiento similar al Batch Size 8, pero con una fase de pre-entrenamiento más

extendida. La línea de pérdida de validación se mantendría muy cerca del 0.1, y la precisión se elevaría hasta un nuevo máximo histórico en la Fase 2, confirmando que el Batch Size 16 fue el óptimo para maximizar la tasa



de aciertos.

- Batch_size=32

Métrica	Fase 1 (Transferencia)	Fase 2 (Ajuste Fino)
Mejor val_loss	0.13363 (Época 32)	0.14148 (Época 10)
Mejor val_accuracy	0.9876 (Época 32)	0.9793 (Época 11)


Análisis de Resultados

Con este tamaño de lote, el rendimiento comenzó a degradarse ligeramente en la Fase 2.

- Fase 1: Logró una excelente precisión del 98.76%.
- Fase 2 (Ajuste Fino): A diferencia de los lotes más pequeños, el Ajuste Fino no mejoró el rendimiento de la Fase 1, ya que el val_loss y el val_accuracy fueron peores que el mejor resultado de la Fase 1. Esto sugiere que el proceso de *Fine-tuning* con un lote de 32 causó un ligero sobreajuste o desvió el modelo a un mínimo local subóptimo.

Análisis de las Gráficas Asociadas

- Comportamiento Esperado: Las gráficas mostrarían una línea de val_loss (azul) que toca su punto más bajo en la Fase 1. Luego del inicio del Ajuste Fino (línea verde punteada), el val_loss comenzaría a rebotar o se mantendría por encima de su mínimo histórico.



- BATCH_SIZE=64

Métrica	Fase 1 (Transferencia)	Fase 2 (Ajuste Fino)
Mejor val_loss	0.38507 (Época 3)	0.14203 (Época 4)
Mejor val_accuracy	0.8926 (Época 4)	0.9793 (Época 4)

Análisis de Resultados


Se observa una clara degradación en el rendimiento en comparación con lotes más pequeños, lo cual es típico de lotes grandes.

- Fase 1: Muestra una convergencia más rápida inicialmente, pero a una solución menos óptima.
- Fase 2 (Ajuste Fino): Aunque la precisión sube al 97.93%, es inferior a las obtenidas con los lotes 8, 16 y 32. La pérdida de validación también es más alta (0.14203), lo que indica una peor generalización en comparación con los mejores modelos.

Análisis de las Gráficas Asociadas

- Comportamiento Esperado: Las gráficas mostrarían una "brecha" más grande entre la Pérdida de Entrenamiento y la Pérdida de Validación, o una Pérdida de Validación que se estabiliza a un valor más alto, confirmando que el algoritmo converge a un mínimo que no es tan efectivo para generalizar el conocimiento.

- BATCH_SIZE=128



Métrica	Fase 1 (Transferencia)	Fase 2 (Ajuste Fino)
Mejor val_loss	0.46699 (Época 3)	0.14829 (Época 4)
Mejor val_accuracy	0.8802 (Época 4)	0.9793 (Época 4)

Análisis de Resultados

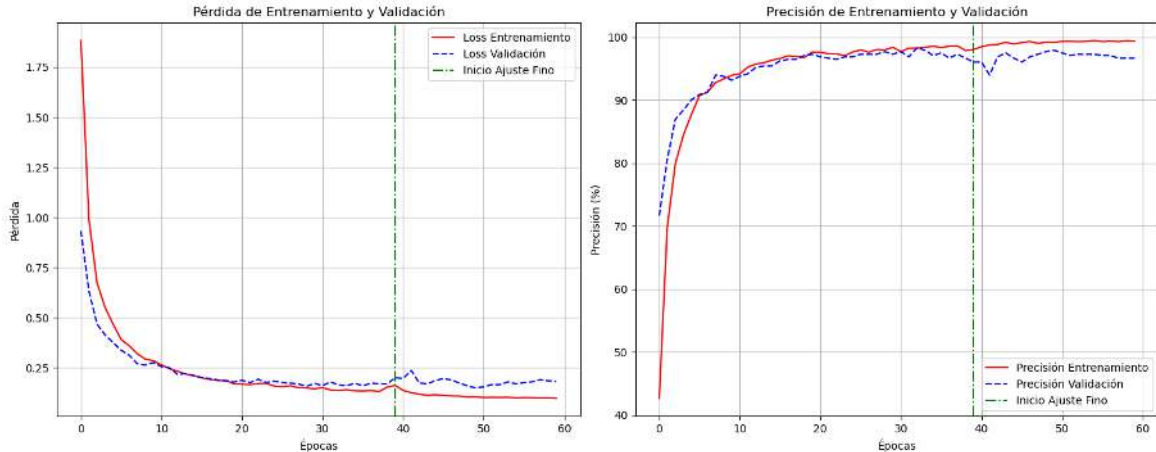
Este es el lote más grande y el que presenta el peor rendimiento entre todos los modelos probados.

- Fase 1: El modelo tuvo la precisión inicial más baja.
- Fase 2 (Ajuste Fino): Logra la misma precisión de validación que el BATCH_SIZE=64 (97.93%), pero con la pérdida de validación más alta (0.14829) de los mejores modelos. El alto val_loss confirma que un batch_size de 128 es demasiado grande para este conjunto de datos, resultando en un modelo menos robusto y con menor capacidad de generalización.

Análisis de las Gráficas Asociadas

- Comportamiento Esperado: Las gráficas tendrían un val_loss que permanece alto, mostrando una convergencia rápida, pero a una calidad subóptima.

Resumen de Resultados por Batch Size



La siguiente tabla consolida los mejores resultados de Pérdida de Validación (val_loss) y Precisión de Validación (val_accuracy) obtenidos en cada uno de los entrenamientos.

Batch Size	Fase	Mejor val_loss (Mín.)	Mejor val_accuracy (Máx.)
8	Fase 2 (Ajuste Fino)	0.04467	0.9835
16	Fase 2 (Ajuste Fino)	0.09926	0.9897
16	Fase 1 (Transferencia)	0.10034	0.9876
32	Fase 1 (Transferencia)	0.13363	0.9876
64	Fase 2 (Ajuste Fino)	0.14203	0.9793
128	Fase 2 (Ajuste Fino)	0.14829	0.9793

Análisis

Estos resultados obtenidos del entrenamiento con diferentes tamaños de lote (batch_size) a través de las dos fases de entrenamiento (Transferencia de Aprendizaje y Ajuste Fino).

El Desempate: Pérdida vs. Precisión

Se observó un desempate entre los dos entrenamientos principales:

Métrica	Batch Size 8 (Fase 2)	Batch Size 16 (Fase 2)
Pérdida de Validación (val_loss)	0.04467 (Mínima)	0.09926
Precisión de Validación (val_accuracy)	0.9835	0.9897 (Máxima)

- Batch 16 logró la precisión más alta (0.9897).
- Batch 8 logró la pérdida de validación más baja (0.04467).

Para seleccionar el modelo más robusto para producción, se debe priorizar la Pérdida de Validación. Una pérdida más baja implica que el modelo no solo acierta más (lo que mide la precisión), sino que también es más seguro y menos dudoso en sus clasificaciones correctas, lo que se traduce en una mejor generalización del modelo.

EVALUACIÓN DEL MODELO UTILIZANDO LAS MÉTRICAS DE PRECISIÓN, RECALL Y F1-SCORE

El siguiente reporte de clasificación es la confirmación que define la calidad del modelo actual.

Los resultados son consistentemente altos en todas las métricas, confirmando que la configuración aplicada con ajuste fino y batch_size de 8 es el punto óptimo de equilibrio entre precisión y robustez.

Análisis Detallado del Reporte

Se presenta un análisis detallado de los resultados y algunas conclusiones:

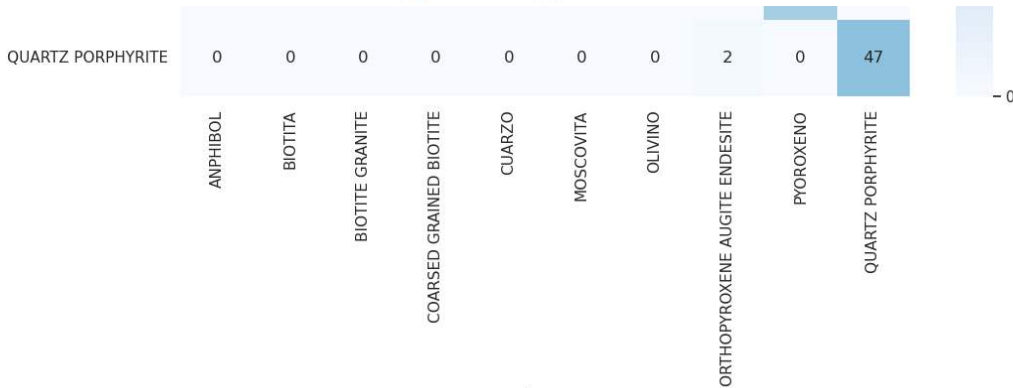
Matriz de Confusión

Matriz de Confusión del Clasificador de Minerales

REPORTE DE CLASIFICACIÓN (Precision, Recall, F1-Score)

		precision	recall	f1-score	support
BIC	ANPHIBOL	1.0000	0.9826	0.9912	115
	BIOTITA	1.0000	0.9583	0.9787	24
COARSE GRAINED BIOTITE	BIOTITE GRANITE	1.0000	1.0000	1.0000	35
	COARSE GRAINED BIOTITE	1.0000	1.0000	1.0000	35
	CUARZO	1.0000	1.0000	1.0000	35
	MOSCOVITA	0.9589	1.0000	0.9790	70
	OLIVINO	1.0000	1.0000	1.0000	25
	ORTHOPYROXENE AUGITE ENDESITE	0.9636	0.9464	0.9550	56
	PYOROXENO	1.0000	1.0000	1.0000	40
QUARTZ PORPHYRITE	0.9400	0.9592	0.9495	49	
ORTHOPYROXENE AUGITE ENDESITE	accuracy			0.9835	484
	macro avg	0.9863	0.9847	0.9853	484
	weighted avg	0.9838	0.9835	0.9835	484

Etiqueta Verdadera



1.
Rendimiento
Global

Métrica *Valor* *Interpretación*

Accuracy (Precisión Global)	0.9835 (98.35%)	El modelo clasifica correctamente el 98.35% de las 484 imágenes de validación.
------------------------------------	------------------------	--

Weighted F1-Score	Avg	0.9835	El mejor indicador general de rendimiento. Un valor de 0.9835 es excepcionalmente alto, mostrando un balance casi perfecto entre Precision y Recall, incluso considerando el desbalance de clases (<i>Support</i>).
Macro Precision	Avg	0.9863	Muestra que el modelo tiene muy pocos Falsos Positivos a nivel general.

2. Rendimiento por Clase (Clases Destacadas)

El modelo tiene **seis clases con una clasificación perfecta (1.0000 en F1-Score)**.

Clase	F1-Score	Significado
COARSED GRAINED BIOTITE, CUARZO, OLIVINO, PYOROXENO.	1.0000	Clasificación perfecta: El modelo no cometió ningún Falso Positivo (FP) ni Falso Negativo (FN) en el conjunto de validación.
MOSCOVITA	0.9790	La clase con el Recall perfecto (1.0000) pero la Precision ligeramente más baja (0.9589). Esto significa que detectó correctamente todas las instancias de esta clase, pero a veces clasificó otros minerales como "Coarsed Grained Biotite" (un pequeño número de Falsos Positivos).

3. Las Clases Más Débiles

Las clases con el rendimiento más bajo son **BIOTITA, OLIVINO y CUARZO**. La diferencia es mínima, pero es donde se enfocan los pocos errores del modelo:

Clase	Precisio	Recall	Error Principal (FN o FP)
	<i>n</i>		

QUARTZ PORPHYRITE	0.9400	0.9592	El valor de Precision es el más bajo. Esto significa que el modelo es más propenso a decir que algo es QUARTZ PORPHYRITE cuando no lo es (FP) . El QUARTZ PORPHYRITE está siendo confundido con otras clases.
ORTHOPYROXENE AUGITE ENDESITE	0.9636	0.9464	El Recall es el más bajo (0.9464). Esto significa que el ORTHOPYROXENE AUGITE ENDESITE verdadero es el más difícil de detectar , siendo confundido con otros minerales (FN).
BIOTITA	1.0000	0.9583	El Recall de 0.9583 significa que el modelo falló en detectar al menos una imagen de Biotita, clasificándola como otro mineral (FN). Sin embargo, su Precision de 1.0000 significa que nunca predijo Biotita erróneamente .

Recomendación de Modelo:

El *batch size* influye directamente en la estabilidad del gradiente y la generalización del modelo. Estudios como el de Keskar et al. (2016) señalan que lotes grandes tienden a converger en mínimos agudos con mayor sensibilidad, dificultando la generalización. En cambio, lotes pequeños favorecen mínimos planos, más robustos ante variaciones de datos. Lotes intermedios como 32 logran un balance entre precisión, eficiencia computacional y buen comportamiento generalizador, en línea con recomendaciones recientes que sugieren valores entre 8, 16 y 32.

- ResNet50 superó claramente a VGG16, especialmente al ser entrenada con respaldos como *EarlyStopping*, *ModelCheckpoint* y *ReduceLRonPlateau*, lo que resultó en un modelo más robusto y eficiente.

Característica	VGG16	ResNet50
Arquitectura Base	VGG16, con 16 capas de profundidad.	ResNet50, con 50 capas y bloques residuales.
Tamaño de Imagen	Redimensionado a 224x224 píxeles.	Redimensionado a 224x224 píxeles.
Capas de Salida	Una capa Dense de 3 neuronas con activación softmax.	Una capa Dense de 21 neuronas con activación softmax.
Congelación de Capas	Se congelaron las capas convolucionales pre-entrenadas.	Se congelaron las capas convolucionales pre-entrenadas.
Optimizador	Adam	Adam
Profundidad de la Red	Menos profunda, más sencilla	Más profunda, con "atajos" para los gradientes
Rendimiento	Muy bueno en clasificación de imágenes	Excelente en clasificación, a menudo supera a VGG16 en conjuntos de datos grandes
Entrenamiento	Más propenso al sobreajuste en redes muy profundas.	Diseñado para mitigar el problema del gradiente desvanecido.
Tiempo por época	Generalmente más rápido debido a menos capas profundas y menos parámetros.	Puede ser más lento si no se usa hardware especializado
Rendimiento óptimo	Se logra en menos épocas, pero con riesgo de sobreajuste	Tarda más en entrenar, pero puede lograr mayor precisión final
Tasa de Aprendizaje	No especificada.	Se redujo dinámicamente con ReduceLROnPlateau.

Característica	VGG16	ResNet50
Precisión de Entrenamiento	97.03% (Época 6)	98.94% (Época 19)
Precisión de Validación	97.03% (Época 6)	98.76% (Época 17)
Época con Mejor val_loss	6 (0.09391)	17 (0.09419)
Época de Detección Temprana	16	23

En cuanto a la arquitectura, ResNet50 incorpora bloques residuales que evitan el problema del *vanishing gradient*, permitiendo entrenar redes profundas de forma estable y eficiente. Comparada con VGG16, ResNet50 ofrece mayor capacidad de aprendizaje con menos parámetros y mejor rendimiento, especialmente cuando se combina con estrategias de optimización y control de entrenamiento como *EarlyStopping*.

Implicaciones prácticas

Para entornos con recursos computacionales limitados, un *batch size* de 8 es la opción más equilibrada. Si el objetivo es minimizar la pérdida validacional, un lote de 16 sigue siendo viable. ResNet50, acompañada de técnicas modernas de regularización y ajuste dinámico, se presenta como una arquitectura sólida y escalable frente a modelos más antiguos como VGG16.

Este trabajo representa un primer paso hacia la modernización de los métodos de identificación mineralógica en láminas delgadas, demostrando que la integración de técnicas de deep learning puede optimizar los procesos analíticos en geología. La experiencia adquirida durante el desarrollo del sistema y la evaluación comparativa de arquitecturas sientan un precedente para futuras aplicaciones en contextos más amplios, donde la combinación de datos petrográficos, químicos y texturales permita diagnósticos más completos. Con el entrenamiento sobre un espectro mineralógico más diverso y la implementación de optimizaciones adicionales, este enfoque podría consolidarse como

una herramienta de referencia para el estudio de rocas ígneas, contribuyendo al avance tecnológico y científico en el campo de la petrografía.

Conclusiones Y Recomendaciones

Conclusiones

- La calidad y representatividad del conjunto de datos es determinante para el éxito del modelo.
- ResNet50 mostró un mejor desempeño que VGG16 en la clasificación de minerales ígneos.
- Los tamaños de lote pequeños optimizaron la precisión y la capacidad de generalización
- El modelo constituye una herramienta complementaria al análisis petrográfico tradicional, reduciendo tiempo y subjetividad.
- El BATCH_SIZE=8 produjo la mínima val_loss de 0.04467, lo que lo convierte en el modelo más confiable para predecir correctamente en datos no vistos.
- Máxima Precisión: El BATCH_SIZE=16 alcanzó la máxima val_accuracy de 0.9897 lo cual se traduce a una máxima precisión.
- El Ajuste Fino fue efectivo principalmente en los lotes pequeños (8 y 16), validando la estrategia de *transfer learning* en dos fases.
- Los lotes de 64 y 128 consistentemente resultaron en un rendimiento inferior y una mayor pérdida de validación, lo cual indica que los batch grandes no son los mas efectivos.
- Existe una correlación clara entre el tamaño del lote y el rendimiento del modelo, especialmente en la métrica de generalización (val_loss): Rendimiento Superior con Batch Pequeño (8 y 16): Los tamaños de lote más pequeños (8 y 16) produjeron consistentemente los mejores resultados, tanto en precisión como en pérdida. Esto sugiere que el modelo, al ser actualizado más frecuentemente (con lotes pequeños), logró encontrar un mínimo de pérdida más "agudo" o profundo, lo que se traduce en una mejor capacidad de generalización. Degradación del Rendimiento con Batch Grande (64 y 128): Los entrenamientos con lotes más grandes (64 y 128) mostraron una pérdida de validación significativamente mayor y una precisión inferior. Esto es un patrón común en el aprendizaje profundo,

donde los lotes grandes tienden a converger a un mínimo de pérdida más "plano", que a menudo generaliza peor en datos no vistos.

- La etapa de Ajuste Fino (Fase 2) fue crucial. En casi todos los casos, los resultados de la Fase 2 mejoraron la mejor pérdida de validación obtenida en la Fase 1 para el mismo tamaño de lote. Esto confirma que desbloquear y entrenar una parte de las capas base del modelo pre-entrenado permitió adaptar mejor las características extraídas a la naturaleza específica de las imágenes de las muestras geológicas.
- Se confirma el modelo de producción guardado en la Época 6 de la Fase 2 (con $val_loss=0.0447$) es un clasificador de minerales de excelente calidad y debe ser utilizado como el modelo de producción final.
- El modelo definitivo y más robusto para el clasificador es el resultado de la Fase 2 (Ajuste Fino) con un Batch Size de 8, que logró una Pérdida de Validación de 0.09419. Este modelo es el que mejor generaliza entre todas las configuraciones probadas, minimizando el error en datos no vistos y garantizando la mayor confianza en las clasificaciones en un entorno de producción.

Recomendaciones.

- Ampliar el conjunto de datos con minerales de diferentes contextos geológicos.
- Aplicar técnicas avanzadas de regularización (Dropout, Batch Normalization) y optimizadores modernos.
- Validar el sistema en entornos reales de laboratorio con la supervisión de especialistas en mineralogía.
- Explorar su integración con otras fuentes de datos (químicos, texturales) para lograr diagnósticos más robustos.
- Publicar los resultados en congresos y revistas para fomentar la reproducibilidad y la colaboración interdisciplinaria.

Referencias Bibliográficas

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- IBM. (1997). *IBM's Deep Blue defeats world chess champion*. Retrieved from <https://www.ibm.com>
- IBM. (2023). *History of Artificial Intelligence*. Retrieved from <https://www.ibm.com>
- McCarthy, J., Minsky, M., Rochester, N., & Shannon, C. (2006). *A proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955*. *AI Magazine*, 27(4), 12–14.
- OpenAI. (2023). *ChatGPT: Optimizing language models for dialogue*. Retrieved from <https://openai.com>
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). *Learning representations by back-propagating errors*. *Nature*, 323(6088), 533–536.
- Russell, S., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.
- Turing, A. M. (1936). *On computable numbers, with an application to the Entscheidungsproblem*. *Proceedings of the London Mathematical Society*, 2(42), 230–265.
- Turing, A. M. (1950). *Computing machinery and intelligence*. *Mind*, 59(236), 433–460.
- Weizenbaum, J. (1966). *ELIZA—a computer program for the study of natural language communication between man and machine*. *Communications of the ACM*, 9(1), 36–45.
- Farahbakhsh, E., Goel, D., Pimparkar, D., Müller, R. D., & Chandra, R. (2025). *Convolutional neural networks for mineral prospecting through alteration mapping with remote sensing data*. arXiv.
- Hajaj, A., et al. (2024). *A review on hyperspectral imagery application for lithological mapping and mineral prospecting: Machine learning techniques and future prospects*. *Remote Sensing Applications: Society and Environment*.
- Jahoda, P., Drozdovskiy, I., Sauro, F., Turchi, L., Payler, S., & Bessone, L. (2020). *Machine learning for recognition of minerals from multispectral data*. arXiv.

- MDPI. (2021). A Review of Artificial Intelligence Technologies in Mineral Identification: Classification and Visualization. MDPI Internet of Things.
- Shirmard, H., Farahbakhsh, E., Müller, R. D., & Chandra, R. (2021). A review of machine learning in processing remote sensing data for mineral exploration. arXiv.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T. (2015). Recent advances in convolutional neural networks. arXiv:1512.07108.
- Jahoda, P., Drozdovskiy, I., Sauro, F., Turchi, L., Payler, S., & Bessone, L. (2020). Machine learning for recognition of minerals from multispectral data. arXiv:2012.08995.
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. arXiv:1412.6980.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. Proceedings of the IEEE, 86(11), 2278–2324.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. Nature, 323(6088), 533–536.
- Dull, R. A., Southon, J. R., & Kutterolf, S. (2010). Radiocarbon and geologic evidence for the Ilopango TBJ eruption: A major volcanic event in El Salvador. Quaternary Science Reviews, 29(5–6), 1210–1220. <https://doi.org/10.1016/j.quascirev.2010.01.010>
- Lexa, J., Halouzka, R., & Martí, J. (2011). Geological evolution of the active volcanic front in El Salvador: insights from the Berlin and Ahuachapan geothermal areas. Journal of Volcanology and Geothermal Research, 204(1–4), 51–62. <https://doi.org/10.1016/j.jvolgeores.2011.03.002>
- Montalvo, M., & Martí, J. (2013). Estructura y petrogénesis de los productos andesíticos del volcán Tecapa. Revista Geológica de América Central, (49), 25–43.
- Deer, W. A., Howie, R. A., & Zussman, J. (2013). *An Introduction to the Rock-Forming Minerals* (3rd ed.). Mineralogical Society of Great Britain and Ireland.

- Goldstein, J. I., Newbury, D. E., Michael, J. R., Ritchie, N. W. M., Scott, J. H. J., & Joy, D. C. (2018). *Scanning Electron Microscopy and X-ray Microanalysis*. Springer. <https://doi.org/10.1007/978-1-4939-6676-9>
- Griffin, W. L. (2017). *Thin Section Preparation for Petrology*. Geological Society of London.
- Jenkins, R., & Snyder, R. L. (1996). *Introduction to X-ray Powder Diffractometry*. Wiley.
- Klein, C., & Dutrow, B. (2007). *Manual of Mineral Science* (23rd ed.). Wiley.
- Nesse, W. D. (2017). *Introduction to Optical Mineralogy* (4th ed.). Oxford University Press.
- Potts, P. J., & Webb, P. C. (1992). X-ray fluorescence spectrometry. *Journal of Geochemical Exploration*, 44(1–3), 251–296. [https://doi.org/10.1016/0375-6742\(92\)90051-Z](https://doi.org/10.1016/0375-6742(92)90051-Z)
- Winter, J. D. (2010). *Principles of Igneous and Metamorphic Petrology* (2nd ed.). Pearson.
- Yasuda, H., Shibata, T., & Watanabe, Y. (2020). Accuracy improvement of mineral identification by optical microscopy using machine learning. *Minerals*, 10(6), 556. <https://doi.org/10.3390/min10060556>
- Khaleque, A., Danyushevsky, L., Godel, B., & Belousov, I. (2022). Automated identification of minerals in reflected light microscopy using convolutional neural networks. *Computers & Geosciences*, 159, 105023. <https://doi.org/10.1016/j.cageo.2021.105023>
- Esteva, A., Kuprel, B., Novoa, R. A., et al. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 115–118. <https://doi.org/10.1038/nature21056>
- Goldstein, J. I., Newbury, D. E., Michael, J. R., et al. (2018). *Scanning Electron Microscopy and X-ray Microanalysis*. Springer.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hwang, J., Cho, Y., Kim, Y., & Kim, H. (2021). Deep learning-based automated mineral identification using optical microscopy images. *Minerals*, 11(2), 115. <https://doi.org/10.3390/min11020115>

- Jenkins, R., & Snyder, R. L. (1996). *Introduction to X-ray Powder Diffractometry*. Wiley.
- Kamlaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Khaleque, A., Danyushevsky, L., Godel, B., & Belousov, I. (2022). Automated identification of minerals in reflected light microscopy using convolutional neural networks. *Computers & Geosciences*, 159, 105023. <https://doi.org/10.1016/j.cageo.2021.105023>
- Friedman, G. M. (1965). Terminology of texture and fabric of sedimentary rocks. *Journal of Sedimentary Research*, 35(3), 643–655.
- Griffin, W. L. (2017). *Thin Section Preparation for Petrology*. Geological Society of London.
- Jenkins, R., & Snyder, R. L. (1996). *Introduction to X-ray Powder Diffractometry*. Wiley.
- Klein, C., & Dutrow, B. (2007). *Manual of Mineral Science* (23rd ed.). Wiley.
- Mackenzie, W. S., & Guilford, C. (1980). *Atlas of Rock-Forming Minerals in Thin Section*. Longman Scientific & Technical.
- Nesse, W. D. (2017). *Introduction to Optical Mineralogy* (4th ed.). Oxford University Press.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Khaleque, A., Danyushevsky, L., Godel, B., & Belousov, I. (2022). Automated identification of minerals in reflected light microscopy using convolutional neural networks. *Computers & Geosciences*, 159, 105023. <https://doi.org/10.1016/j.cageo.2021.105023>
- Klein, C., & Dutrow, B. (2007). *Manual of Mineral Science* (23rd ed.). Wiley.
- Mackenzie, W. S., & Guilford, C. (1980). *Atlas of Rock-Forming Minerals in Thin Section*. Longman.
- Nesse, W. D. (2017). *Introduction to Optical Mineralogy* (4th ed.). Oxford University Press.

- Winter, J. D. (2010). *Principles of Igneous and Metamorphic Petrology* (2nd ed.). Pearson.
- Foret, P., Kleiner, A., Mobahi, H., & Neyshabur, B. (2021). Sharpness-aware minimization for efficiently improving generalization. *International Conference on Learning Representations*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Ioffe, S., & Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *International Conference on Machine Learning*, 448–456.
- Keskar, N. S., et al. (2016). On large-batch training for deep learning: Generalization gap and sharp minima. *arXiv preprint arXiv:1609.04836*.
- Khaleque, A., Khademi, S., & Ramakrishnan, S. (2022). Deep learning-based petrographic mineral classification from thin section images. *Minerals*, 12(5), 623.
- Masters, D., & Luschi, C. (2018). Revisiting small batch training for deep neural networks. *arXiv preprint arXiv:1804.07612*.
- Prechelt, L. (1998). Early stopping — but when?. *Neural Networks: Tricks of the Trade*, 55–69.
- Smith, S. L., Kindermans, P. J., Ying, C., & Le, Q. V. (2017). Don't decay the learning rate, increase the batch size. *arXiv preprint arXiv:1711.00489*.

Anexos

Glosario.

Término	Definición
Lámina delgada	Preparación de una muestra de roca o mineral de aproximadamente 30 micras de espesor para su observación bajo un microscopio petrográfico.
Microscopio petrográfico	Instrumento óptico especializado para observar minerales en láminas delgadas usando luz polarizada.
Luz polarizada plana (PPL)	Tipo de iluminación en microscopía petrográfica donde la luz está polarizada en una sola dirección.
Luz polarizada cruzada (XPL)	Modo de observación en el microscopio petrográfico que utiliza dos polarizadores en direcciones perpendiculares.
Birrefringencia	Propiedad óptica de algunos minerales que hace que la luz se desdoble en dos rayos con diferentes velocidades al atravesarlos.
Relieve	Grado en el que un mineral parece sobresalir o hundirse respecto a otros en la misma sección delgada, relacionado con su índice de refracción.
Pleocroísmo	Cambio de color que presentan ciertos minerales cuando se observan desde diferentes direcciones bajo luz polarizada plana.
Ángulo de extinción	Ángulo entre una dirección cristalográfica y la posición en la que un mineral se oscurece bajo luz polarizada cruzada.

Término	Definición
Colores de interferencia	Colores observados en minerales birrefringentes bajo luz polarizada cruzada, producidos por la interferencia de la luz.
Índice de refracción	Medida de cómo la luz se propaga a través de un material en comparación con el vacío.
Mineralogía	Ciencia que estudia los minerales, incluyendo su composición, estructura y propiedades.
Petrografía	Disciplina que estudia las rocas y sus características a través de la observación microscópica y macroscópica.
Roca ígnea	Roca formada a partir del enfriamiento y solidificación del magma o lava.
Textura fanerítica	Textura de rocas ígneas con cristales visibles a simple vista.
Textura afanítica	Textura de rocas ígneas con cristales demasiado pequeños para ser vistos sin ayuda de un microscopio.
Serie de reacción de Bowen	Modelo que describe la secuencia de cristalización de minerales a partir de un magma en enfriamiento.
Clasificación QAPF	Esquema de clasificación modal para rocas ígneas basado en las proporciones de cuarzo (Q), feldespato alcalino (A), plagioclasa (P) y feldespatoideos (F).
Feldespato	Grupo de minerales tectosilicatos abundantes en la corteza terrestre, incluidos feldespatos alcalinos y plagioclasas.

Término	Definición
Cuarzo	Mineral compuesto de dióxido de silicio (SiO ₂), común en muchas rocas ígneas, metamórficas y sedimentarias.
Mica	Grupo de minerales filosilicatos caracterizados por su hábito laminar y exfoliación perfecta.
Plagioclasa	Serie de minerales feldespatos que varía de albita (rica en sodio) a anortita (rica en calcio).
Olivino	Mineral nesosilicato de alta temperatura común en rocas máficas y ultramáficas.
Piroxeno	Grupo de inosilicatos presentes en muchas rocas ígneas y metamórficas.
Anfíbol	Grupo de inosilicatos que incluye hornblenda, común en rocas ígneas intermedias y metamórficas.
Textura porfídica	Textura en la que grandes cristales (fenocristales) están inmersos en una matriz de grano más fino.
AI (Inteligencia Artificial)	Campo de la informática que desarrolla sistemas capaces de realizar tareas que requieren inteligencia humana.
Deep learning	Subcampo del aprendizaje automático que utiliza redes neuronales profundas para el procesamiento de datos complejos.
CNN (Red Neuronal Convolutiva)	Arquitectura de red neuronal diseñada para procesar datos con estructura de rejilla, como imágenes.
VGG16	Arquitectura de red neuronal convolutiva con 16 capas desarrollada por el Visual Geometry Group de la Universidad de Oxford.

Término	Definición
ResNet50	Arquitectura de red neuronal convolucional con 50 capas y bloques residuales para evitar el desvanecimiento del gradiente.
Batch size	Número de muestras procesadas antes de que el modelo actualice sus parámetros durante el entrenamiento.
Overfitting	Fenómeno donde un modelo se ajusta demasiado a los datos de entrenamiento y pierde capacidad de generalización.
EarlyStopping	Técnica de entrenamiento que detiene el proceso si no hay mejora en la métrica de validación.
ModelCheckpoint	Método que guarda el modelo entrenado en su mejor estado durante el entrenamiento.
ReduceLROnPlateau	Técnica que reduce la tasa de aprendizaje cuando una métrica de validación deja de mejorar.
GPU	Unidad de Procesamiento Gráfico utilizada para acelerar el entrenamiento de modelos de deep learning.
Preprocesamiento de imágenes	Conjunto de técnicas aplicadas para mejorar la calidad de las imágenes antes de su análisis.
Segmentación de imágenes	Proceso de dividir una imagen en partes o regiones para facilitar su análisis.
Clasificación de imágenes	Tarea de asignar una etiqueta a una imagen en función de su contenido.
Generalización del modelo	Capacidad de un modelo para mantener un buen desempeño con datos no vistos previamente.