

UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERÍA
CARRERA DE INGENIERÍA PETROLERA



**DESARROLLO DE UN PROGRAMA PARA LA
IDENTIFICACIÓN DE SECCIONES PETROGRÁFICAS
MEDIANTE LA IMPLEMENTACIÓN DE REDES
NEURONALES CONVOLUCIONALES**

Proyecto de Grado presentada para la obtención del Grado de Licenciatura

POR: MARÍA FERNANDA ZENTENO CASTILLO

TUTOR: ING. PEDRO REYNALDO MARÍN DOMÍNGUEZ

LA PAZ - BOLIVIA
2024



**UNIVERSIDAD MAYOR DE SAN ANDRÉS
FACULTAD DE INGENIERIA**



LA FACULTAD DE INGENIERIA DE LA UNIVERSIDAD MAYOR DE SAN ANDRÉS AUTORIZA EL USO DE LA INFORMACIÓN CONTENIDA EN ESTE DOCUMENTO SI LOS PROPÓSITOS SON ESTRICTAMENTE ACADÉMICOS.

LICENCIA DE USO

El usuario está autorizado a:

- a) Visualizar el documento mediante el uso de un ordenador o dispositivo móvil.
- b) Copiar, almacenar o imprimir si ha de ser de uso exclusivamente personal y privado.
- c) Copiar textualmente parte(s) de su contenido mencionando la fuente y/o haciendo la cita o referencia correspondiente en apego a las normas de redacción e investigación.

El usuario no puede publicar, distribuir o realizar emisión o exhibición alguna de este material, sin la autorización correspondiente.

TODOS LOS DERECHOS RESERVADOS. EL USO NO AUTORIZADO DE LOS CONTENIDOS PUBLICADOS EN ESTE SITIO DERIVARA EN EL INICIO DE ACCIONES LEGALES CONTEMPLADAS EN LA LEY DE DERECHOS DE AUTOR.

DEDICATORIA

A mis padres, Exalta Graciela Castillo Ticona y Mario Rufino Zenteno Villca y a mi hermano Ronald Remberto Zenteno Castillo, por su amor incondicional, apoyo constante y sacrificio a lo largo de mi carrera académica. Sin su aliento y orientación, este logro no habría sido posible.

Este proyecto de grado está dedicado a todos ustedes, cuyo apoyo y aliento han sido pilares fundamentales en mi viaje académico.

AGRADECIMIENTO

Quiero expresar mi sincero agradecimiento a las siguientes personas e instituciones que han desempeñado un papel fundamental en la realización de este proyecto de grado:

A mis padres, Exalta Graciela Castillo Ticona y Mario Rufino Zenteno Villca, por su apoyo constante a lo largo de mi carrera universitaria y sus palabras de aliento en momentos difíciles en la misma. Sin su apoyo incondicional el camino para concluir mi carrera universitaria hubiera sido más complicada y larga. A mi hermano Ronald Remberto Zenteno Castillo, por sus consejos y apoyo en mi toma de decisiones al transcurso del desarrollo de este proyecto.

A mi asesor de proyecto de grado, Ing. Pedro Reynaldo Marín Domínguez, por su dedicación, orientación experta y paciencia a lo largo de este proceso. Su apoyo y consejos fueron invaluable.

Al Geólogo Jaime Álvaro Choque Sansute, por su guía en el proceso de clasificación de muestras de roca y por haber compartido conmigo su gran experiencia profesional.

A mis amigos y compañeros de carrera, quienes estuvieron siempre dispuestos a escucharme, brindándome su ánimo y aliento en los momentos de desafío y compartiendo conmigo las alegrías de los logros alcanzados, con sus discusiones, intercambios de ideas y amistad hicieron que este viaje fuera memorable.

A la Universidad Mayor de San Andrés, por proporcionar el entorno y los recursos necesarios para la realización de esta investigación y mi formación académica en general.

A todos los catedráticos, ingenieros, licenciados y técnicos que compartieron su conocimiento y experiencia conmigo, contribuyendo de manera significativa a mi crecimiento académico y personal.

A cualquier otra persona o entidad que haya aportado de alguna manera a este proyecto, incluso si no se menciona específicamente aquí, su contribución es apreciada.

ÍNDICE

1 DEDICATORIA	I
2 AGRADECIMIENTO	II
3 ÍNDICE.....	IV
4 ÍNDICE DE FIGURAS.....	VIII
5 ÍNDICE DE TABLAS	IX
6 RESUMEN EJECUTIVO	1
1 CAPITULO 1 - GENERALIDADES	3
1.1 INTRODUCCIÓN.....	3
1.2 ANTECEDENTES	4
1.3 PLANTEAMIENTO DEL PROBLEMA	6
<i>1.3.1 IDENTIFICACIÓN DEL PROBLEMA.....</i>	<i>6</i>
<i>1.3.2 FORMULACIÓN DEL PROBLEMA.....</i>	<i>6</i>
1.4 OBJETIVOS.....	7
<i>1.4.1 OBJETIVO GENERAL</i>	<i>7</i>
<i>1.4.2 OBJETIVOS ESPECÍFICOS</i>	<i>7</i>
1.5 JUSTIFICACIÓN.....	7
<i>1.5.1 JUSTIFICACIÓN TÉCNICA</i>	<i>7</i>
<i>1.5.2 JUSTIFICACIÓN SOCIAL</i>	<i>8</i>
<i>1.5.3 JUSTIFICACIÓN ECONÓMICA</i>	<i>9</i>
1.6 ALCANCE	10
<i>1.6.1 ALCANCE TEMÁTICO</i>	<i>10</i>
2 CAPITULO 2 – PETROGRAFÍA.....	12
2.1 PETROGRAFÍA	12

2.1.1 PETROGRAFÍA MACROSCÓPICA.....	13
2.1.2 PETROGRAFÍA MICROSCÓPICA.....	14
2.1.2.1 Sección Delgada.....	14
2.1.2.2 Microscopio Petrográfico.....	15
2.2 CLASIFICACIÓN DE ROCAS.....	16
2.2.1 ROCAS SEDIMENTARIAS.....	16
2.2.1.1 Rocas Sedimentarias Químicas	17
a) Caliza.....	17
b) Dolomía.....	17
c) Rocas Silíceas.....	18
d) Evaporitas.....	18
e) Carbón.....	18
2.2.1.2 Rocas Sedimentarias Detríticas	19
a) Lutita	19
b) Arenisca.....	20
c) Conglomerado y Brecha	22
d) Minerales Petrográficos.....	22
e) Micas	22
f) Moscovita.....	22
g) Biotita.....	22
2.2.2 ROCAS ÍGNEAS.....	23
2.2.3 ROCAS METAMÓRFICAS.....	23
2.3 COMPOSICIÓN DE LAS ROCAS	24
2.3.1 Composición Química	24
2.3.2 Composición Mineralógica	25
2.3.3 Composición Modal.....	25
2.4 PETROGRAFÍA DE ROCAS	25
2.4.1 ROCAS DETRÍTICAS TERRÍGENAS.....	25

2.4.1.1 Cuarzo (SiO ₂).....	28
2.4.1.2 Feldespato	29
2.4.1.3 Fragmentos de roca	30
2.4.1.4 Micas.....	31
2.4.1.1 Clorita	31
2.4.1.2 Glauconita.....	33
2.4.1.3 Arenitas, matriz y cemento	34
2.4.1.4 Cuarzo arenita, arcosa	34
2.4.1.5 Litarenitas	35
2.4.1.6 Oolitos.....	36
2.4.1.7 Peloides e Intraclastos	37
3 CAPITULO 3 – INTELIGENCIA ARTIFICIAL.....	39
3.1 INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL	39
3.1.1 ¿QUÉ ES UNA RED NEURONAL?	41
3.1.2 REDES NEURONALES CONVOLUCIONALES.....	42
3.2 MATLAB	44
3.3 C++.....	45
3.4 JAVA.....	46
3.4.1 USOS DE JAVA.....	46
3.4.1.1 Desarrollo de videojuegos.....	46
3.4.1.2 Computación en la nube.....	46
3.4.1.3 Macrodatos.....	47
3.4.1.4 Inteligencia artificial	47
3.4.1.5 Internet de las cosas (IoT)	47
3.5 PYTHON.....	47
3.5.1 BIBLIOTECAS DE PYTHON	48
3.5.1.1 Librerías de Python con la Ciencia de Datos.....	49
4 CAPITULO 4 – DESARROLLO DEL PROGRAMA APLICATIVO A PETROGRAFÍA	51

4.1 IDENTIFICACIÓN DEL LENGUAJE DE PROGRAMACIÓN	51
4.2 RECOPIACIÓN DE DATA BASE	55
4.2.1 CATEGORÍAS SELECCIONADAS PARA LA CLASIFICACIÓN Y DETECCIÓN	56
4.2.2 ETIQUETADO DE IMÁGENES.....	57
4.2.3 FUENTES DE IMÁGENES PARA LA DATA BASE.....	60
4.3 DESARROLLO Y DISEÑO DE LA RED CONVOLUCIONAL.....	62
4.3.1 CLASIFICADOR DE TIPO DE ROCA.....	63
4.3.2 DETECTOR DE CARACTERÍSTICAS DE SECCIONES PETROGRÁFICAS	64
4.3.3 INTERFAZ.....	66
4.4 VALIDACIÓN DEL PROGRAMA	67
4.4.1 VALIDACIÓN INTERNA DEL PROGRAMA	67
4.4.2 VALIDACIÓN CON DATOS DE LABORATORIO	69
4.5 ANÁLISIS DE RESULTADOS DEL PROGRAMA	73
5 CAPITULO 5 – ANÁLISIS DE COSTOS	76
5.1 ANÁLISIS DE VIABILIDAD ECONÓMICA.....	76
5.1.1 CALCULO DEL PRECIO DEL PROGRAMA DE IDENTIFICACIÓN DE SECCIONES PETROGRÁFICAS.....	77
6 CAPITULO 6 – CONCLUSIONES Y RECOMENDACIONES	83
6.1 CONCLUSIONES.....	83
6.2 RECOMENDACIONES	85
7 BIBLIOGRAFÍA	87
8 ANEXOS.....	90

ÍNDICE DE FIGURAS

Figura 1: Microscopio Petrográfico.....	16
Figura 2: Categorías de redondez de granos con baja y alta esfericidad, según Pettijhon y cols., 1973.....	27
Figura 3: Fotografías microscópicas de lámina delgada de Cuarzo	28
Figura 4: Fotografías microscópicas de lámina delgada de conglomerado.....	30
Figura 5: Fotografía microscópica de Fragmentos de Roca.....	31
Figura 6: Micas en una sección delgada.....	32
Figura 7: Sección delgada de Clorita.....	32
Figura 8: Sección delgada de Folkestone	33
Figura 9: Fotografías de secciones petrográficas	34
Figura 10: Sección delgada de arenita cuarcítica	35
Figura 11: Sección petrográfica de litarenita.....	36
Figura 12: Fotografías microscópicas de ooides	37
Figura 13: Fotografías microscópicas de peloides e intraclastos	38
Figura 14: La estructura habitual y básica de una red neuronal	42
Figura 15: Esquema matricial de red neuronal convolucional	43
Figura 16: Ejemplo de etiquetado semi automático	59
Figura 17: Registro de colección de mineralogía y petrología de BGS	61
Figura 18: Alta calidad de fotografías de secciones petrográficas	62
Figura 19: Interfaz del identificador de secciones petrográficas desarrollado	66
Figura 20: Parte de salida del clasificador.....	68
Figura 21: Muestras seleccionadas para laboratorio	70

Figura 22: Micro vetilla de Esparita	72
Figura 23: Fotografía de cristales de Muscovita	72
Figura 24: Microfósiles de foraminíferos y Oolitos	73

ÍNDICE DE TABLAS

Tabla 1: Clasificación de rocas detríticas según el tamaño del clasto	19
Tabla 2: Madurez Textural	21
Tabla 3: Rocas Ígneas y su clasificación	23
Tabla 4: Clasificación de rocas metamórficas comunes	24
Tabla 5: Clasificación granulométrica de las rocas sedimentarias y sedimentos detríticos	26
Tabla 6: Tabla comparativa de lenguajes de programación	52
Tabla 7: Rocas seleccionadas para la identificación	56
Tabla 8: Minerales y microfósiles seleccionados para la detección	57
Tabla 9: Coordenadas de punto de muestreo de las rocas seleccionadas	69
Tabla 10: Resultados de laboratorio de las muestras seleccionadas	70
Tabla 11: Resultados obtenidos con el programa desarrollado	71
Tabla 12: Tabla comparativa de resultados	74
Tabla 13: Valores de constantes	78
Tabla 14: Análisis del costo	80

RESUMEN EJECUTIVO

A la vista que la inteligencia artificial está cada vez más presente en las diferentes áreas de estudio, se hace necesaria la implementación de esta innovación en la industria y más el desarrollo del Machine Learning en base a redes neuronales, debido a la capacidad para realizar tareas en el procesamiento de información con un alto grado de precisión y eficiencia.

El presente proyecto contempla el desarrollo de una red neuronal convolucional que estandariza el proceso de identificación, minimizando los sesgos humanos y mejorando la reproducibilidad de los resultados.

Identificando que Python y sus bibliotecas son la mejor opción para el desarrollo de este programa, se procedió a la recopilación de fotografías de alta calidad de secciones petrográficas llegando a crear una database con más de 30 categorías en total y se realizó su respectivo etiquetado. Adecuando el tipo de etiquetado a cada uno de los requerimientos para las fases del programa, utilizándose tanto un etiquetado manual como uno semiautomático. Posteriormente se realizó la codificación del programa, identificando dos fases de desarrollo la primera para clasificación con el objetivo de tener el nombre del tipo de roca representativa de cada sección petrográfica y la segunda para un detector de las características mineralógicas y/o micro fosilíferas principales de cada sección petrográfica.

Una vez que el programa fue ejecutado, se procedió a validar sus resultados a través de la comparación entre los datos generados por el programa y los informes proporcionados por el Instituto de Investigaciones Geológicas y Medio Ambiente de la Universidad Mayor de San Andrés. Este análisis reveló un alto grado de concordancia y precisión entre las salidas del programa desarrollado y las evaluaciones realizadas en el laboratorio. Esta sólida validación respalda la eficacia del programa en la identificación de secciones geológicas, lo que sugiere un potencial

sumamente significativo en aplicaciones prácticas. La capacidad de automatización y la precisión en la identificación de secciones petrográficas se destacan como atributos esenciales que hacen de este sistema una herramienta valiosa en diversas áreas donde se requiere una identificación precisa y confiable.

PALABRAS CLAVE:

Inteligencia Artificial, Redes Neuronales Convolucionales, Precisión, Secciones Petrográficas y Descripción Microscópica.

CAPITULO 1 - GENERALIDADES

1.1 INTRODUCCIÓN

La identificación y análisis de secciones petrográficas constituyen una parte esencial en la caracterización de las propiedades geológicas y mineralógicas de las muestras. Este proceso, fundamental en la investigación geológica y en la industria de la exploración de recursos naturales, tradicionalmente ha dependido de la experiencia y pericia de geólogos y especialistas en mineralogía. Sin embargo, en la era de la informática y la inteligencia artificial, surge la oportunidad de transformar y agilizar este proceso mediante la aplicación de tecnologías avanzadas.

En este contexto, el presente proyecto se centra en el desarrollo de un programa para la identificación de secciones petrográficas, empleando redes neuronales convolucionales (CNNs) como la piedra angular de esta investigación. Las redes neuronales convolucionales han demostrado su capacidad para realizar tareas de procesamiento de imágenes con un alto grado de precisión y eficiencia. Este enfoque permitirá no solo agilizar el análisis de muestras, sino también estandarizar y objetivizar el proceso de identificación, minimizando la influencia de sesgos humanos y mejorando la reproducibilidad de los resultados.

El sistema propuesto no se limitará únicamente a la identificación automatizada, sino que también se realizará un proceso de validación mediante la comparación de los resultados del programa con resultados de laboratorio. Esto asegurará la confiabilidad y precisión de las descripciones realizadas por el sistema, al comparar los resultados automatizados con las observaciones y mediciones obtenidas a través de métodos tradicionales de análisis de láminas delgadas.

A lo largo de este proyecto, se explorarán las principales dificultades y desafíos que los

profesionales enfrentan en la identificación manual de secciones petrográficas. Además, se establecerán los objetivos clave del proyecto, que van desde la investigación y desarrollo de la arquitectura CNN hasta la implementación del sistema completo y su validación con resultados de muestras evaluadas en laboratorio.

El resultado de este proyecto no solo contribuirá al campo de la ingeniería petrolera, la geología y la mineralogía, sino que también abrirá nuevas vías para la integración de la inteligencia artificial en disciplinas científicas y técnicas, promoviendo avances significativos en la eficiencia y precisión de los análisis geológicos.

1.2 ANTECEDENTES

En 1943, Warren S. McCulloch y Walter Pitts publicaron "A Logical Calculus of Ideas Immanent in Nervous Activity", donde validaron la comparación de las neuronas en el cerebro humano con umbrales binarios de lógica booleana. Posteriormente, en 1958, Frank Rosenblatt profundizó en esta investigación, logrando que una computadora aprendiera a diferenciar entre cartas marcadas en la parte superior derecha y otras marcadas en la parte superior izquierda (IBM, 2021).

Paul Werbos, en su tesis doctoral de 1974, realizó la primera implementación de redes neuronales en una investigación, sentando las bases para el desarrollo de esta área (IBM, 2021).

En los últimos años, las redes neuronales convolucionales han demostrado su eficacia en tareas de procesamiento de imágenes y reconocimiento de patrones en diversos campos. En mineralogía y geología, se han aplicado con éxito para identificar y clasificar minerales en imágenes macroscópicas y microscópicas, lo que sugiere su potencial en la descripción de secciones petrográficas.

La geología y la exploración de recursos naturales han adoptado gradualmente tecnologías automatizadas para mejorar la eficiencia y precisión. Esto incluye la automatización de procesos de muestreo, análisis químico y geofísico. La identificación y descripción automatizada de secciones petrográficas se ajusta a esta tendencia hacia la automatización en el campo geológico.

Además, la aplicación de técnicas de procesamiento de imágenes para el análisis de datos geológicos ha ido en aumento. Las imágenes geológicas, incluidas las láminas delgadas, se han sometido a análisis de textura y reconocimiento de patrones para extraer información mineralógica y estructural.

Los estudios han documentado los desafíos y limitaciones de la identificación y descripción manual de minerales y texturas en secciones petrográficas, incluida la variabilidad en la interpretación y la ambigüedad visual. Estos desafíos subrayan la necesidad de enfoques más objetivos y automatizados.

Las redes neuronales convolucionales han logrado resultados destacados en diversas aplicaciones de procesamiento de imágenes, como el reconocimiento de objetos, segmentación y clasificación. Su capacidad para capturar características y patrones visuales complejos podría ser beneficiosa en la identificación de características en secciones petrográficas. Varias disciplinas científicas han experimentado avances en la automatización, incluyendo métodos para analizar datos complejos y realizar tareas repetitivas de manera eficiente. La geología puede beneficiarse de estas innovaciones al aplicar enfoques similares en el análisis de muestras geológicas. La integración de tecnologías de vanguardia en geología, como análisis remotos y sistemas de información geográfica (SIG), ha sido un enfoque creciente para obtener información precisa y actualizada. La identificación automatizada de secciones petrográficas o también llamadas láminas delgadas se alinea con esta tendencia de incorporar tecnología avanzada en la industria.

1.3 PLANTEAMIENTO DEL PROBLEMA

1.3.1 IDENTIFICACIÓN DEL PROBLEMA

La identificación de láminas delgadas de muestras de rocas, para empresas, instituciones y/o universidades que trabajan o realizan investigación en base a muestras geológicas, desempeña un papel fundamental en la exploración de recursos naturales, la investigación geológica y la evaluación de la historia geológica en regiones de estudio, este procedimiento es tradicionalmente realizado por expertos que enfrentan desafíos significativos que limitan su eficacia y objetividad.

Debido a que la interpretación manual está sujeta a la experiencia y subjetividad del analista, puede dar lugar a diferencias en la descripción entre diferentes profesionales e incluso entre análisis repetidos realizados por el mismo analista de laboratorio. Añadiendo la ambigüedad visual debido a que la examinación requiere minuciosidad en cada área de la lámina delgada, lo que conlleva a fatiga visual y potencialmente, a errores en la descripción. Además, que debido a la examinación detallada el procedimiento puede consumir mucho tiempo, limitando así la cantidad de muestras que un profesional puede determinar en un periodo determinado.

Por lo tanto, el problema se presenta claramente: la interpretación manual de láminas delgadas de rocas es susceptible a variabilidad, subjetividad y errores humanos que limitan la confiabilidad y la eficiencia de los resultados.

1.3.2 FORMULACIÓN DEL PROBLEMA

Será posible que la implementación de redes neuronales convolucionales asista la identificación de secciones petrográficas de manera que se pueda superar las limitaciones y proporcionar una identificación más precisa, objetiva y eficiente en laminas delgadas de rocas.

Será posible reunir y preparar un conjunto de datos de secciones petrográficas que sea representativo y útil para que el entrenamiento de la red neuronal sea capaz de describir y clasificar características petrográficas con precisión y eficiencia.

1.4 OBJETIVOS

1.4.1 OBJETIVO GENERAL

Desarrollar un programa para la identificación de secciones petrográficas mediante la implementación de redes neuronales convolucionales.

1.4.2 OBJETIVOS ESPECÍFICOS

- Identificar el lenguaje de programación adecuado para el desarrollo del programa de aprendizaje automático.
- Recopilar y preparar la base de datos de imágenes de secciones petrográficas con anotaciones precisas.
- Diseñar y desarrollar una arquitectura de red convolucional (CNN) adecuada para el procesamiento de imágenes de secciones petrográficas.
- Realizar la validación del rendimiento del programa mediante la comparación con resultados emitidos por un laboratorio.

1.5 JUSTIFICACIÓN

1.5.1 JUSTIFICACIÓN TÉCNICA

Desde un enfoque en el avance de la tecnología el desarrollo de un programa de identificación automática de láminas delgadas en base a redes neuronales convolucionales

representa un avance tecnológico significativo en el campo de la ingeniería y geología, implementando la inteligencia artificial en la identificación de muestras geológicas se mejora la precisión y eficacia del proceso.

Automatizar el procedimiento reducirá la influencia de sesgos humanos y errores subjetivos en el proceso de identificación una vez más conduciendo a resultados más precisos y consistentes.

Finalmente, la automatización también permitirá analizar un mayor número de láminas delgadas en un tiempo menor en comparación con el enfoque manual. Esto es especialmente relevante en procesos de investigación y explotación de recursos naturales donde el análisis de un gran número de muestras es esencial.

1.5.2 JUSTIFICACIÓN SOCIAL

La implementación de un sistema automatizado de identificación de secciones petrográficas mediante redes neuronales convolucionales no solo tiene un impacto en la eficiencia del proceso, sino que también contribuye significativamente a la salud y bienestar de los analistas de laboratorio. La labor de identificación manual en microscopía puede ser intensiva y demandante en términos visuales y cognitivos, lo que puede tener consecuencias para la salud de los profesionales involucrados. En este sentido, la automatización ofrece beneficios directos para la salud laboral de los analistas: Reduce la Fatiga visual y mental, previene problemas de ergonomía, permite un mayor enfoque en el análisis interpretativo de resultados mejorando así la calidad de trabajo y reduciendo el estrés asociado con la carga de trabajo intensiva y repetitiva.

También se debe resaltar que el desarrollo del programa puede hacer el análisis de muestras geológicas más accesible a un rango amplio de profesionales y/o estudiantes fomentando la colaboración interdisciplinaria y aumentar la comprensión de la geología en diversas áreas de

investigación científica.

1.5.3 JUSTIFICACIÓN ECONÓMICA

En la industria de la exploración de recursos naturales, la identificación precisa y rápida de la composición de las muestras geológicas es esencial para tomar decisiones informadas sobre la viabilidad y el potencial de un yacimiento. La automatización de la identificación de secciones petrográficas mediante redes neuronales convolucionales puede tener un impacto significativo en la eficiencia de este proceso, ofreciendo beneficios notables para la exploración de recursos.

La identificación manual de minerales y texturas es una tarea que requiere tiempo, ya que implica el análisis detenido de cada área de la lámina. La automatización permite procesar múltiples láminas en paralelo y en un tiempo considerablemente menor en comparación con el enfoque manual. Esto acelera el proceso de identificación, lo que es crucial en proyectos de exploración que involucran la evaluación de un gran número de muestras. Además, en la exploración de recursos, el tiempo es un factor crítico. Las decisiones sobre la inversión en un yacimiento o la planificación de operaciones dependen de la comprensión temprana de la composición mineralógica. La automatización permite obtener resultados rápidos y precisos, lo que permite a los equipos de exploración tomar decisiones informadas de manera más rápida y eficiente.

Por último, la automatización de procesos de exploración y análisis puede otorgar a las empresas una ventaja competitiva al acelerar la toma de decisiones y aumentar la precisión. Esto es especialmente relevante en un entorno empresarial donde la rapidez y la eficiencia son factores clave para ganar licitaciones.

1.6 ALCANCE

1.6.1 ALCANCE TEMÁTICO

Para conseguir los objetivos del presente proyecto de grado se utilizará la siguiente metodología, teniendo seis fases:

1RA FASE: Investigación Preliminar

Se realizará una investigación exhaustiva sobre técnicas de procesamiento de imágenes, redes neuronales convolucionales y métodos tradicionales de identificación de láminas delgadas de roca, analizando las dificultades y desafíos comunes durante la identificación manual de secciones delgadas de rocas.

2DA FASE: Desarrollo de la Arquitectura de la CNN:

Se desarrollará el diseño y configuración adecuada de una arquitectura de CNNs implementando la más adecuada para la tarea de identificación.

3RA FASE: Construcción y Anotación del Conjunto de Datos:

Se procederá a la recopilación y preparación de la data base con imágenes representativas de láminas o secciones delgadas de rocas con sus correspondientes etiquetas de identificación, también se realizará la clasificación del conjunto de base de datos para el entrenamiento, validación y prueba.

4TA FASE: Implementación del programa:

Se diseñará una interfaz de usuario interactiva e intuitiva para facilitar la interacción y visualización de resultados junto con el desarrollo del software que permita a los usuarios cargar


imágenes de láminas delgadas y recibir resultados de identificación generados por la red neuronal.

5TA FASE: Entrenamiento y Evaluación del Modelo:

Se llevará a cabo el entrenamiento del modelo CNN utilizando el conjunto de datos de entrenamiento y prueba. Corroborando el nivel de precisión del programa mediante la selección de un subconjunto de imágenes para su evaluación.

6TA FASE: Validación del programa:

De las muestras recolectadas de una campaña geológica se escogerá tres muestras representativas de una zona seleccionada que se mandaran al laboratorio del Instituto de Investigaciones Geológicas y Medio Ambiente de la Universidad Mayor de San Andrés. Realizando el análisis de laboratorio tradicional para comparar y validar las identificaciones generadas por el sistema automatizado.



CAPITULO 2 – PETROGRAFÍA

2.1 PETROGRAFÍA

La petrografía es el área encargada de la descripción y clasificación de rocas por medio de la observación microscópica de secciones petrográficas o también denominadas laminas delgadas que son extraídas de la roca de estudio. Este tipo de análisis da como resultado una serie de características evaluables los que ayuda a determinar la composición de la roca (Servicio Geologico Mexicano, 2017).

Al ser una roca la agrupación de minerales las cuales corresponden a ciertas condiciones de formación y a través de los minerales se pueden estudiar dichas condiciones, como por ejemplo las propiedades ópticas cuando la luz polarizada pasa o se refleja sobre ellos, lo que también es conocido como mineralogía Óptica (Servicio Geologico Mexicano, 2017).

Siendo el grupo denominado petrográficos el conjunto de minerales que desempeñan un papel fundamental en la formación de la roca teniendo como ejemplos a los silicatos, carbonatos, sulfatos, sulfuros, cloruros, fosfatos, óxidos e hidróxidos. También se debe considerar que de todos los elementos que forman a la roca, los principales a considerar son los componentes primarios que son los que le dan el nombre a la roca presentándose de manera constante y seguidamente se debe considerar a los componentes accidentales o también denominados accesorios siendo su presencia no fundamental para la clasificación de la roca debido a que son los minerales secundarios que se forman a consecuencia de la transformación o alteración de los minerales primarios (Servicio Geologico Mexicano, 2017).

Si el análisis macroscópico o megascopico, realizado por medio de una lupa o a simple vista, de los afloramientos o rocas proporciona información, el análisis microscópico proporciona datos

más precisos, debido a esto para el estudio petrográfico se necesita el empleo de un microscopio, siendo también como estudios complementarios los rayos X.

Según el Servicio Geológico Mexicano, el estudio petrográfico requiere un examen físico de la roca, conocido también como descripción macroscópica o megascopico, este examen nos otorga información acerca del color, textura, aspecto dureza, tamaño del grano o granulosidad de la roca. Saliendo a colación dos términos: afinitas o afanítica y fanerítica. El primer término se refiere a que los constituyentes son tan pequeños que no se aprecian a simple vista y el segundo término se refiere a los componentes que se aprecian a siempre vista.

Después de las observaciones megascópicas se realiza una descripción microscópica. Una descripción microscópica consiste en determinar la composición mineralógica y los rasgos texturales, con lo que es posible obtener mucha información de donde se originó la roca; también se determina la forma y color de los cristales, tipo u origen de cada mineral (primarios o secundarios), la textura, la relación mutua entre los minerales y/o asociaciones minerales, así como la matriz o cementante en caso que esté presente. Cada tipo de roca tiene características microscópicas específicas muy importantes en una clasificación. Cabe señalar que ambos análisis en conjunto (megascópico y microscópico) brindan los parámetros necesarios para describir y clasificar acertadamente una roca.

2.1.1 PETROGRAFÍA MACROSCÓPICA

Para la clasificación de una roca, los geólogos realizan un análisis de las características y propiedades mediante unas herramientas básicas, como ser: lupa, lápiz de dureza, ácido clorhídrico del 10%, imán y un martillo de geólogo.

- **Lupa:** es utilizada para analizar y definir los minerales presentes en la muestra de

roca, la textura, el color, la meteorización y demás propiedades visuales en las rocas.

- **Lápiz de dureza:** define la dureza de Mohs de los minerales presentes en la roca.
- **Ácido Clorhídrico:** identifica la presencia de minerales de carbonatos.
- **Imán:** es utilizado para evidenciar minerales magnéticos.
- **Martillo cateador:** rompe las muestras de roca para analizarlas en superficie fresca.

2.1.2 PETROGRAFÍA MICROSCÓPICA

Esta técnica sirve para analizar las muestras de roca de la misma manera que en la técnica macroscópica, pero de manera más detallada. Debido al alto rango de visión se puede analizar propiedades más avanzadas como el clivaje, analizar las secciones delgadas en luz polarizada y luz normal, etc.

2.1.2.1 Sección Delgada

Una sección delgada es una lámina de roca de 30 micras de espesor que se elabora a partir de una muestra de roca. Las mismas sirven, en el estudio petrográfico, para determinar la mineralogía, las alteraciones y la composición de la muestra de roca (Adams, MacKenzie, & Guilford, Preparation of a thin section of a rock, 1984).

Estas preparaciones se las estudian con un microscopio petrográfico de alta calidad, las láminas delgadas son adheridas a láminas de vidrio por medio de una resina epoxi, posteriormente siendo cubiertas por un cubreobjetos. El grosor de la lámina se debe a la necesidad de que la luz atraviese la muestra (Adams, MacKenzie, & Guilford, Preparation of a thin section of a rock, 1984).

Cuando se analiza una lámina delgada la luz del microscopio una vez polarizada atraviesa la lámina de esta manera llegando al analizador y luego al observador para así conseguir la identificación de la muestra de roca.


Según el Servicio Geológico Mexicano (2021), en una roca el proceso incluye:

- **Corte:** la muestra de roca se corta con una sierra de punta de diamante para alcanzar una superficie plana.
- **Pulido:** posteriormente se pule el trozo de roca para eliminar las huellas que haya dejado el corte y así obtener un plano más suave.
- **Pegado:** se adhiere la superficie ya pulida sobre un portaobjetos hecho de vidrio con un cemento incoloro e isótropo.
- **Corte Final:** si es posible se recorta la muestra en el portaobjetos para obtener una rodaja más fina.
- **Desbaste:** para obtener una muestra de 30 micras de espesor se desbasta la misma.
- **Cubrimiento:** finalmente se lo coloca la muestra en un cubreobjetos y se procede a pegarlo con un cemento.

2.1.2.2 Microscopio Petrográfico

Este instrumento se emplea para analizar características y propiedades de una muestra de roca, se utiliza una luz polarizada entre la preparación y la fuente luminosa (Servicio Geológico Mexicano, 2017). Utilizando el analizador, luz polaroid perpendicular a la primera proyección de luz, se analiza otro tipo de características y propiedades de la misma muestra de roca. Dependiendo de las propiedades a analizar el tipo de iluminación cambiara. El microscopio petrográfico (Figura 1) puede analizar cristales de hasta 10 micras, para partículas de menor tamaño se utiliza técnicas sub microscópicas, como ser los microscopios electrónicos.

Figura 1: Microscopio Petrográfico



Nota. Tomado de Características del microscopio petrográfico, de María Piedad Franco y Juan Carlos Gonzalo, (2000)

2.2 CLASIFICACIÓN DE ROCAS

Tomando en consideración el origen de la roca se clasifican en tres tipos: Las rocas sedimentarias, las rocas ígneas y las rocas metamórficas (Bowen & Schairer, 1956).

2.2.1 ROCAS SEDIMENTARIAS

Las rocas sedimentarias son el resultado de los procesos meteorización mecánica y química, su nombre se debe al material que se deposita a partir de agentes de transporte como ser el agua o el aire. La mayoría de los sedimentos se deposita en los lagos, los valles, los ríos, los mares, entre otros, debido a que son transportados desde los lechos de roca por los conocidos agentes de

transporte (agua o aire). Debido a que este proceso es un ciclo la pila de sedimentos se acumulan y los materiales se compactan en el fondo, como resultado de periodos prolongados las partículas se cementan formando una roca sólida. En estos periodos de tiempo el sedimento experimenta grandes cambios hasta convertirse en roca sedimentaria para luego ser sometida a altas temperaturas y presiones convirtiéndose en una roca metamórfica (Tarbuck & Lutgens, 2005).

Debido a su naturaleza contienen indicadores de ambientes pasados, como ser fósiles, que son vitales para el estudio del pasado geológico.

Existen dos tipos de formación de rocas sedimentarias:

2.2.1.1 Rocas Sedimentarias Químicas

Según Tarbuck & Lutgens (2005), el material soluble se precipita mediante procesos orgánicos o inorgánicos, conociéndose como sedimento químico, este material no permanece disuelto en el agua de forma indefinida. Teniendo como ejemplos: Caliza, Dolomía, Rocas Silíceas (Silex), Evaporitas, carbón.

a) Caliza

Este tipo de roca representa el 10% de las rocas sedimentarias, es de las rocas sedimentarias químicas más abundantes. Compuesta por carbonato de calcio, tiene dos formas de origen, primero por medio de medios inorgánicos y segundo por medios bioquímicos. El tipo de origen más común es bioquímico marino (Tarbuck & Lutgens, 2005).

b) Dolomía

La mayoría de este tipo de roca se forma por el reemplazo del magnesio del agua de mar es reemplazada por el calcio de la caliza. De tiene mayor evidencia de rocas antiguas pertenecientes a este tipo de roca sedimentaria, debido a que en ese tiempo existió la sombra suficiente para que

el calcio fuera sustituido por el magnesio (Tarbuck & Lutgens, 2005).

c) Rocas Silíceas

También conocidas como Sílex, tiene como característica ser muy compactas y duras compuesta por sílice microcristalina. Existen dos formas de depósitos de rocas silíceas, como nódulos de forma irregular en la caliza y como capas de roca (Tarbuck & Lutgens, 2005).

d) Evaporitas

Como su nombre lo enuncia, la sedimentación de precipitados químicos también es desencadenada por la evaporación, con el paso del tiempo muchas de las partes anteriormente consideradas como cuencas ahora son tierras secas, estas antiguas cuencas se encontraban bajo niveles someros de un mar con estrechas conexiones con el océano abierto, por estas condiciones el agua de la bahía se saturada y se suscitaba el depósito de sal, denominándolos actualmente como evaporitas (Tarbuck & Lutgens, 2005).

e) Carbón

El carbón tiene como característica que se encuentra compuesto por materia orgánica, dándole una diferencia fundamental con las demás rocas sedimentarias químicas. La etapa inicial de su formación consiste en la acumulación de grandes cantidades de vegetales especialmente en un ambiente pantanoso para evitar la descomposición rápida de los vegetales expuestos a la atmósfera. Posteriormente la descomposición parcial de los restos vegetales en un ambiente pantanoso pobre de oxígeno genera una capa de turba, seguidamente la turba se convierte en lignito lentamente y simultáneamente el enterramiento incrementa la temperatura de los sedimentos generando reacciones químicas produciendo gases orgánicos y agua (Tarbuck & Lutgens, 2005).

2.2.1.2 Rocas Sedimentarias Detríticas

Se originan en depósitos detríticos, acumulación de material transportado en forma de clastos sólidos. Los componentes fundamentales de estas rocas son los minerales de arcilla y el cuarzo (Tarbuck & Lutgens, 2005).

La base fundamental para la distinción entre rocas sedimentarias detríticas es el tamaño del clasto. En la tabla 1 se puede observar una clasificación de acuerdo al tamaño de los clastos que constituyen las rocas detríticas.

Tabla 1: Clasificación de rocas detríticas según el tamaño del clasto

TAMAÑO (mm)	CLASTO	SEDIMENTO	ROCA DETRÍTICA
>256	Bloque	Grava	Conglomerado O Brecha
64-256			
4-64			
2-4	Canto		
1/16 - 2	Grano	Arena	Arenisca
1/256 – 1/16	Gránulo	Limo	Limolita
<1/256	Partícula	Arcilla	Lutita

Nota. Adaptado de Ciencias de la Tierra: Una introducción a la geología física, por Eduard J. Tarbuck (2005).

Las rocas sedimentarias detríticas comunes son la lutita, la arenisca y el conglomerado o brecha siendo mencionadas de acuerdo al tamaño del clasto en forma creciente.

a) Lutita

Según Tarbuck & Lutgens (2005), la Lutita es una roca sedimentaria compuesta por partículas del tamaño de la arcilla y limo, tiene como característica el grano fino, siendo estas tan

pequeñas que dificulta el estudio y análisis de esta roca en comparación con otras rocas sedimentarias. Tiene como origen la sedimentación gradual de sus partículas en corrientes turbulentas relativamente tranquilas.

Comúnmente la composición química de la roca proporciona información adicional, como ser la lutita negra debiendo su color a la abundancia de materia orgánica en su composición indicando de esta manera que la sedimentación se produjo en un ambiente predominantemente anaeróbico, provocando que los elementos orgánicos no se oxiden fácilmente y se descompongan.

La acumulación de limo y arcilla tienen a provocar la formación de capas delgadas denominadas láminas, inicialmente con una disposición desordenada que permite la acumulación de agua en el espacio poroso. Sin embargo, conforme la pila estratigráfica aumenta esta disposición cambia, alineándose así de forma paralela las partículas de arcilla y limo, reduciéndose el espacio poroso y expulsando el agua. La baja probabilidad de que el agua penetre los microscópicos espacios porosos de la roca ocasiona que la Lutita forme barreras al movimiento subsuperficial del petróleo y el agua. Cabe resaltar que las lutitas bituminosas son las que pueden convertirse en un recurso energético valioso, debido a que contienen enormes cantidades de petróleo sin explotar (Tucker, 2013).

b) Arenisca

Según Tarbuck & Lutgens (2005), las areniscas son rocas sedimentarias en las cuales predominan los clastos de tamaño de arenas, 1/16 - 2 milímetros, las areniscas tienen 5 componentes principales los cuales son el cuarzo, feldespato, fragmentos líticos, matriz y cemento, estas rocas también contienen fragmentos de compuestos orgánicos que se depositan junto con el sedimento detrítico, además de pistas significativas de su origen.

La forma de los granos arenosos nos indica cuál ha sido la historia de la arenisca, debido a que si los granos son muy redondeados es una evidencia de que los sedimentos fueron transportados por tiempos prolongados. En cambio, los granos arenosos muy angulosos son indicativos de un tiempo de transporte corto o de que fue transportado por otro agente de transporte aparte del agua o el viento, como por ejemplo glaciares (Tarbuck & Lutgens, 2005).

Según Tucker (2013), la clasificación de areniscas requiere la estimación de las proporciones de los tipos principales de grano y por lo tanto el estudio de la sección delgada es requerido. Existen dos tipos de madurez del sedimento, mineralógico y texturizado, los sedimentos maduros mineralógicamente son aquellos que contienen una alta proporción de minerales químicamente estables y físicamente más resistentes como el cuarzo, los sedimentos inmaduros mineralógicamente contienen menos granos estables como ser feldespatos. La madurez texturizada de un sedimento depende del contenido de material granulado fino, una escala de madurez textural es presentada por Folk (1951), descrita en la siguiente tabla 2:

Tabla 2: Madurez Textural

MADURACIÓN	CONTENIDO	GRANOS
ETAPA INMADURA	> 5% Matriz Arcilla	Mal ordenado y no bien redondeado
ETAPA SUB MADURA	<5% Matriz Arcilla	Mal ordenado y no bien redondeado
ETAPA MADURA	Poca O Sin Arcilla	Bien ordenado y no bien redondeado
ETAPA SÚPER MADURA	Sin Arcilla	Bien ordenado y bien redondeado

Nota. Elaboración propia, adaptado de Petrología, por Folk (1951).

c) Conglomerado y Brecha

En el caso de los conglomerados el tamaño de clasto puede variar desde grandes cantos redondeados hasta pequeños clastos comparados con el tamaño de los guisantes. Es debido a esto que es fácil de identificar los clastos de estos tipos de roca (Tarbuck & Lutgens, 2005).

d) Minerales Petrográficos

Los minerales petrográficos, también denominados silicatos, son minerales fundamentales de las rocas ígneas. Tenemos como ejemplos: el Cuarzo, Feldespatos alcalinos (potásicos), Feldespatos sódico- cálcicos (plagioclasas), micas (Moscovitas, biotita, flogopita), Hornblenda, Piroxenos y el Olivino (Castillo Garcia, Angamarca Lliguin, Ojeda Pardo, & Cuenca Gualan, 2021).

e) Micas

La exfoliación más sencilla y conocida es el realizado por las micas, debido a que las micas en una dirección tienen enlaces débiles se produce la exfoliación creando laminas planas y delgadas (Tarbuck & Lutgens, 2005).

f) Moscovita

Se encuentra en la clase de silicatos dentro del grupo de las micas, tiene como origen y ambiente geológico magmas ácidos enriquecidos de potasio. Se evidencia su presencia con láminas pequeñas y semitransparentes en rocas ígneas, es un indicador de metamorfismo en rocas metamórficas y como componente detrítico en rocas sedimentarias (Maldonado, 2021).

g) Biotita

De origen núcleo potásico y ambientes meso termal. Es un mineral que es característico de la formación en rocas ígneas. En determinados yacimientos de minerales se presenta como un mineral de alteración hidrotermal. Además, de estar presente en rocas metamórficas de grado

(Maldonado, 2021).

2.2.2 ROCAS ÍGNEAS

La mayoría de la corteza terrestre está compuesta por rocas ígneas. Su formación es conforme se enfrían y solidifican las rocas fundidas, si este fenómeno ocurre en la superficie se las clasifica como rocas ígneas extrusivas o volcánicas a diferencia de cuando el magma se enfría antes de alcanzar la superficie denominándose así rocas ígneas intrusivas o plutónicas (Tarbuck & Lutgens, 2005)

Por su composición química y su textura se muestra en la tabla 3:

Tabla 3: Rocas Ígneas y su clasificación

COMPOSICIÓN QUÍMICA	GRANÍTICA	ANDESÍTICA	BASÁLTICA	ULTRAMAFICA
Fanerítica	Granito	Diorita	Gabro	Periodita
Afanítica	Rolita	Andesita	Basalto	Komatita
Porfídica		Porfídico		
TEXTURA	Vítrea	Obsidiana		
		Pumita		Poco Comunes
	Piroclástica	Toba		
		Brecha Volcánica		

Nota. Adaptado de Ciencias de la Tierra: Una introducción a la geología física, por Eduard J. Tarbuck (2005).

2.2.3 ROCAS METAMÓRFICAS

La formación de las rocas metamórficas se da a partir de rocas ígneas, metamórficas y sedimentarias. Siendo el significado de metamorfismo el “cambio de forma” se denomina así a las

rocas que pasaron por un proceso de cambios en su mineralogía, textura y hasta su composición química (Tarbuck & Lutgens, 2005). Se puede apreciar los tipos de rocas en la tabla 4:

Tabla 4: Clasificación de rocas metamórficas comunes

NOMBRE DE LA ROCA	TEXTURA	TAMAÑO DE GRANO
Pizarra	Foliada	Muy Fino
Filita		Fino
Esquistos		Medio A Grueso
Gneis		Medio A Grueso
Migmatita		Medio A Grueso
Milonita	Poco Foliada	Fino
Meta Conglomerado		De Grano Grueso
Mármol	No Foliada	Medio A Grueso
Cuarcita		Medio A Grueso
Corneana		Fino
Antracita		Fino
Brecha De Falla		Medio A Muy Grueso

Nota. Adaptado de Ciencias de la Tierra: Una introducción a la geología física, por Eduard J. Tarbuck (2005).

2.3 COMPOSICIÓN DE LAS ROCAS

2.3.1 Composición Química

La identificación de la fuente de origen de una roca se logra mediante el análisis de su

composición química. Este proceso implica determinar el porcentaje en peso de los diversos elementos químicos que componen la roca en cuestión. Mediante este enfoque, se puede obtener una valiosa información sobre las condiciones geológicas y las fuerzas naturales que contribuyeron a la formación de la roca. La composición química proporciona pistas sobre la historia y evolución de la roca, permitiendo a los geólogos y científicos entender mejor los procesos geodinámicos que han dado forma a la corteza terrestre a lo largo del tiempo. De esta manera, el análisis químico de las rocas no solo revela su estructura interna, sino que también ofrece una ventana al pasado geológico, contribuyendo así a la comprensión más profunda de la historia de nuestro planeta. (Franco & Gonzalo, 2000).

2.3.2 Composición Mineralógica

Este tipo de composición incluye a los diferentes tipos de minerales y su composición química, debido a que los minerales que forman parte de la roca dependen de las condiciones de presión y temperatura a la cual fueron formadas o cuando fue su última transformación y de la composición química de la roca (Franco & Gonzalo, 2000).

2.3.3 Composición Modal

La composición modal es representada por el volumen de los minerales, granos u otros componentes que componen la roca. La moda sirve para clasificar y nombrar, distinguiendo a los diferentes tipos de roca de un mismo grupo. (Franco & Gonzalo, 2000)

2.4 PETROGRAFÍA DE ROCAS

2.4.1 ROCAS DETRÍTICAS TERRÍGENAS

Según la escala que propone J. A. Udden y Wentworth (Tabla 5) las rocas provenientes de

sedimentos detríticos terrígenos pueden clasificarse teniendo en cuenta su granulometría (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Tabla 5: Clasificación granulométrica de las rocas sedimentarias y sedimentos detríticos

DIÁMETRO LIMITE (EN MILÍMETROS DE LA CLASE)	DENOMINACIÓN DE LA CLASE	DENOMINACIÓN DE LA ROCA SEGÚN SU GRANULOMETRÍA	
256	Bloque	Rudita	
64	Bloque Pequeño	Conglomerado	
4	Canto	Brecha	
2	Canto Pequeño		
1	Arena Muy Gruesa	Arenita	
0.5 (1/2)	Arena Gruesa	Arenisca	
0.25 (1/4)	Arena	Arena	
0.125 (1/8)	Arena Fina		
0.0625 (1/16)	Arena Muy Fina		
0.0312 (1/32)	Limo Grueso	Limolita	Argilita
0.0156 (1/64)	Limo Medio		Lutita
0.0078 (1/128)	Limo Fino		Pelita
0.0039 (1/256)	Limo Muy Fino	Arcillita	

Nota. Adaptado de Atlas of sedimentary rocks under the microscope, por Adams, Mackenzie, & Guilford (1984).


Las limolitas gruesas, las arenitas, los conglomerados y brechas de grano más fino, teniendo

la denominación para este grupo de sedimentos terrígenos de grano intermedio, son las que tienen mejores resultados al realizar el estudio petrográfico bajo el microscopio. Se tiene como principales componentes de los granos a fragmentos de cuarzo, feldespato y de rocas. Además, el espacio entre los granos puede estar ocupada por una matriz original o por un cemento (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Como contraparte tenemos a las arcillas y las pizarras arcillosas que contienen tamaño de grano demasiado fino para un adecuado análisis bajo el microscopio petrográfico. Y su estudio se realiza preferentemente con un microscopio electrónico o mediante la difracción de rayos X.

En el caso de los conglomerados y brechas la identificación es de gran facilidad y se la realiza con una lupa, teniendo sobreentendido que para un estudio completo se requiere del estudio microscópico. Para la correcta descripción de las rocas sedimentarias a nivel microscópico se debe considerar la forma de los granos y por consiguiente su grado de redondez. Como se muestra en la Figura 2 en la cual se indican cinco tipos de redondez en granos de dos categorías de esfericidad (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Figura 2: Categorías de redondez de granos con baja y alta esfericidad, según Pettijhon y cols., 1973.




Nota. Tomado de Manual de prácticas de petrología sedimentaria, de Ulises Zeus Hernández T., (2017)

2.4.1.1 Cuarzo (SiO₂)

Según Adams, Mackenzie y Guilford (1984), es el mineral más abundante en las conocidas arenitas y conglomerados. Exceptuando el tamaño y forma de los granos individuales del mineral se requiere las siguientes características para obtener mayor información de su origen:

- Se puede determinar si los granos minerales son cristales individuales o si están conformados por múltiples cristales con diversas orientaciones.
- La uniformidad o la presencia de ondulaciones en la extinción de los minerales se puede observar.
- Se pueden identificar inclusiones en los minerales o determinar si están ausentes.
- En el caso de granos minerales policristalinos, se puede evaluar si los bordes de los cristales son lisos y sin fracturas o si muestran suturas.

Figura 3: Fotografías microscópicas de lámina delgada de Cuarzo



Nota: I) fotografía con luz polarizada sin analizador (LPNA) II) fotografía con luz polarizada y analizada (LPA). Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

2.4.1.2 Feldespato

Al igual que el cuarzo, los feldespatos son componentes importantes de arenitas y conglomerados. Existen dos tipos, siendo los feldespatos alcalinos más frecuentes en su aparición y poseen una mejor conservación que las plagioclasas cálcicas debido tanto a su resistencia a la alteración química como a que el origen de la gran mayoría de las rocas detríticas es a base de rocas graníticas o gnéicas que tienen como componente principal a feldespatos alcalinos. El feldespato al sufrir alteración química da lugar a la generación de micas secundarias y minerales arcillosos. Concluyendo así que la identificación de los feldespatos en microscopio es sencilla (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).


Debido a que las plagioclasas presentan las típicas maclas polisintéticas, la microlina suele presentar su enrejado característico y frecuentemente, pueden reconocerse entre la ortosa sin macla y el cuarzo puede ser difícil, pero en este caso, son útiles los criterios siguientes:

- En cuanto a la alteración, la ortosa tiende a experimentar cambios químicos que le dan tonos turbios y un aspecto de coloración rojiza o pardusca en luz polarizada no analizada, mientras que el cuarzo permanece claro y sin alteraciones.
- En lo que respecta al índice de refracción, el cuarzo tiene un índice muy cercano o ligeramente superior al del adhesivo de la lámina, mientras que la ortosa siempre presenta un índice de refracción inferior al adhesivo.
- En cuanto a las características ópticas, la ortosa es una mineral biáxico con un ángulo $2V$ moderado, mientras que el cuarzo es un mineral uniáxico, a menos que esté deformado, en cuyo caso podría mostrar propiedades biáxicas.

En la Figura 4 se muestra dos fotografías I y II, donde se identifica un grano grande de plagioclasa, siendo evidente por sus maclas polisintéticas (mostradas en la fotografía II).

Realizando un análisis más detallista se puede observar que esta plagioclasa muestra una combinación de una macla simple y una macla múltiple o polisintética. En la fotografía I, se evidencia un aspecto turbio debido a la alteración, dispuesta en parches irregulares en la muestra de plagioclasa. Se puede evidenciar que probablemente el mineral de alteración es una sericita.

Figura 4: Fotografías microscópicas de lámina delgada de conglomerado



Nota: I) fotografía con luz polarizada sin analizador (LPNA) II) fotografía con luz polarizada y analizada (LPA). Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

2.4.1.3 Fragmentos de roca


Según Adams, Mackenzie y Guilford (1984), otro componente importante de las rocas detríticas son los fragmentos de rocas y en especial las rocas metamórficas. En la Figura 5 se puede apreciar los fragmentos de roca que se encuentran encima del cuarzo, siendo constituidos por un grano fino, que no puede ser identificados a pesar de los aumentos que posee el microscopio. La roca está muy mal clasificada, es decir presenta una gran variedad de tamaños, además que consta de muchos fragmentos pequeños de roca, de granos de cuarzo y, al menos, una plagioclasa, así como el cristal grande de cuarzo que aparece en la fotografía.

También se debe aclarar que los fragmentos de rocas metamórficas de grano grueso son

con frecuencia esquistosos y en algunas ocasiones estos fragmentos llegan a ser clasificados como cuarzos esquistosos y no como fragmentos de rocas metamórficas.

Finalmente, se debe aclarar que los fragmentos de rocas, excepto los de sílex, son poco frecuentes en las rocas sedimentarias terrígenas, dado su disgregación en sus granos constituyentes.

Figura 5: Fotografía microscópica de Fragmentos de Roca



Nota: Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

2.4.1.4 Micas


Las micas pueden variar en color (figura 7), pero la moscovita tiende a ser incolora o de un color pálido, mientras que la biotita es generalmente más oscura, con tonos que van desde el marrón claro hasta el negro. La lepidolita puede ser de color rosa o lila. Las micas tienen un hábito cristalino característico de exfoliación, lo que significa que se pueden separar en láminas muy delgadas. Esto se debe a su estructura en capas (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

2.4.1.1 Clorita

Se refiere a un mineral del grupo de los filosilicatos que se encuentra en abundancia en


rocas sedimentarias. Puede encontrarse en pequeñas láminas de origen detrítico, comúnmente procedentes de rocas metamórficas de baja temperatura, o bien como resultado de la alteración de fragmentos de rocas volcánicas. Además, es posible hallarlo como un mineral autigénico que rellena los espacios porosos de las rocas (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984)

Figura 6: Micas en una sección delgada



Nota: Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

Figura 7: Sección delgada de Clorita




Nota: Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

2.4.1.2 Glauconita

Se trata de un aluminosilicato hidratado de hierro y potasio que se origina exclusivamente en entornos sedimentarios marinos, comúnmente en aguas poco profundas. Se presenta en forma general de pequeñas agrupaciones redondas llamadas pellets, compuestas por cristales diminutos. En la figura 8 se pueden observar múltiples pellets de glauconita en una arenisca de grano grueso. La glauconita se distingue con facilidad en las imágenes bajo luz polarizada no analizada (LPNA) debido a su tono de verde o azul verdoso. El grano ubicado en el centro de la parte superior de la imagen contiene numerosos cristales pequeños de cuarzo con tamaño similar al limo. La glauconita exhibe una birrefringencia moderada, pero en las imágenes con luz polarizada analizada (LPA), los colores de interferencia son opacados por el color natural del mineral. El resto de la roca está compuesto por granos de cuarzo monocristalinos, y en el rincón inferior derecho se aprecia un fragmento de roca sedimentaria. El cemento, que muestra colores de interferencia de alto orden, es calcita (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Figura 8: Sección delgada de Folkestone




Nota: I) fotografía con luz polarizada sin analizador (LPNA) II) fotografía con luz polarizada y analizada (LPA). Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

2.4.1.3 Arenitas, matriz y cemento

Durante la deposición, la mayoría de las arenitas tienen poca cantidad de sedimento matriz entre los granos. Sin embargo, en algunas rocas detríticas, puede haber cierta cantidad de lodo terrígeno depositado junto con los granos. Cuando la matriz de sedimento supera el 15%, se denomina grauwas. En casos excepcionales, algunas arenitas pueden tener una matriz de lodo carbonatado. En la figura 9 se muestran dos fotografías donde la roca contiene grandes granos de cuarzo redondeados y otros granos más pequeños, de subangulosos a subredondeados. Por lo tanto, la roca es una arenisca con una matriz de lodo carbonatado, que probablemente se depositó simultáneamente con los granos. El cemento es el proceso principal que contribuye a la reducción de la porosidad de las areniscas. (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Figura 9: Fotografías de secciones petrográficas




Nota: I) fotografía con luz polarizada sin analizador (LPNA) II) fotografía con luz polarizada y analizada (LPA). Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

2.4.1.4 Cuarzo arenita, arcosa

La figura 10 muestra una roca compuesta principalmente por cuarzo, la cual puede ser

clasificada como una cuarzoarenita. En clasificaciones anteriores, estas arenitas solían ser llamadas cuarcitas, aunque es más preciso reservar este término para rocas metamórficas. Dado que consisten en un 95% de cuarzo, estas arenitas cuarcíticas suelen ser mineralógicamente maduras. La roca representada en este caso es textualmente de madura a submadura. Carece de arcilla y está bastante bien clasificada. La evaluación del redondeo de los granos resulta difícil debido a la compactación y cementación que ocultan la forma original de los granos. (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Figura 10: Sección delgada de arenita cuarcítica




Nota: Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

2.4.1.5 Litarenitas

Se trata de arenitas que poseen menos del 95% de cuarzo y una proporción de fragmentos de roca mayor que la de feldespatos. Estas arenitas pueden ser clasificadas según la naturaleza petrográfica de los fragmentos de roca presentes. En la figura 11 se exhibe una sedarenita, donde los fragmentos de roca provienen de formaciones carbonatadas. Se observa un fragmento de grano fino justo encima del centro de la fotografía, procedente de una roca dolomítica, y en el cuadrante inferior derecho se pueden apreciar otros ejemplos de fragmentos carbonatados. Además, esta roca

contiene cuarzos monocristalinos y restos de placas de equinodermos (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Figura 11: Sección petrográfica de litarenita



Nota: Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)


2.4.1.6 Oolitos

También denominados Ooides, estos son granos esféricos o elipsoides con un diámetro menor de 2 mm, que presentan laminillas concéntricas regulares alrededor de un núcleo. En rocas antiguas, los ooides suelen mostrar tanto laminillas concéntricas como una estructura radial. En ocasiones, no es posible determinar si la estructura radial corresponde a una característica primaria o si se formó durante la inversión de aragonito a calcita.

La figura 12 exhibe tres fotografías: en la primera, se muestran ooides con estructuras radial y concéntrica bien definidas, cuyos núcleos son granos de carbonato micrítico. La muestra incluye una variedad de ooides, desde aquellos con un núcleo pequeño y un córtex, como se observa en la segunda fotografía, donde los ooides muestran una estructura concéntrica poco preservada. En la tercera imagen, se presentan ooides con envolturas relativamente delgadas desarrolladas sobre núcleos de cuarzo detrítico. El cemento es de calcita no ferrosa esparítica, con un tinte rosado

debido a la tinción. (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Figura 12: Fotografías microscópicas de ooides



Nota: Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)


2.4.1.7 Peloides e Intraclastos

La mayoría de los alóquimos de las rocas carbonatadas consisten en granos compuestos parcial o totalmente de micrita, aunque carecen de laminillas concéntricas en sus capas externas. Se han utilizado varios términos para clasificar este tipo de granos, los cuales en su mayoría dependen de la interpretación del origen de los mismos. Los granos compuestos de micrita que no

muestran ninguna estructura interna reconocible son conocidos como peloides.

Los intraclastos, por otro lado, están compuestos por fragmentos de sedimento que, inicialmente depositados en el fondo de una cuenca sedimentaria y parcialmente litificados, fueron posteriormente removidos y formaron nuevos granos sedimentarios (Adams, Mackenzie, & Guilford, Atlas of sedimentary rocks under the microscope, 1984).

Figura 13: Fotografías microscópicas de peloides e intraclastos



Nota: La fotografía de la izquierda representa una sección delgada que presenta peloides y la fotográfica de la derecha es un ejemplo de intraclasto. Extraído y adaptado de Atlas of sedimentary rocks under the microscope de Adams, Mackenzie, & Guilford, (1984)

CAPITULO 3 – INTELIGENCIA ARTIFICIAL

Según Álvarez Munarriz (1994), La inteligencia artificial se define como una ciencia que con el fin de simular el comportamiento inteligente del ser humano se procede al diseño y construcción de máquinas capaces de este propósito.

Como es de todos conocido, el desarrollo de la Inteligencia Artificial (IA) durante la última década ha tenido un gran avance. En todas las ramas de conocimiento han surgido aplicaciones y problemas en los que se utiliza una u otra forma de IA para abordarlos. De la misma forma, este proyecto está centrado en la IA, en concreto, en los sistemas de clasificación mediante tratamiento de imágenes y redes neuronales. Antes de describir nuestra implementación, vamos a introducir algunos conceptos clave que utilizamos en el proyecto. Se partirá de una introducción a la misma, indicando los diferentes subcampos que existen y focalizando en los que son más importantes para este proyecto. También se indicarán los frameworks y hardware utilizados en este campo.

3.1 INTRODUCCIÓN A LA INTELIGENCIA ARTIFICIAL

Hoy en día la inteligencia artificial (IA), es una rama de estudio multidisciplinaria necesaria en todas las ciencias. En el área de las ciencias computacionales se la define como las máquinas que presentan cierta capacidad de pensamiento. Sin embargo, la definición de inteligencia artificial está en continua transformación debido al avance continuo de tecnología. La inteligencia artificial se construye a base de principios que varían de acuerdo a la disciplina en la cual se la quiera emplear teniendo como base de diferenciación el análisis del problema, base de datos o la manera de solución del problema (Serna A., Acevedo M., & Serna M., 2017)

Como hemos dicho, este proyecto se encuentra dentro del campo de la informática conocido como Inteligencia Artificial (del inglés, Artificial Intelligence, IA).

Algunas de las definiciones dadas de inteligencia artificial por distintos autores son:

- 'La IA es el arte de crear máquinas con capacidad de realizar funciones que realizadas por personas requieren de inteligencia.' (Kurzweil, 1990)
- 'La IA es el estudio de cómo lograr que las computadoras realicen tareas que, por el momento, los humanos hacen mejor.' (Rich, Knight, 1991).
- 'La IA es la rama de la ciencia de la computación que se ocupa de la automatización de la conducta inteligente.' (Lugar y Stubblefied, 1993).
- 'La IA es el campo de estudio que se enfoca a la explicación y emulación de la conducta inteligente en función de procesos computacionales.'(Schalkoff, 1990).

Aunque la definición que más se acerca a la realidad de la inteligencia artificial es la creación de programas o máquinas que, dotándolos de ciertos datos de entrada, sean capaces de resolver problemas, para ello imitan funciones cognitivas asociadas al ser humano.

Allan Turing fue el primer científico en hablar sobre Inteligencia artificial cuando, en 1950, inició su artículo "Computing machinery and intelligence", formulando la pregunta: "¿las máquinas pueden pensar?". Mediante el conocido como test de Turing lo que se buscaba era medir la capacidad de una máquina para hacerse pasar por ser humano. En 1956, fue acuñado el término inteligencia artificial por John MacCarthy, Marvin Minsky y Claude Shannon en la Conferencia de Dartmouth.

La inteligencia artificial se divide en varias ramas, de las cuales destacan los sistemas expertos, la robótica, el procesamiento de lenguaje natural, los sistemas de visión, los sistemas de

aprendizaje y las redes neuronales.

Los sistemas de visión tienen como objetivo que un computador sea capaz de entender una escena o las características de una imagen. Por su parte, el aprendizaje automático desarrolla técnicas que permiten a los computadores aprender, generalizando comportamientos a partir de una información suministrada.

3.1.1 ¿QUÉ ES UNA RED NEURONAL?

Una red neuronal se la puede definir como un modelo simplificado que tiene como función emular o imitar el procesamiento del cerebro humano con la información. Al contener versiones abstractas de las conocidas neuronas su funcionamiento se basa en un sin número de unidades de procesamiento interconectadas entre sí (IBM, 2021).


Las anteriormente mencionadas unidades de procesamiento se organizan por capas (layers). Teniendo como capas fundamentales: una capa de entrada, una o varias capas ocultas y una capa de salida como se muestra en la figura 14. La capa de entrada cuenta con unidades representantes a los campos de entrada mientras que la capa de salida cuenta con unidades que representan los campos de destino. Las unidades se conectan con ponderaciones (IBM, 2021).

El aprendizaje de la red neuronal se da por una examinación de los registros individuales, proporcionando una predicción para cada registro y simultáneamente realizando los ajustes pertinentes a las ponderaciones al obtener una predicción incorrecta. Este proceso se repite muchas veces y hasta haber alcanzado varios criterios de parada y por ende haber mejorado sus predicciones (IBM, 2021).

La red aprende a través del entrenamiento por ende a un inicio todas las ponderaciones son aleatorias y las respuestas de la red no son precisas. Al presentarle a la red continuamente ejemplos

con resultados ya establecidos las nuevas respuestas son comparadas con los resultados conocidos. La información obtenida a través de esta comparación es pasada a través de la red cambiando así las ponderaciones gradualmente. Conforme el entrenamiento progresa la red adquiere mayor precisión en la réplica de resultados. Una vez concluido el entrenamiento, la red puede ser aplicada a casos futuros en los que se desconoce el resultado (IBM, 2021).

Figura 14: La estructura habitual y básica de una red neuronal



Nota: Tomado de Estructura de una red neuronal, de Daniel Burrueco s.f, Interactive Chaos (<https://interactivechaos.com/es>), Reconocimiento-No Comercial-No Comercial 4.0 Internacional.


3.1.2 REDES NEURONALES CONVOLUCIONALES

Consiste en un tipo de red neuronal con aprendizaje supervisado, teniendo su primera aparición en el año 1998, su utilidad principal es la capacidad de “Analizar imágenes”. Por ende, los datos de entrada generalmente son imágenes en forma de matrices, siendo una matriz cada pixel. Si la imagen se encuentra en escalas de grises la matriz solo tendrá un canal en otras palabras una

sola matriz y en caso de respetar el formato RGB la entrada estará formada por tres canales o tres matrices, donde en cada canal se representará la saturación de cada uno de los colores primarios (Sierra Ramos, 2022).

Al contemplar imágenes como datos de entrada se procesan las matrices correspondientes a los píxeles de las mismas por ende no solo se procesa el píxel enfocado sino también los que se encuentran alrededor del mismo, como se muestra en la figura 15. Existe también un coste computacional al tratar las imágenes y como contraposición las redes neuronales convolucionales utilizan el Pooling. Teniendo como utilidad principal la reducción del costo.

Figura 15: Esquema matricial de red neuronal convolucional



Nota: Red neuronal profunda que consiste en capas ocultas que tienen funciones de convolución y agrupación además de la función de activación para introducir la no linealidad. Tomado de: Entendiendo las redes neuronales: De la neurona a RNN, CNN y Deep Learning, de Pilar Cornieles, 2019, AILATAM, (<https://ia-latam.com>)

3.2 MATLAB

MATLAB representa una plataforma de programación y cálculo numérico ampliamente empleada por una gran cantidad de ingenieros y científicos en todo el mundo, con el propósito de analizar datos, diseñar algoritmos y construir modelos (MATLAB, 2023).

MATLAB simplifica las labores de Machine Learning al proporcionar herramientas y funciones diseñadas para manejar volúmenes considerables de datos y aplicaciones que facilitan la aplicación de Machine Learning. MATLAB representa el entorno óptimo para llevar a cabo el análisis de datos mediante Machine Learning. (The MathWorks Inc., 2023)

Con MATLAB, los equipos de ingeniería y análisis de datos tienen a su disposición un conjunto inmediato de funciones predefinidas, diversas cajas de herramientas, aplicaciones especializadas en clasificación (4:34), regresión (3:42) y agrupación en clústeres (1:50), además de datos fundamentales para tomar decisiones informadas (The MathWorks Inc., 2023).

Según The MathWorks (2023), MATLAB habilita la capacidad de extraer características de señales e imágenes mediante métodos establecidos, tanto manuales como automáticos, y realizar la selección automática de características para lograr modelos más eficientes.

- i. Optimizar las características mediante la aplicación de múltiples técnicas de ingeniería de características.
- ii. Comparar diferentes enfoques, como regresión logística, árboles de clasificación, máquinas de vectores de soporte, métodos de ensemble y Deep Learning.
- iii. Emplear AutoML para optimizar modelos a través de técnicas de reducción y ajuste de hiperparámetros.
- iv. Integrar los modelos de Machine Learning en sistemas, clústeres y nubes

empresariales, y prepararlos para su implementación en hardware específico en tiempo real.

- v. Generar automáticamente código para analizar datos provenientes de sensores integrados.
- vi. Ofrecer apoyo para flujos de trabajo completos, desde la fase de análisis de datos hasta la implementación final.

3.3 C++

C++ ejemplifica un lenguaje de programación compilado y multiparadigma que se basa principalmente en el enfoque imperativo y la orientación a objetos, e incluye también elementos de programación genérica y funcional (Universidad de Valladolid, 2020).

Un programa elaborado en un lenguaje imperativo se compone de un conjunto de instrucciones que guían al ordenador en la ejecución de una tarea específica.

En un lenguaje imperativo:

- i. Se tiene conocimiento del estado actual del programa en cada paso, determinado por los valores de las variables empleadas.
- ii. Se modifica el estado del programa mediante sentencias.

La implementación de hardware en la mayoría de las computadoras está diseñada para ejecutar código máquina que sigue un enfoque imperativo:

- i. Las variables se corresponden con ubicaciones de memoria.
- ii. Las sentencias se traducen en instrucciones.

3.4 JAVA

Java es un lenguaje de programación ampliamente adoptado y se ha convertido en un pilar en el mundo de la tecnología durante más de dos décadas. Con su versatilidad, se ha convertido en un lenguaje esencial en diversos dominios. Java es un lenguaje de programación multiplataforma, orientado a objetos y altamente centrado en la red, lo que significa que se puede utilizar como una plataforma en sí mismo. Además, Java es conocido por su velocidad, seguridad y fiabilidad, lo que lo hace adecuado para una amplia gama de aplicaciones (Amazon Web Services, 2023).

3.4.1 USOS DE JAVA

Java tiene numerosos usos en la actualidad debido a su flexibilidad y gratuidad. Aquí hay algunas de las aplicaciones más comunes de Java:

3.4.1.1 Desarrollo de videojuegos

Java es ampliamente utilizado en la creación de videojuegos, desde juegos para dispositivos móviles hasta juegos de computadora más complejos. Incluso los videojuegos modernos que incorporan tecnologías avanzadas, como el machine learning o la realidad virtual, confían en Java como parte de su desarrollo (Amazon Web Services, 2023).

3.4.1.2 Computación en la nube

Java se destaca en el ámbito de la computación en la nube gracias a su capacidad de "escribir una vez y ejecutar en cualquier lugar" (WORA). Esto lo convierte en una elección ideal para aplicaciones descentralizadas basadas en la nube, ya que los proveedores de servicios en la nube pueden utilizar Java para ejecutar programas en diversas plataformas subyacentes (Amazon Web Services, 2023).

3.4.1.3 Macrodatos

Java se utiliza en sistemas de procesamiento de datos que pueden manejar conjuntos de datos complejos y enormes cantidades de información en tiempo real. Su capacidad para procesar datos a gran escala lo hace valioso en el ámbito de los macrodatos (Amazon Web Services, 2023).

3.4.1.4 Inteligencia artificial

Java ofrece un amplio conjunto de bibliotecas de machine learning que lo hacen idóneo para el desarrollo de aplicaciones de inteligencia artificial, como el procesamiento del lenguaje natural y el aprendizaje profundo. Su estabilidad y velocidad son ventajas clave en este campo (Amazon Web Services, 2023).

3.4.1.5 Internet de las cosas (IoT)

En el contexto del IoT, Java se utiliza para programar sensores y dispositivos periféricos que pueden conectarse de forma independiente a Internet. Esto lo convierte en una elección popular para aplicaciones en el ámbito del IoT (Amazon Web Services, 2023).

3.5 PYTHON

Python es un lenguaje de programación versátil y de fácil comprensión. Ofrece estructuras de datos eficientes de alto nivel y un sistema de programación orientado a objetos simple pero efectivo. La elegante sintaxis de Python y su tipado dinámico, junto con su naturaleza interpretada, lo convierten en una elección ideal para tareas de scripting y desarrollo rápido de aplicaciones en diversas áreas y para la mayoría de las plataformas. El intérprete de Python y su amplia librería estándar están disponibles de forma gratuita en código fuente y binario para la mayoría de las plataformas a través del sitio web oficial de Python, “<https://www.python.org/>”, y se pueden distribuir libremente. Este mismo sitio también ofrece distribuciones y enlaces a numerosos

módulos de Python de terceros, programas, herramientas y documentación adicional (Python, 2023).

Python es altamente extensible, permitiendo la incorporación de funciones y tipos de datos implementados en C, C++ u otros lenguajes que pueden ser llamados desde C. Además, Python es adecuado como lenguaje de extensión para aplicaciones personalizables (Python, 2023).

3.5.1 BIBLIOTECAS DE PYTHON

Dentro del contexto de Python, las "librerías," también conocidas como "bibliotecas" o "módulos," representan conjuntos de funciones, clases y métodos predefinidos que amplían la funcionalidad básica del lenguaje. Estas librerías pueden estar escritas en Python o en otros lenguajes de programación y se pueden incorporar en tus programas, lo que permite reutilizar código y acceder a funcionalidades adicionales sin tener que comenzar desde cero (ID DIGITAL SCHOOL, 2023).

Las librerías de Python desempeñan un papel fundamental en el ecosistema del lenguaje, ya que habilitan a los desarrolladores para aprovechar un amplio espectro de funcionalidades específicas, que abarcan desde la manipulación de cadenas, operaciones matemáticas, acceso a bases de datos, manejo de archivos, creación de interfaces gráficas, procesamiento de datos científicos, construcción de sitios web, entre otras muchas posibilidades (ID DIGITAL SCHOOL, 2023).

Algunas de las librerías de Python más destacadas incluyen:

- i. NumPy: Ideal para cálculos numéricos y manipulación de matrices y arreglos.
- ii. Pandas: Útil para la manipulación y análisis de datos estructurados en forma de tablas (DataFrames).

- iii. Matplotlib y Seaborn: Empleadas para la visualización de datos y creación de gráficos.
- iv. Requests: Perfecta para realizar solicitudes HTTP y trabajar con APIs web.
- v. Flask y Django: Utilizadas en el desarrollo de aplicaciones web y sitios web.
- vi. TensorFlow y PyTorch: Fundamentales en la implementación de aprendizaje profundo y machine learning.
- vii. SQLite3 y SQLAlchemy: Usadas en el trabajo con bases de datos.

Estas son solo algunos ejemplos de las numerosas librerías disponibles en Python. La comunidad de Python es extremadamente activa, lo que significa que constantemente se crean y mantienen nuevas librerías para cubrir diversas necesidades y tareas de programación. El uso de estas librerías permite a los desarrolladores ahorrar tiempo y esfuerzo, lo que contribuye a la popularidad y la versatilidad de Python en una amplia gama de aplicaciones (ID DIGITAL SCHOOL, 2023).

3.5.1.1 Librerías de Python con la Ciencia de Datos

Las librerías de Python desempeñan un papel esencial en el campo de la Ciencia de Datos. Gracias a la rica colección de librerías disponibles para Python, los científicos de datos pueden acceder a herramientas poderosas para el análisis, manipulación, visualización y modelado de datos de manera más eficiente (ID DIGITAL SCHOOL, 2023).

Aquí se presentan algunas de las librerías clave de Python que se utilizan ampliamente en el ámbito de la Ciencia de Datos:

- i. NumPy: Esta librería proporciona soporte para operaciones matemáticas y numéricas eficientes en matrices y arreglos, y sirve de base para muchas otras librerías de Ciencia de Datos.

- ii. Pandas: Pandas se utiliza para la manipulación y análisis de datos estructurados en forma de DataFrames, facilitando tareas como la limpieza de datos, la combinación de conjuntos de datos y la realización de operaciones de agregación.
- iii. Matplotlib y Seaborn: Estas librerías se emplean en la visualización de datos, permitiendo a los científicos de datos crear gráficos, histogramas, diagramas de dispersión y más.
- iv. Scikit-learn: Es una librería de machine learning ampliamente utilizada que ofrece implementaciones eficientes de varios algoritmos de aprendizaje supervisado y no supervisado.
- v. TensorFlow y PyTorch: Estas librerías son fundamentales en el aprendizaje profundo (deep learning), lo que permite construir y entrenar redes neuronales para tareas complejas como el reconocimiento de imágenes y el procesamiento del lenguaje natural.
- vi. Statsmodels: Esta librería se enfoca en la estimación de modelos estadísticos y el análisis de datos.

Gracias a la combinación de estas librerías, los científicos de datos pueden llevar a cabo análisis avanzados de datos, entrenar modelos de machine learning y desarrollar soluciones para problemas complejos en diversos campos, como finanzas, medicina, marketing, ciencias sociales y muchos otros.

Python se ha consolidado como uno de los lenguajes más populares en el ámbito de la Ciencia de Datos debido a la riqueza de su ecosistema de librerías, su facilidad de uso y su comunidad activa, que continuamente crea nuevas herramientas y mejora las existentes para satisfacer las cambiantes necesidades de este campo en constante evolución.

CAPITULO 4 – DESARROLLO DEL PROGRAMA APLICATIVO A PETROGRAFÍA

4.1 IDENTIFICACIÓN DEL LENGUAJE DE PROGRAMACIÓN

La elección del lenguaje de programación adecuado para el aprendizaje automático, también conocido como Machine Learning, dependió de varios factores, entre ellos y el más importante el objetivo principal del proyecto la identificación de imágenes, además se consideró la disponibilidad de bibliotecas del lenguaje de programación y las capacidades de las herramientas que se tuvo para realizar la programación.

Las imágenes utilizadas fueron fotografías realizadas a las secciones petrográficas que fueron analizadas mediante el microscopio petrográfico, teniendo como finalidad la identificación del nombre de la roca y sus componentes mineralógicos principales. Se consideraron inicialmente cuatro lenguajes de programación: Python, MATLAB, C++ y Java, de los cuales se realizó una investigación exhaustiva buscando la más adecuada a las necesidades del programa y facilidad para el desarrollo del programa. Un factor muy importante para la elección del lenguaje de programación y en este caso limitante fue que se consideraron los recursos y hardware disponibles, la investigación también se alinea a que las necesidades de algunos lenguajes de programación llegan a estar optimizados para ciertas arquitecturas o dispositivos. En contra parte, otros lenguajes están disponibles en una amplia gama de arquitecturas o dispositivos. También se realizó una investigación sobre la accesibilidad a las bibliotecas y frameworks aptas para el procesamiento de imágenes y el buscado aprendizaje automático. Evidenciando que algunos de los lenguajes propuestos inicialmente poseían bibliotecas muy robustas para el propósito buscado. A continuación, en la tabla 6 se presenta una tabla comparativa de los diferentes lenguajes de programación considerados para realizar el programa de identificación, identificando las ventajas y desventajas que se reconocieron en el proceso de elección:

Tabla 6: Tabla comparativa de lenguajes de programación

LENGUAJES DE PROGRAMACIÓN	VENTAJAS	DESVENTAJAS
PYTHON	<ul style="list-style-type: none"> • Facilidad de uso y legibilidad del código. • Amplio ecosistema de bibliotecas y frameworks para una variedad de aplicaciones, incluyendo análisis de datos, aprendizaje automático, desarrollo web y más. • Comunidad activa y abundante documentación en línea. • Adopción generalizada en la comunidad de programación y aprendizaje automático. • Integración sencilla con hardware y otras tecnologías. • Adecuado para prototipado rápido y desarrollo ágil. • Ampliamente utilizado en aplicaciones de procesamiento de señales y control, especialmente en entornos académicos e industriales. 	<ul style="list-style-type: none"> • Entorno de desarrollo integrado (ide) robusto para cálculos numéricos. • Algunas licencias pueden ser costosas.
MATLAB	<ul style="list-style-type: none"> • Ofrece herramientas y cajas de herramientas específicas para matemáticas y simulación. • Facilita la visualización y análisis de datos y resultados. • Menos versátil fuera de aplicaciones científicas y de ingeniería. • Máximo rendimiento y control sobre recursos del sistema. 	<ul style="list-style-type: none"> • Mayor complejidad en el desarrollo y depuración del código en comparación con lenguajes de más alto nivel. • Garbage collection puede afectar el rendimiento en aplicaciones de tiempo real.
C++	<ul style="list-style-type: none"> • Adecuado para aplicaciones de alto rendimiento, sistemas embebidos y desarrollo de software de bajo nivel. • Amplia disponibilidad de bibliotecas de procesamiento de imágenes y gráficos. 	<ul style="list-style-type: none"> • Menos adecuado para cómputo numérico y procesamiento de datos en comparación con Python y MATLAB.
JAVA	<ul style="list-style-type: none"> • Portabilidad, ya que es un lenguaje de plataforma cruzada. • Ampliamente utilizado en el desarrollo de aplicaciones empresariales y móviles. • Fuerte soporte para sistemas distribuidos y grandes proyectos. 	

Nota: Elaboración propia en base a información recopilada en la investigación.

Siguiendo lo anteriormente nombrado, en el caso de MATLAB, a pesar de tener herramientas específicas para el procesamiento de imágenes y para el aprendizaje automático, como por ejemplo la caja de herramientas de visión por computadora, se identificó que al ser MATLAB un software de paga puede ser costoso en términos de licencias, lo que fue una limitación en el desarrollo del proyecto. Además, que existen restricciones en las licencias, lo que generaba un riesgo en la distribución del programa en especial si uno de los requisitos era el poder compartir el software o el modelo generado con otros usuarios.

Una vez descartando a MATLAB como lenguaje de programación a utilizar, se procedió a analizar a C++. Sin embargo, a pesar de ser adecuado para aplicaciones de alto rendimiento y eficiencia en el procesamiento de imágenes y aprendizaje automático. La búsqueda de información acerca de la curva de aprendizaje, arroja que la ya mencionada curva de aprendizaje tiende a ser más empinada en comparación con lenguajes de alto nivel como ser Python, lo que asume un requerimiento de tiempo y esfuerzo mayor para aprender y dominar. Del mismo modo, el lenguaje de programación de C++ es más propenso a errores, necesitando una gestión más detallada de la memoria en comparación de los lenguajes más abstractos.

Posteriormente, se consideró el desarrollo del programa por el lenguaje de programación de Java debido a que es portátil y a la existencia de bibliotecas como la Deeplearning4j y JavaCV para el procesamiento de imágenes y el aprendizaje automático. No obstante, su rendimiento puede ser inferior al de lenguajes de programación como C++ en aplicaciones de alto rendimiento y procesamiento de imágenes intensivo agregando también que su uso para aprendizaje automático no es tan común, lo que resulta en una menor disponibilidad de modelos pre entrenados y recursos de la comunidad.

Seguidamente, se realizó el análisis del lenguaje de programación Python y se pudo apreciar

su versatilidad y facilidad de uso. Evidenciando la amplia gama de bibliotecas y frameworks que poseen especialmente en el procesamiento de imágenes, aprendizaje automático, análisis de datos, entre otros haciéndolo apto para el desarrollo de proyectos de cualquier disciplina. Teniendo a favor la legibilidad y claridad de sus sintaxis facilito el desarrollo del programa. Además, que teniendo la comunidad activa que ofrece este lenguaje facilito la colaboración en las consultas que emergieron durante el desarrollo. Para el desarrollo de este programa, se optó por utilizar el aprendizaje automático como enfoque principal. Python fue la elección natural para este propósito, dado que es ampliamente reconocido en la comunidad de aprendizaje automático y ofrece una amplia gama de bibliotecas y herramientas específicas para esta disciplina.

Sin embargo, durante el desarrollo del programa, se enfrentaron a ciertas restricciones que debían superarse para lograr un funcionamiento óptimo. Una de las limitaciones críticas fue la cantidad limitada de memoria RAM disponible para llevar a cabo tareas de procesamiento intensivo. En este contexto, Python demostró ser una solución idónea al ser completamente compatible con Google Colab, un editor de código en línea que ofrece la ventaja de ejecutar códigos en un entorno de GPU (Unidad de Procesamiento Gráfico). Esta característica resultó esencial, ya que el uso de GPU aceleró significativamente el proceso de entrenamiento y evaluación de modelos de aprendizaje automático, a pesar de las limitaciones de memoria física.

Además, Python permitió una integración perfecta con Google Drive, que desempeñó un papel crucial en la gestión y el acceso a la base de datos de imágenes. La capacidad de trabajar con archivos de imágenes sin comprimir o sin reducir su calidad fue fundamental para asegurar la precisión y la eficiencia del proceso de análisis de imágenes. La asociación entre Python y Google Drive permitió un acceso rápido y sencillo a los datos, lo que simplificó en gran medida el flujo de trabajo del programa.

En resumen, Python se destacó como el lenguaje de programación adecuado para superar las restricciones técnicas y operativas del proyecto, brindando la flexibilidad y las herramientas necesarias para el aprendizaje automático y facilitando la colaboración con servicios en línea como Google Colab y Google Drive. Esto resultó en un entorno eficiente y efectivo para el desarrollo y la ejecución exitosa del programa.

4.2 RECOPIACIÓN DE DATA BASE

Durante el proceso de recopilación de datos para la creación de una base de datos destinada al entrenamiento de un modelo de clasificación de imágenes y detección de objetos en Python, se realizaron consideraciones fundamentales. El inicio de este proceso implicó una cuidadosa selección de las categorías que se buscaban clasificar, estableciendo así un marco conceptual para el modelo. Este paso inicial permitió definir claramente los objetos de interés y establecer las pautas para el entrenamiento del algoritmo.

Posteriormente, se procedió a identificar las características específicas que se deseaban detectar dentro de cada categoría. Esta fase implicó un análisis detallado de los elementos distintivos presentes en las imágenes, estableciendo así los parámetros que el modelo debía aprender a reconocer y clasificar de manera efectiva. La determinación del número de imágenes necesario para cada categoría se basó en la disponibilidad de fotografías de secciones petrográficas nítidas. Se priorizó la calidad visual de las imágenes para garantizar un conjunto de datos robusto y representativo. Este enfoque aseguró que el modelo pudiera aprender de manera efectiva las variaciones y sutilezas presentes en las secciones petrográficas, lo que contribuye a su capacidad para realizar clasificaciones precisas y detectar objetos con alto nivel de detalle.

En resumen, el proceso de recopilación de datos se llevó a cabo de manera meticulosa,

considerando no solo la cantidad de imágenes, sino también la calidad y representatividad de las mismas. Esto sienta las bases para el desarrollo de un modelo de aprendizaje automático capaz de realizar tareas de clasificación de imágenes y detección de objetos con precisión en el entorno de programación Python.

4.2.1 CATEGORÍAS SELECCIONADAS PARA LA CLASIFICACIÓN Y DETECCIÓN

Tomando como base lo descrito en el capítulo dos donde se menciona la petrografía, se tomaron como base principal para la data set a las tres categorías principales de rocas: rocas sedimentarias, ígneas y metamórficas. Obteniendo una serie de grupo de imágenes de rocas que se detallan en la tabla 7:

Tabla 7: Rocas seleccionadas para la identificación

ROCAS SEDIMENTARIAS	ROCAS ÍGNEAS	ROCAS METAMÓRFICAS
1. Arenisca	1. Granito	1. Mármol
2. Lutita (Arcilla)	2. Basalto	2. Esquisto
3. Conglomerado	3. Riolita	3. Gneis
4. Caliza	4. Diorita	4. Pizarra
5. Subarcosa	5. Pórfido	5. Cuarcita
6. Yeso	6. Andesita	6. Anfíbolita
7. Siltita	7. Obsidiana	7. Filita
8. Dolomita	8. Gabro	8. Cuarcita
9. Brecha	9. Pumita	

Nota: Elaboración Propia, en base a las imágenes recopiladas de British Geological Survey y otros.

Una vez concluyendo la recopilación de imágenes de los diferentes tipos de roca se procedió a la recopilación de imágenes más detalladas de los minerales y microfósiles, que llegan a componer a las rocas ya mencionadas en la tabla anterior. Esto debido a que la primera fase del programa consta de la clasificación general de la roca y la segunda consiste en una detección de sus características mineralógicas y fosilíferas. Para obtener la segunda fase se necesita una base de datos lo más amplio que permita el acceso a este tipo de imágenes y su correcto etiquetado. A continuación, en la tabla 8 se presenta la lista de minerales que se recopilaron para crear la segunda base de datos usada en el desarrollo del programa.

Tabla 8: Minerales y microfósiles seleccionados para la detección

MINERALES / MICROFÓSILES	
Oolitos	Cuarzo
Calcitas	Inter Clastos
Clorita	Foraminíferos
Ortosas	Microlina
Circón	Micrita
Moscovita	Esparrita
Plagioclasas	Glaucomita

Nota: Elaboración Propia, en base a las imágenes recopiladas de British Geological Survey y otros.

4.2.2 ETIQUETADO DE IMÁGENES

En el proceso de entrenamiento supervisado, la etapa de etiquetado de imágenes desempeñó un papel fundamental, y se completó con éxito. Cada imagen del conjunto de datos se etiquetó


cuidadosamente para indicar a qué categoría pertenecía o qué características específicas contenía. Este procedimiento se llevó a cabo mediante la asignación de etiquetas a cada imagen, lo que proporcionó al modelo información crucial sobre el contenido de las mismas.

En particular, se consideraron dos enfoques para llevar a cabo este proceso de etiquetado. En primer lugar, se optó por el etiquetado manual, que implicó la laboriosa tarea de asignar etiquetas de forma manual a cada imagen y subdividir las en carpetas. Aunque este enfoque requirió tiempo y esfuerzo, demostró ser altamente preciso y específico. El proceso de etiquetado manual logró tener un control a fondo del contenido visual de las imágenes, lo que garantizó que las etiquetas fueran consistentes y precisas. Este proceso se realizó para la fase de clasificación general de las rocas

Adicionalmente al etiquetado manual, se implementó una estrategia de etiquetado semiautomático (Figura 16) con el objetivo de optimizar la eficiencia del proceso. Esta metodología aprovechó herramientas avanzadas y algoritmos de etiquetado automático que, mediante el uso de técnicas avanzadas de procesamiento de imágenes, lograron identificar automáticamente objetos presentes en las imágenes y asignar las etiquetas correspondientes. Esta aproximación resultó fundamental para acelerar significativamente la fase de etiquetado, permitiendo manejar conjuntos de datos más extensos de manera eficaz.

A pesar de la automatización, se implementó una supervisión cercana para asegurar la precisión de las etiquetas generadas. Esto se volvió especialmente crucial en situaciones donde se requería una interpretación contextual más detallada o en casos donde la complejidad de la imagen exigía una verificación manual para evitar posibles errores. Este enfoque híbrido, combinando la eficiencia de la automatización con la atención humana para validar y refinar resultados, garantizó la calidad y exactitud de las etiquetas asignadas, incluso en escenarios más desafiantes.

Figura 16: Ejemplo de etiquetado semi automático



Nota: Dos ejemplos del etiquetado (I: rectangular; II: poligonal) realizado con el programa MakeSense de Inteligencia Artificial para el etiquetado semiautomático. Elaboración Propia

Como se muestra en la imagen anterior se realizó el etiquetado de dos maneras diferentes para identificar la diferencia en el rendimiento del entrenamiento del programa. Por consiguiente, se realizó dos entrenamientos con una categoría elegida al azar, en este caso fue la categoría de foraminíferos, de los cuales 125 imágenes se etiquetaron de forma semiautomática de forma

rectangular y poligonal, una vez realizado el entrenamiento y con un número de épocas de 20 se obtuvo un rendimiento del 83.21% para el etiquetado rectangular y un 83,87% para el etiquetado poligonal. Concluyendo así que el tipo de etiquetado no influye de forma significativa en la calidad del entrenamiento para la detección. Cabe resaltar que el rendimiento se vio reducido debido a que al ser una prueba se utilizó un número reducido de imágenes de la data base de la categoría de Foraminíferos.

La combinación de etiquetado manual y automático permitió etiquetar con éxito todas las imágenes del conjunto de datos, proporcionando al modelo la información necesaria para su entrenamiento. Este proceso de etiquetado preciso y coherente es esencial para la capacidad del modelo de llevar a cabo tareas de clasificación, detección o cualquier otra relacionada con el procesamiento de imágenes con un alto grado de precisión y confiabilidad.

4.2.3 FUENTES DE IMÁGENES PARA LA DATA BASE

Gran parte de la base de datos fue extraída del Servicio Geológico Británico, BGS por sus siglas en inglés *British Geological Survey*, siendo esta el principal proveedor del Reino Unido de datos, información y conocimientos geo científicos.

Dentro del apartado dedicado a la base de datos, cobra especial relevancia la presencia de BRITROCKS: la base de datos que alberga colecciones detalladas de imágenes petrográficas, las cuales han sido minuciosamente clasificadas según el tipo de rocas al que pertenecen, como se ejemplifica de manera visual en la Figura 17.

Este extenso y cuidadosamente curado repositorio de información mineralógica y petrográfica ha desempeñado un papel fundamental en la fase de clasificación del proyecto. La riqueza de datos proporcionada por BRITROCKS ha permitido establecer una sólida base de

conocimiento, brindando a los investigadores y profesionales acceso a una amplia variedad de imágenes y clasificaciones que han facilitado el proceso de categorización y análisis de muestras.

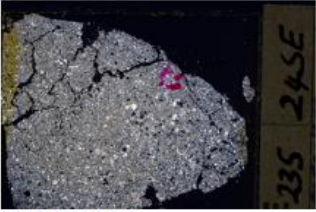
Figura 17: Registro de colección de mineralogía y petrología de BGS

BGS mineralogy and petrology collection record	
Sample number	E25748; COLLNOBCW82;
Sample Donor	Worsam, B. C.
Rock name	Sandstone (Undifferentiated).
Stratigraphy	Keuper Marl, Lower [Obsolete: Use Bom, Mmg, Sim].
Comments	Cavernous fine Sst. Keuper Marl.
Locality details	Upton, Burford BH. 540 yd S 35 deg W of Taynton Church
50k map sheet	Cirencester (235) View images in GeoScience related to 'Cirencester' View a geological map near 'Cirencester'
Map reference	SP 0264 0162
Year collected	0
Bore name	Upton 1
Confidentiality	No restrictions

Petrological thin sections

Links to high resolution images

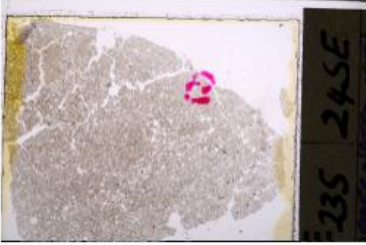
E25748



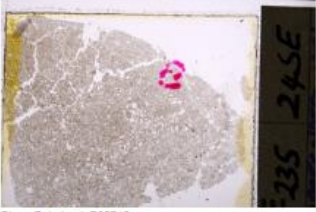
Cross Polarized, E25748

Transition from XPL to PPL light

XPL PPL



Field of view: c. 31 mm.




Plane Polarized, E25748

Nota: Extraído de Registro de colección de mineralogía y petrología de BGS, por British Geological Survey, 2023, BGS (<https://webapps.bgs.ac.uk/data/britrocks/britrocks.cfc?method=viewSamples&sampleId=150764>)

Como se puede apreciar en la figura anterior, esta base de datos nos proporciona imágenes de secciones petrográficas tanto con luz polarizada cruzada y luz polarizada plana, dando mayor precisión en el entrenamiento.

Además, nos proporciona imágenes de alta calidad de cada sección (Figura 18), reduciendo la ambigüedad en la calidad de entrenamiento.

Figura 18: Alta calidad de fotografías de secciones petrográficas



Nota: Extraído de Registro de colección de mineralogía y petrología de BGS, por British Geological Survey, 2023, BGS (<https://webapps.bgs.ac.uk/data/britrocks/britrocks.cfc?method=viewSamples&sampleId=150764>)

El resto de la data base se la recopiló de sitios web como ser el Servicio Geológico Mexicano, *United States Geological Survey*, GeoHubLiverpool, y otras páginas menores de las cuales se pudo recolectar tanto imágenes para la clasificación del tipo de roca como para la detección de las características mineralógicas o fosilíferas de las secciones petrográficas.

4.3 DESARROLLO Y DISEÑO DE LA RED CONVOLUCIONAL

El desarrollo del programa se llevó a cabo en dos fases fundamentales, cada una con un propósito específico en el análisis de las fotografías de secciones petrográficas. Estas dos partes, el clasificador de tipo de roca y el detector de características mineralógicas y/o micro fosilíferas, representan componentes esenciales de una herramienta integral diseñada para el proyecto.

Ambas partes del programa están interconectadas y se complementan entre sí para

proporcionar una visión completa y detallada de las secciones. La información generada por el clasificador de tipo de roca se utiliza para guiar el análisis más detallado realizado por el detector de características mineralógicas y/o microfosilíferas.

4.3.1 CLASIFICADOR DE TIPO DE ROCA

Se reunió un conjunto de datos de imágenes de secciones petrográficas que represento una variedad de tipos de roca, 26 tipos de roca, y en diferentes condiciones. Como se indicó en el punto 3.2.2 de este proyecto se realizó el etiquetado de las imágenes, que para el presente caso se lo realizo manualmente, debido a que no era necesaria la generación de etiquetas de forma externa. En cuanto a la calidad de las imágenes se buscó que tuvieran una resolución de 1024x1024 pixeles, debido a que la calidad de las imágenes afecta directamente la capacidad del modelo para aprender y generalizar.

Las bibliotecas utilizadas fueron Tensor Flow (tf), debido a que se necesitó un aprendizaje automático profundo y al tener como beneficio que es de código abierto se lo utilizo para definir y entrenar el modelo de la red neuronal. Para este programa se creó un nuevo modelo y no se utilizó un modelo pre entrenado.

También se utilizó la biblioteca Keras, para ser más precisos Keras Layers y Models que al ser parte de la API Keras y estar integrada a TensorFlow se la utilizo para definir las capas de la red neuronal convolucional y crear el modelo de la red. La biblioteca Numpy se utilizó para la manipulación de imágenes.

En el caso de la biblioteca OpenCV, se utilizó para cargar y procesar las imágenes previamente a la clasificación. Usando la función `cv2.imread(path_img)` se realizó la carga de imágenes de secciones petrográficas en la ruta `path_img`. A pesar de que OpenCV es capaz de

trabajar con varios formatos de imágenes como ser: JPEG, PNG y TIFF, para este proyecto se utilizó únicamente imágenes en formato JPEG. Debido a que saltaba un error en el entrenamiento al momento de trabajar con diferentes formatos de imágenes. Esta biblioteca también fue utilizada para el redimensionamiento de las imágenes con la función `cv2.resize (image, desired_size)` con este redimensionamiento no reducimos la calidad de la imagen al contrario al unificar el tamaño de todas las imágenes cargadas ya sea en la base de datos de entrenamiento, validación o prueba podemos tener un procesamiento fluido de la clasificación. Adicionalmente, se utilizó la función `cv2_imshow(image)` para mostrar la imagen en dos ocasiones la primera antes del entrenamiento para controlar la calidad de imágenes que están entrando desde la base de datos al entrenamiento y la segunda se utilizó para mostrar la imagen en la interfaz del usuario en otras palabras esta función se utilizó para visualizar la imagen original antes de la clasificación y la imagen con la etiqueta de clasificación superpuesta después de la clasificación.

En resumen, este código se enfoca en la clasificación de tipos de roca a partir de imágenes y utiliza TensorFlow, Keras y OpenCV principalmente para crear y entrenar una CNN para esa tarea. El código también incluye la funcionalidad para cargar imágenes y realizar predicciones de clasificación en tiempo real.

4.3.2 DETECTOR DE CARACTERÍSTICAS DE SECCIONES PETROGRÁFICAS

Para el desarrollo del detector de características se utilizó la funcionalidad de detector de objetos de las redes neuronales convencionales, debido a la reducida accesibilidad de imágenes con descripciones detalladas el data base consiste en únicamente 14 categorías. Igualmente, como se indicó en el punto 3.2.2 de este proyecto se realizó el etiquetado de las imágenes, que para el presente caso se lo realizó de manera semiautomática con el programa MakeSense, debido a que

para la detección de objetos se deben tener etiquetas externas que indique las coordenadas de la ubicación del objeto detectado en la imagen. En cuanto a la calidad de las imágenes se buscó que tuvieran la misma resolución de 1024x1024 píxeles, debido a que la calidad de las imágenes afecta directamente la capacidad del modelo para aprender y generalizar.

Las bibliotecas que se utilizó para el desarrollo fueron: NumPy, que se utilizó para trabajar con las matrices y tensores que representan datos de imágenes y los resultados de la predicción.

Para el desarrollo del detector también se utilizó TensorFlow para definir, compilar y entrenar el modelo de detección. Cabe aclarar que al igual que en la clasificación se creó un modelo nuevo para el entrenamiento y no se utilizó un modelo pre entrenado debido a la diferencia entre las bases de datos preexistentes en las bibliotecas de Python.


Para el trazado de las curvas de entrenamiento y mostrar las imágenes se utilizó la extensión matplotlib.pyplot. Aprovechando la aplicación de esta librería para la creación de visualización, gráficos y trazado de datos se lo empleo para la visualización de imágenes con etiquetas y para mostrar gráficos de entrenamiento. Con la función plt.plot() se utilizó para visualizar la precisión y la pérdida del modelo durante el entrenamiento. Seguidamente la función plt.imshow() se utilizó para la visualización de una imagen en la interfaz de Google Colab, donde se realizó el entrenamiento.

Para la visión por computadora se utilizó a OpenCV (cv2) para el cargado, procesamiento y para mostrar las imágenes. La función cv2.imread nos ayudó a cargar imágenes desde una ruta específica como se pude evidenciar en el código adjunto en la sección de Anexos. Una vez cargada se la guardaba como una matriz NumPy. También, se utilizó la función cv2.putText() que nos ayudó a mostrar la etiqueta de clase predicha en la imagen procesada.

4.3.3 INTERFAZ

La interfaz se desarrolló con la herramienta Qt Designer, debido a que es la herramienta que mejor se adapta a las limitaciones del hardware. El programa consta de tres formularios, el primero, Figura 19, consta de cuatro botones de comando el primero que nos permite subir la imagen desde una carpeta del ordenador, el segundo que limpia las imágenes cargadas, el tercer botón manda la orden para la predicción con respecto de la imagen cargada. Una vez realizada la predicción se pasa al segundo formulario donde se presentan los resultados de la predicción, Anexo, y si la imagen identificada fue recolectada dentro de los límites del país se llenan las casillas de coordenadas UTM y se habilita el botón de comando Buscar resultando así un tercer formulario donde se presenta la formación mas aproximada a los resultados obtenidos por el programa todo basado en el Léxico Estratigráfico publicado en Yacimientos Petrolíferos Fiscales Bolivianos. Finalmente, se cierra el programa cierra el programa.

Figura 19: Interfaz del identificador de secciones petrográficas desarrollado



Nota: Interfaz del programa para la identificación de secciones petrográficas. Elaboración propia en base al programa desarrollado con Python y Qt Designer

4.4 VALIDACIÓN DEL PROGRAMA

4.4.1 VALIDACIÓN INTERNA DEL PROGRAMA

Durante la ejecución del código de programación a razón de que se utilizó TensorFlow y Keras existe partes de salida que se generan durante el entrenamiento de la red neuronal convolucional, gracias a esta salida se pudo obtener información sobre cómo estaba progresando el entrenamiento. En la Figura 20 se muestra la parte de salida de la fase de clasificación, donde se puede evidenciar que el tiempo del último paso de entrenamiento tomo 10 segundos y 486 milisegundos, la función de perdida que nos indica cuán lejos esta la predicción de la red neuronal de los valores reales en este caso está en 0.3147 lo que indica que la red está haciendo buenas predicciones en el conjunto de entrenamiento. Seguidamente tenemos la precisión actual en el conjunto de entrenamiento, denominado *accuracy*, que resulta en un 0.9678 lo que indica que las predicciones correctas realizadas por la red en comparación con el total de ejemplos en el conjunto de entrenamiento es del 96.78%. Pasando a la parte de validación, la función de perdida en el conjunto de validación es del 0.4035 que indica lo bien generalizada que esta la red de datos que no ha visto durante el entrenamiento. Por último, la precisión del conjunto de validación indica un 98.97% de aciertos en el conjunto de imágenes de validación.

En el caso de del detector se obtuvo un parte de salida similar donde se puede evidenciar que el tiempo del último paso de entrenamiento tomo 14 segundos y 914 milisegundos, la función de perdida que nos indica cuán lejos esta la predicción de la red neuronal de los valores reales en este caso está en 0.4680 lo que indica que la red está haciendo buenas predicciones en el conjunto de entrenamiento es evidente que este valor es mayor al de la clasificación, pero se debe a que el número de imágenes de entrenamiento es menor al conseguido para la clasificación. Seguidamente

tenemos la precisión actual en el conjunto de entrenamiento, denominado *accuracy*, que resulta en un 0.9286 lo que indica que las predicciones correctas realizadas por la red en comparación con el total de ejemplos en el conjunto de entrenamiento es del 92.86%. Pasando a la parte de validación, la función de pérdida en el conjunto de validación es del 0.4534 que indica lo bien generalizada que está la red de datos que no ha visto durante el entrenamiento. Por último, la precisión del conjunto de validación indica un 95.75% de aciertos en el conjunto de imágenes de validación.

Aun teniendo en cuenta que el rango de aceptación o aprobación del modelo depende de cada caso de estudio lo aconsejable es que la precisión supere el 90%, una vez realizado el entrenamiento y con resultados en las partes de salida y debido a que en ambos entrenamientos la precisión supera este rango, se consideran aceptables o aprobados ambos entrenamientos validando el cumplimiento con el objetivo de clasificación y detección de características de las imágenes de secciones petrográficas, dando paso a la identificación de secciones petrográficas a través de imágenes.

Figura 20: Parte de salida del clasificador

```
Epoch 1/10
20/20 [=====] - 259s 12s/step - loss: 1.3329 - accuracy: 0.4329 - val_loss: 0.9864 - val_accuracy: 0.5192
Epoch 2/10
20/20 [=====] - 9s 434ms/step - loss: 0.8258 - accuracy: 0.6256 - val_loss: 0.6442 - val_accuracy: 0.6987
Epoch 3/10
20/20 [=====] - 8s 398ms/step - loss: 0.5702 - accuracy: 0.7235 - val_loss: 0.4885 - val_accuracy: 0.7244
Epoch 4/10
20/20 [=====] - 7s 369ms/step - loss: 0.3950 - accuracy: 0.8199 - val_loss: 0.3662 - val_accuracy: 0.8333
Epoch 5/10
20/20 [=====] - 9s 431ms/step - loss: 0.3666 - accuracy: 0.8673 - val_loss: 0.5639 - val_accuracy: 0.7372
Epoch 6/10
20/20 [=====] - 7s 365ms/step - loss: 0.3764 - accuracy: 0.8325 - val_loss: 0.3341 - val_accuracy: 0.8846
Epoch 7/10
20/20 [=====] - 7s 358ms/step - loss: 0.4228 - accuracy: 0.8705 - val_loss: 0.4298 - val_accuracy: 0.9294
Epoch 8/10
20/20 [=====] - 8s 426ms/step - loss: 0.3751 - accuracy: 0.8953 - val_loss: 0.5708 - val_accuracy: 0.9361
Epoch 9/10
20/20 [=====] - 7s 348ms/step - loss: 0.4093 - accuracy: 0.9476 - val_loss: 0.4722 - val_accuracy: 0.9789
Epoch 10/10
20/20 [=====] - 10s 486ms/step - loss: 0.3147 - accuracy: 0.9678 - val_loss: 0.4035 - val_accuracy: 0.9897
```

Nota: Parte de salida del clasificador donde se comprueba el porcentaje de precisión del entrenamiento. Elaboración propia en base a resultados emitidos por el programa.

4.4.2 VALIDACIÓN CON DATOS DE LABORATORIO

Para la validación con datos de laboratorio se tomaron los resultados emitidos por el Instituto de Investigaciones Geológicas y Medio Ambientales (IGEMA) de la Universidad Mayor de San Andrés.

Se realizó una campaña geológica en octubre de 2021, en la provincia de Palos Blancos en el departamento de La Paz. Como área de exploración se seleccionó los afloramientos en la carretera de Sapecho – Yucumo, en la expedición se recolectaron un total de 13 muestras. De las cuales se seleccionaron tres muestras, muestra N°3, muestra N° 7A y muestra N°11, que resultaron las más representativas de la zona de estudio. Estas tres muestras seleccionadas fueron mandadas al instituto IGEMA, para su análisis petrográfico y los informes resultantes son los utilizados para la validación del programa desarrollado. Las coordenadas UTM donde se recolectaron las muestras N.º 3, N.º 7A y N.º 11 (Figura 21), se encuentran en la tabla 9.

Tabla 9: Coordenadas de punto de muestreo de las rocas seleccionadas

PUNTO DE MUESTREO	X	Y	Z
3	697086.84	8291458.83	958
7	699819.49	8296805.76	785
11	703332.34	8299733.91	605

Nota: Elaboración propia en base a los datos recolectados por el GPS.

Las muestras de roca pasaron por el área técnica del Instituto de Investigaciones Geológicas y del Medio Ambiente para la elaboración de la sección petrográfica para el respectivo análisis con el microscopio petrográfico.

Figura 21: Muestras seleccionadas para laboratorio



Nota: Fotografías de las muestras de roca extraídas en Palos Blancos. I) Muestra N.º 7a, II) Muestra N.º 3 y III) Muestra N.º 11. Elaboración propia.

El tiempo de espera aproximado expresado por el laboratorista y técnico del instituto fue de dos semanas para la emisión de los resultados. Una vez obtenido el informe de laboratorio se pudieron apreciar los resultados plasmados en la tabla 10, además que la descripción petrográfica completa se encuentra en la sección de Anexos.

Tabla 10: Resultados de laboratorio de las muestras seleccionadas

	MUESTRA N.º 3	MUESTRA N.º 7A	MUESTRA N.º 11
TIPO DE ROCA	CALIZA	SUBARCOSA	CALIZA
	Micrita	Cuarzo	Micrita
	Microfósiles (Foraminíferos)	Plagioclasas	Microfósiles (Foraminíferos)
	Intraclastos	Ortosa	Esparita
	Esparita	Microlina	Oolitos
DESCRIPCIÓN MICROSCÓPICA	Menas De Hierro	Muscovita	Intraclastos
		Clorita	Hidróxidos De Hierros
		Circón	Cuarzo
		Calcita	Menas De Hierro
		Materia Orgánica	
		Menas De Hierro	

Nota: tabla elaborada con la descripción petrográfica de numero de orden 69/2021 emitida por el Instituto de Investigaciones Geológicas del Medio Ambiente de la Universidad Mayor de San Andrés, por Ing. Hans Resnikowski P.

Las imágenes proporcionadas en el informe de laboratorio se introdujeron al programa desarrollado en este proyecto dando como resultado los datos de la siguiente tabla:


Tabla 11: Resultados obtenidos con el programa desarrollado

	Muestra N.º 3	MUESTRA N.º 7a	Muestra N.º 11
TIPO DE ROCA	CALIZA	SUBARCOSA	CALIZA
CARACTERÍSTICAS PRINCIPALES	Micrita	Cuarzo	Micrita
	Foraminíferos	Plagioclasas	Foraminíferos
	Intraclastos	Ortosa	Esparita
	Esparita	Microlina	Oolitos
		Muscovita	Intraclastos
		Clorita	Cuarzo
		Circón	
	Calcita		

Nota: Elaboración propia en base a los resultados obtenidos con el programa.


A continuación, se muestran algunas imágenes como ejemplo de cada sección petrográfica que se llevó a analizar. La Figura 22 se trata de la sección delgada de la muestra N.º 3 y se puede apreciar una micro vetilla de Esparita rodeada de micrita. Posteriormente tenemos una fotografía de los cristales de Muscovita de la sección petrográfica de la muestra N.º 7ª (Figura 23). Finalmente, en la Figura 24 tenemos una fotografía de los microfósiles foraminíferos y Oolitos presentes en la lámina delgada de la muestra N.º 11

Figura 22: Micro vetilla de Esparita




Nota: Extraído del material solicitado al instituto de forma digital, fuente: Instituto de Investigaciones Geológicas y del Medio Ambiente

Figura 23: Fotografía de cristales de Muscovita



Nota: Extraído del material solicitado al instituto de forma digital, fuente: Instituto de Investigaciones Geológicas y del Medio Ambiente

Figura 24: Microfósiles de foraminíferos y Oolitos



Nota: Extraído del material solicitado al instituto de forma digital, fuente: Instituto de Investigaciones Geológicas y del Medio Ambiente

4.5 ANÁLISIS DE RESULTADOS DEL PROGRAMA

Se realizó una tabla comparativa, tabla 12, en donde se muestra las coincidencias entre los resultados encontrados con el programa y los resultados de laboratorio. El porcentaje de acierto no es mostrado por el programa a la hora de mostrar resultados, pero con la función de precisión de validación mostrada en el punto 3.4.1 y en base a la matriz de confusión comúnmente usada para la evaluación de precisión y exactitud en el Machine Learning. Se tomó el valor mayor de desaciertos en ambos entrenamientos teniendo así un 4.25% de incertidumbre. Usamos el término de incertidumbre cuando nos referimos a predicciones como lo que realiza el programa debido a que es más apropiado hablar de "incertidumbre" en lugar de "error" para describir la medida de cuánto puede variar la predicción en torno a su valor central o esperado. La incertidumbre es una forma de expresar la falta de precisión o el grado de confianza en una predicción.

Tabla 12: Tabla comparativa de resultados

MUESTRA	N° 3	N° 3 (PROGRAMA)	N° 7A	N° 7A (PROGRAMA)	N.º 11	N° 11 (PROGRAMA)
TIPO DE ROCA	CALIZA	CALIZA	SUBARCOSA	SUBARCOSA	CALIZA	CALIZA
	Micrita	Micrita	Cuarzo	Cuarzo	Micrita	Micrita
	Microfósiles (Foraminíferos)	Foraminíferos	Plagioclasas	Plagioclasas	Microfósiles (Foraminíferos)	Foraminíferos
	Intra Clastos	Intra Clastos	Ortosa	Ortosa	Esparita	Esparita
	Esparita	Esparita	Microlina	Microlina	Oolitos	Oolitos
	Menas De Hierro	X	Muscovita	Muscovita	Intra Clastos	Intra Clastos
DESCRIPCIÓN MICROSCÓPICA			Clorita	Clorita	Hidróxidos De Hierros	X
			Circón	Circón	Cuarzo	Cuarzo
			Calcita	Calcita	Menas De Hierro	X
			Materia Orgánica	X		
			Menas De Hierro	X		

Nota: Elaboración propia, en base a los resultados emitidos por el Instituto De Investigaciones Geológicas Y Medio Ambiente y los resultados obtenidos del programa.

En el caso de las menas de hierro, la materia orgánica e hidróxidos de hierro, estas tres categorías no fueron encontradas por el programa debido a que la base de datos no las incluye. En base a la investigación realizada se tuvo una lista inicial de las características mineralógicas que tendría que contener la base de datos, pero al tener que ser fabricada desde cero la base de datos hubo algunas características que no fueron incluidas debido a la ausencia de fuentes respaldadas para su incorporación a la base de datos.



CAPITULO 5 – ANÁLISIS DE COSTOS

En este capítulo, se llevará a cabo un análisis económico en relación a la implementación del programa como un producto final. Este producto se presenta como una herramienta especializada diseñada para la identificación de secciones petrográficas en muestras geológicas, con el propósito fundamental de agilizar el proceso de análisis microscópico y reducir la exposición prolongada de los analistas al uso del microscopio.

5.1 ANÁLISIS DE VIABILIDAD ECONÓMICA

Es importante destacar que el desarrollo de tecnología se ha convertido en un asunto de gran relevancia a nivel global. En este contexto, el enfoque de nuestra investigación está firmemente orientado a la satisfacción de una necesidad que ha sido expresada. La creciente demanda de soluciones eficientes en el campo de la geología y la petrografía, que permitan un análisis más rápido y preciso de las muestras, refleja la importancia de este proyecto. Al proporcionar una herramienta que cumple con estos requisitos, contribuimos a mejorar la eficiencia en la investigación científica, la exploración de recursos naturales y otros campos relacionados, lo que a su vez tiene un impacto económico significativo y un beneficio directo para la sociedad en su conjunto. Este análisis económico se centrará en cuantificar y evaluar los costos y beneficios asociados con la implementación de esta solución tecnológica, así como en identificar las oportunidades económicas que pueden derivarse de su adopción a nivel mundial.

Este análisis costeo permitirá evaluar el valor económico y la eficiencia de nuestro programa en relación con las alternativas existentes en el mercado, que se centran en la realización de aspectos específicos del programa que se ha creado.

Este estudio de costos se presenta como una herramienta esencial para entender el

rendimiento financiero y la ventaja competitiva de nuestro programa en el contexto de las soluciones tecnológicas disponibles. Al comparar los costos asociados con la implementación y el uso de nuestro programa con los costos relacionados con las alternativas, podremos identificar de manera más clara las áreas donde se generan ahorros y eficiencias, así como las ventajas cualitativas que pueden diferenciar nuestro producto. Esto, a su vez, ayudará a respaldar las decisiones empresariales y estratégicas relacionadas con la adopción y promoción de nuestro programa en el mercado.

5.1.1 CALCULO DEL PRECIO DEL PROGRAMA DE IDENTIFICACIÓN DE SECCIONES PETROGRÁFICAS

En la administración de proyectos de software uno de los modelos utilizados es el modelo COCOMO, nombrado así por sus siglas en inglés *Constructive Cost Model*, el cual fue empleado para el cálculo del proyecto teniendo como ecuación de cálculo del esfuerzo la siguiente:

$$E = a * (KLOC)^b \quad \text{Ec. (1)}$$

Donde:

E = Esfuerzo

KLOC = Número estimado de líneas de código del proyecto, miles

a = factor constante

b = factor constante

También se utilizó la ecuación del desarrollo del proyecto:

$$T_d = c * E^d \quad \text{Ec. (2)}$$

Donde:

T_d = Tiempo de desarrollo requerido

c = factor constante

d = factor constante

Los valores de las constantes se presentan en la siguiente tabla:

Tabla 13: Valores de constantes

MODO DE DESARROLLO	a	b	c	d
ORGÁNICO	3,2	1,05	2,5	0,38
SEMI – ORGÁNICO	3,0	1,12	2,5	0,35
ACOPLADO	2,8	1,20	2,5	0,32

Nota: Extraído de Modelo COCOMO, por Yadith Miranda Silva.

El modo de desarrollo adecuado para el programa es el orgánico por consiguiente utilizaremos esas constantes para el cálculo, el código en total tiene 863 líneas de código, excluyendo las capas ocultas del entrenamiento automático, debido a que las unidades del KLOC es en miles el dato a reemplazar sería 0.863.

Cálculo del esfuerzo en función de la Ecuación 1:

$$E = a * (KLOC)^b$$

$$E = 3.2 * (0.863)^{1.05}$$

$$E = 2,741 \text{ meses} - \text{hombre}$$

Cálculo del tiempo de desarrollo del producto en función de la Ecuación 2:

$$T_d = c * E^d$$

$$T_d = 2.5 * 2.741^{0.38}$$

$$T_d = 3.667 \text{ meses}$$

Se contabilizaron un total de 863 líneas de código en total para la creación de los modelos de la clasificación y de la detección y el diseño de la interfaz y presentación de resultados, al ser un valor inferior a las 50000 líneas de código corresponden a un proyecto orgánico, obteniéndose de esta manera un de desarrollo del proyecto de aproximadamente 4 meses. Realizando una investigación en el sector laboral de programadores nos brindaron la siguiente información: el precio del trabajo es de 40 Bs la hora por el desarrollo de un código de inteligencia artificial. Considerando además un mes de 20 días laborables. Con estos datos se puede realizar el cálculo del sueldo total del proyecto mediante la siguiente ecuación:

$$\text{Sueldo} = T_d * \text{Precio trabajado} \quad \text{Ec. (3)}$$

$$\text{Sueldo} = 4 \text{ meses} * \frac{20 \text{ días laborables}}{1 \text{ mes}} * \frac{8 \text{ horas}}{1 \text{ día laboral}} * \frac{40 \text{ Bs}}{1 \text{ hora}}$$

$$\text{Sueldo} = 25.600 \text{ Bs}$$

Para el cálculo del sueldo en dólares, se tomó el tipo de cambio de compra en dólares oficializado por el Banco Central de Bolivia en fecha 12 de diciembre de 2023, teniendo la equivalencia de 1 dólar es equivalente a 6,86 bolivianos:

$$\text{Sueldo} = 25.600 \text{ Bs} * \frac{1 \text{ USD}}{6,86 \text{ Bs}}$$

$$\text{Sueldo} = 3.731,78 \text{ USD} \cong 3750 \text{ USD}$$

A continuación, se mostrará la tabla realizada para el análisis de costo beneficio:

Tabla 14: Análisis del costo

	EXPRESADO EN BOLIVIANOS		EXPRESADO EN DÓLARES	
	Mes	Por 4 Meses	Mes	Por 4 Meses
<u>Suministros</u>				
Energía Eléctrica	120,00	480,00	17,49	69,97
Internet	346,00	1.384,00	50,44	201,75
Comunicaciones (Celular)	30,00	120,00	4,37	17,49
<u>Salarios / Sueldos (Mano De Obra)</u>				
Sueldo	6.400,00	25.600,00	937,50	3.750,00
Costos De Capacitación	5.500,00	22.000,00	801,75	3.207,00
Actualización Del Programa	2.975,00	11.900,00	433,67	1.734,69
<u>Impuestos</u>				
Impuesto Al Valor Agregado IVA 13%		14.476,80		2.080,00
Impuesto A Las Transacciones IT 3%		3.340,80		480,00
Impuesto A Las Utilidades IUE 12,5%		2.227,20		320,00
<u>Costes De Inversión</u>				
Compra De Computadora		13.850,40		1.990,00
Costo Del Producto		<u>95.379,20</u>		<u>13.855,46</u>

Nota: Elaboración propia en base al análisis económico realizado.

Para el costo de internet se consideró los diferentes planes de Internet de las diferentes

empresas distribuidoras del servicio en el país optando por el servicio Plan de Fibra Óptica Hogar 10 M, con una velocidad de 68 Mbps de la empresa Entel con un costo mensual de 346 Bs. Bajo el mismo criterio se otorgaron un presupuesto básico para los servicios como la energía eléctrica y las comunicaciones.

Para calcular el determinante de la relación costo-beneficio, es necesario considerar el costo de venta que se presenta a continuación:

El costo de venta en bolivianos es de 111.360,00, y el costo de venta en dólares es de 16.000,00. Estos datos nos permitirán calcular la relación que determina el valor del costo-beneficio, lo cual es un indicador clave para evaluar la viabilidad del proyecto.

La fórmula para calcular el valor del costo-beneficio es la siguiente:

$$\text{Valor del costo – beneficio} = \frac{\text{beneficios netos}}{\text{Costos de inversion}}$$

Sustituyendo los valores:

En bolivianos,

$$\text{Valor del costo – beneficio} = \frac{111.360,00}{95.379,20}$$

$$\text{Valor del costo – beneficio} = 1,17$$

En dólares,

$$\text{Valor del costo – beneficio} = \frac{16.000,00}{13.855,46}$$

$$\text{Valor del costo – beneficio} = 1,16$$

El índice del valor del costo-beneficio indica que, si es mayor que uno, el proyecto es viable y se puede llevar a cabo. Además, cabe recalcar que el monto final indica el costo estimado de cuánto costaría el desarrollo del programa para su implementación de manera empresarial.



CAPITULO 6 – CONCLUSIONES Y RECOMENDACIONES

6.1 CONCLUSIONES

Tras la evaluación de los resultados del estudio del presente proyecto de investigación, se tiene las siguientes conclusiones:

Mediante la identificación de dos muestras de Calizas y una Subarcosa, extraídas en la provincia de Palos Blancos, y la comparación de los resultados del programa con los resultados de laboratorio emitidos por el Instituto de Investigaciones Geográficas y Medio ambiente se verifico el cumplimiento con la identificación de secciones petrográficas.

En base a la información recolectada dentro de la investigación exhaustiva que se realizó para la selección del lenguaje de programación más adecuado para el desarrollo del programa en base al aprendizaje automático. Esta selección involucro la evaluación de cuatro lenguajes, teniendo en cuenta los factores como la eficiencia en el procesamiento de datos, la disponibilidad de bibliotecas de Machine Learning, los requerimientos del sistema y la comunidad de desarrollo. Después de una cuidadosa consideración, se optó por el lenguaje de programación de código abierto Python que permitió una implementación eficaz de las redes neuronales convolucionales, lo que resulto en un sistema que pudo procesar y analizar las imágenes de secciones petrográficas con rapidez y precisión.

La recopilación y preparación de la base de datos de imágenes de secciones petrográficas fue un paso crítico en el proceso. Se realizo una extensa búsqueda por database de imágenes de secciones petrográficas representativas, al no existir una database preexistente se procedió a la creación de una a raíz de varias fuentes de imágenes de servicios geológicos de diferentes países. Estas imágenes se sometieron a un proceso de etiquetado preciso, donde se identificaron y

etiquetaron con cuidado las características clave de cada sección petrográfica. La calidad y confiabilidad de la base de datos se mantuvo en un nivel óptimo, lo que garantizó que el modelo de aprendizaje automático pudiera entrenarse con datos de alta calidad y, por lo tanto, alcanzar un rendimiento excepcional en la identificación de las muestras.

El desarrollo del programa se realizó en dos fases fundamentales: un clasificador de tipos de roca y un detector de características mineralógicas y/o micro fosilíferas en fotografías de secciones petrográficas. Estas dos partes son componentes esenciales de una herramienta integral para el proyecto y se complementan mutuamente. En la primera fase, el "Clasificador de Tipo de Roca," se utilizó un conjunto de datos de imágenes de secciones petrográficas que representaban 26 tipos de rocas en diversas condiciones. El programa se desarrolló utilizando TensorFlow y Keras, con OpenCV para cargar y procesar imágenes. En la segunda fase, el "Detector de Características de Secciones Petrográficas," se utilizó la funcionalidad de detección de objetos en redes neuronales convolucionales. El conjunto de datos consistió en 14 categorías y las imágenes se etiquetaron de manera semiautomática con el programa MakeSense. Las bibliotecas utilizadas incluyeron NumPy, TensorFlow para trazar curvas de entrenamiento y visualizar imágenes. La arquitectura fue optimizada para garantizar un rendimiento sobresaliente.

La validación del rendimiento del programa se realizó en dos partes. El programa dentro de su entrenamiento cuenta con la parte de validación del entrenamiento y un auto ajuste en base de las etiquetas del conjunto de imágenes de validación, el cual llegó a una precisión de 95.75%. debido a que la precisión es superior el 90% se acepta el entrenamiento como valido, posteriormente se realizó la validación en base a la comparación con resultados del programa con los emitidos por un laboratorio especializado, Instituto de Investigaciones Geológicas y Medio Ambiente, que tenía experiencia en la identificación de secciones petrográficas. Los resultados

obtenidos revelaron una alta concordancia y precisión entre el programa desarrollado y las evaluaciones del laboratorio. Esta validación respaldó la efectividad del programa en la identificación de las secciones, lo que sugiere que el sistema tiene un potencial significativo en aplicaciones prácticas, donde la automatización y la precisión en la identificación de muestras son esenciales.

En resumen, estos objetivos han sido alcanzados con éxito, y el programa desarrollado representa una contribución valiosa en el campo de la identificación de secciones petrográficas utilizando redes neuronales convolucionales. Este proyecto no solo es un logro técnico, sino que también sienta las bases para futuras investigaciones y aplicaciones prácticas en la industria, donde la automatización y la precisión en la identificación de muestras son de suma importancia.

6.2 RECOMENDACIONES

Tras la evaluación de los resultados del estudio del presente proyecto de investigación, se tiene las siguientes recomendaciones:

La falta de database en el área de Geología e Ingeniería Petrolera es evidente, por ende, se recomienda incentivar a los estudiantes a realizar investigación y crear base de datos con el respaldo de la Universidad Mayor de San Andrés, y de esta manera ampliar el área de investigación de la carrera.

En el desarrollo del programa se presentaron limitaciones debido a los requerimientos del sistema, para el mejoramiento del programa y el acceso a mejores funciones que optimicen el rendimiento del programa se recomienda un equipo con mayores capacidades del procesamiento y una tarjeta gráfica con mayor capacidad.

El área del Subandino Norte no se encuentra ampliamente explorada, por ende, se

recomienda que la carrera realice exploraciones de investigación geológica en este sector. Aprovechando la ubicación de la universidad, de esta manera la carrera amplia sus trabajos de investigación y el instituto de la carrera de ingeniería petrolera podrá realizar la creación de data bases que generaran un valor agregado a nuestra carrera.



BIBLIOGRAFÍA

Adams, A. E., MacKenzie, W. S., & Guilford, C. (1984). Preparation of a thin section of a rock. En A. E. Adams, W. S. MacKenzie, & C. Guilford, *Atlas of sedimentary rocks under the microscope* (págs. 97-98). Inglaterra: Longman Group.

Adams, A. E., Mackenzie, W., & Guilford, C. (1984). *Atlas of sedimentary rocks under the microscope*. London: Taylos & Francis Ltd.

Alvarez Munárriz, L. (1994). *Fundamentos de la inteligencia artificial*. Murcia: Secretariado de Publicaciones Universidad de Murcia.

Amazon Web Services. (2023). *¿Que es Java?* Obtenido de <https://aws.amazon.com/es/what-is/java/>

Castillo Garcia, H. L., Angamarca Lliguin, L. A., Ojeda Pardo, F. R., & Cuenca Gualan, D. I. (2021). *Introducción a la Petrografía*. Paraná: Atena.

IBM. (noviembre de 2021). *¿Qué son las redes neuronales?* Obtenido de <https://www.ibm.com/es-es/topics/neural-networks>

IBM. (17 de 08 de 2021). *Documentacion*. Obtenido de El modelo de redes neuronales: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>

ID DIGITAL SCHOOL. (18 de Julio de 2023). *ID BOOT CAMPS*. Obtenido de ¿Qué son las librerías de Python?: <https://iddigitalschool.com/bootcamps/que-son-las-librerias-de-python/#:~:text=En%20el%20contexto%20de%20Python,la%20funcionalidad%20b%C3%A1sica%20del%20lenguaje.>

Maldonado, Y. (2021). *Geología Web*. Obtenido de Moscovita:

<https://geologiaweb.com/minerales/moscovita/>

MATLAB. (2023). *Mathworks*. Obtenido de Matemáticas. Gráficas. Programación.: <https://la.mathworks.com/products/matlab.html#:~:text=MATLAB%20es%20una%20plataforma%20de,desarrollar%20algoritmos%20y%20crear%20modelos.>

Python. (04 de Noviembre de 2023). *Pyhton.org*. Obtenido de Documentation: El tutorial de Python: <https://docs.python.org/es/3/tutorial/>

Serna A., A., Acevedo M., E., & Serna M., E. (2017). Principios de la Inteligencia Artificial en las Ciencias Computacionales. En E. Serna M., *Desarrollo e inovacion en ingenieria* (págs. 161-172). Medellin: IAI.

Servicio Geologico Mexicano. (22 de 03 de 2017). *Servicio Geologico Mexicano*. Obtenido de Petrografia: <https://www.sgm.gob.mx/Web/MuseoVirtual/Rocas/Petrografia.html>

Sierra Ramos, J. M. (27 de 02 de 2022). *Universidad Complutense de Madrid*. Obtenido de Introduccion a las redes neuronales artificiales: <https://docta.ucm.es/rest/api/core/bitstreams/d49dbf3b-af91-41be-aeac-40b6b1e78ea8/content>

Tarbuck, E. J., & Lutgens, F. K. (2005). *Ciencias de la Tierra: Una Introduccion a la Geologia Fisica*. Madrid: Pearson Education S.A.

The MathWorks Inc. (2023). *The MathWorks Inc*. Obtenido de Machine Learning con MATLAB: <https://la.mathworks.com/discovery/machine-learning.html#machine-learning-with-matlab>

Tucker, M. E. (2013). *Petrologia Sedimentaria*. Blackwell Science.

Universidad de Valladolid. (2020). *Fundamentos de programación*. Obtenido de El

lenguaje C++: https://www2.eii.uva.es/fund_inf/cpp/temas/1_introduccion/introduccion.html#el-lenguaje-c



ANEXOS

ANEXO A: Código del entrenamiento del programa

DETECTOR

```
import numpy as np

import tensorflow as tf

from tensorflow import keras

from tensorflow.keras import layers

from tensorflow.keras.applications import MobileNetV2

from tensorflow.keras.preprocessing.image import ImageDataGenerator

import matplotlib.pyplot as plt

# Montar Google Drive para acceder a la base de datos de imágenes

from google.colab import drive

drive.mount('/content/drive')

# Ruta a la carpeta que contiene las imágenes de las láminas de roca

data_dir = '/content/drive/MyDrive/DB- DETECTOR'
```

```
path_Imagenes='/content/drive/MyDrive/DB- DETECTOR/IMAGENES'
```

```
path_Imagenes_train='/content/drive/MyDrive/DB- DETECTOR/IMAGENES/TRAIN'
```

```
path_Imagenes_Val='/content/drive/MyDrive/DB- DETECTOR/IMAGENES/VAL'
```

```
path_Labels='/content/drive/MyDrive/DB- DETECTOR/LABELS'
```

```
path_Labels_train='/content/drive/MyDrive/DB- DETECTOR/LABELS/TRAIN'
```

```
path_Labels_Val='/content/drive/MyDrive/DB- DETECTOR/LABELS/VAL'
```

```
path_carpeta_test='/content/drive/MyDrive/DB- DETECTOR/LABELS/VAL'
```

```
path_img_test='/content/drive/MyDrive/IGEMA/PETR.69 FERNANDA ZENTENO
```

```
(11).jpg'
```

```
from tensorflow.keras.preprocessing.image import ImageDataGenerator
```

```
# Directorios de datos
```

```
train_dir = path_Imagenes_train
```

```
val_dir = path_Imagenes_Val
```

```
test_dir = path_carpeta_test
```

```
# Configuración de aumento de datos
```

```
train_datagen = ImageDataGenerator(
```

```
    rescale=1.0 / 255,
```

```
    rotation_range=20,
```

```
    width_shift_range=0.2,
```



```

    height_shift_range=0.2,

    shear_range=0.2,

    zoom_range=0.2,

    horizontal_flip=True,

    fill_mode='nearest'

)

val_datagen = ImageDataGenerator(rescale=1.0 / 255)

test_datagen = ImageDataGenerator(rescale=1.0 / 255)

# Generadores de datos

batch_size = 32

train_generator = train_datagen.flow_from_directory(

    train_dir,

    target_size=(224, 224),

    batch_size=batch_size,

    class_mode='categorical'

)

val_generator = val_datagen.flow_from_directory(

    val_dir,

```

```

    target_size=(224, 224),

    batch_size=batch_size,

    class_mode='categorical'

)

test_generator = test_datagen.flow_from_directory(

    test_dir,

    target_size=(224, 224),

    batch_size=batch_size,

    class_mode='categorical'

)

base_model = MobileNetV2(input_shape=(224, 224, 3), include_top=False)

x = layers.GlobalAveragePooling2D()(base_model.output)

x = layers.Dense(10, activation='softmax')(x)

model = keras.Model(inputs=base_model.input, outputs=x)

model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])

history = model.fit(train_generator, validation_data=val_generator, epochs=10)

# Después de completar el entrenamiento

# Guarda el modelo entrenado en un archivo

```

```
model.save('/content/modelo_entrenado.h5')

# URL de Google Drive donde deseas guardar el modelo

model_url = '/content/drive/MyDrive'

# Copia el modelo a Google Drive

!cp /content/modelo_entrenado.h5 "$model_url"

import cv2

# Carga de la imagen

image = cv2.imread(path_img_test) # Reemplaza 'imagen.jpg' con la ruta de tu imagen

# Redimensiona la imagen al tamaño esperado

desired_size = (224, 224)

image = cv2.resize(image, desired_size)

# Realiza la detección de objetos utilizando el modelo cargado

predictions = model.predict(np.expand_dims(image, axis=0))

# Procesa las predicciones y muestra los resultados

# Esto depende de cómo estén estructuradas tus predicciones y clases

# Muestra la imagen con las detecciones

from google.colab.patches import cv2_imshow

cv2_imshow(image)
```

```

#cv2.imshow('Object Detection', image)

cv2.waitKey(0)

cv2.destroyAllWindows()

from tensorflow import keras

import cv2

import numpy as np

# Cargar el modelo previamente entrenado

model = keras.models.load_model('/content/modelo_entrenado.h5') # Reemplaza con la
ruta a tu modelo

# Cargar la imagen de entrada

image = cv2.imread('/content/drive/MyDrive/IGEMA/PETR.69 FERNANDA ZENTENO
(11).jpg') # Reemplaza con la ruta de tu imagen

# Preprocesar la imagen (ajusta el tamaño y normaliza los valores de píxeles)

image = cv2.resize(image, (224, 224))

image = image / 255.0 # Normaliza los valores de píxeles

# Realizar la predicción

predictions = model.predict(np.expand_dims(image, axis=0))


# Procesar las predicciones (ajusta esto según tu modelo y datos)

# Supongamos que el modelo devuelve una lista de probabilidades para cada clase

```

```
class_labels = ['Calcita', 'Circon', 'Clorita', 'Cuarzo', 'Esparita', 'Foraminiferos', 'Interclastos',  
'Muscovita', 'Oolitos', 'Plagioclasas'] # Reemplaza con las etiquetas reales  
  
predicted_class = np.argmax(predictions)  
  
# Dibuja el resultado en la imagen  
  
label = class_labels[predicted_class]  
  
cv2.putText(image, label, (10, 30), cv2.FONT_HERSHEY_SIMPLEX, 1, (0, 255, 0), 2)  
  
# Muestra la imagen con el resultado  
  
from google.colab.patches import cv2_imshow  
  
cv2_imshow(image)
```


ANEXO B: Interfaz del programa



ANEXO C: Informe petrográfico



UNIVERSIDAD MAYOR DE SAN ANDRÉS
INSTITUTO DE INVESTIGACIONES GEOLÓGICAS Y DEL MEDIO AMBIENTE
SERVICIOS LABORATORIOS
La Paz - Bolivia



DESCRIPCION PETROGRAFICA

Número de Orden: 69/2021

Solicitante: María Fernanda Zenteno Castillo

No. De Muestras: 3

Analizado por: Ing. Hans Resnikowski P.

Fecha: 22/11//2021

Sección No. 3

Nombre de la roca: Caliza Biomicrita

Descripción Mesoscópica

Fragmento de roca sedimentaria química de grano fino, es de color gris marrón en superficie fresca y marrón en superficie alterada, es competente y masiva. Está compuesta por calcita (efervescente al entrar en contacto con ácido clorhídrico), microfósiles y escasos intraclastos de cuarzo. También existen aisladas vetillas de calcita y patinas superficiales hidróxidos de hierro.

Descripción microscópica.

Micrita	50%
Microfósiles	35%
Esparita	14%
Intraclastos	1%
Menas de hierro	<1%
TOTAL	100%

Descripción Microscópica.

Micrita. Es el componente mayoritario en la roca, es masiva y sostiene a los microfósiles y a los clastos de cuarzo.

Microfósiles. Están presentes diferentes especies de foraminíferos. Miden entre 100 μ m y 2 mm.

Intraclastos. Están compuestos por cuarzo detrítico, los cuales tienen formas subangulosas y en promedio miden 50 μ m.

Esparita. Se encuentra como microvetillas y reemplazando en algunos sectores a la micrita. Algunos cristales presentan maclas.

Menas de hierro. Tienen formas redondeadas, su presencia es muy escasa. Miden en promedio 10 μ m.

Clasificación. La roca se clasifica como una Caliza biomicrita (Según la clasificación de Folk, 1962)



Sección No. 7a

Nombre de la roca: Subarcosa carbonatada de grano fino

Descripción Mesoscópica

Fragmento roca sedimentaria de grano fino y de color gris claro. Es homogénea, compacta, presenta cierta laminación y tiene una textura detrítica. Está compuesta por clastos de cuarzo, calcita, feldespatos, muscovita y menas de hierro.

Descripción microscópica.

Cuarzo	80%
Plagioclasas	3%
Ortosa	2%
Microclina	1%
Muscovita	2%
Clorita	1%
Circón	<1%
Calcita	8%
Materia orgánica	1%
Menas de hierro	2%
TOTAL	100%

Cuarzo. Los clastos presentan formas subangulosas, en general tienen baja esfericidad y buena clasificación. Sus contactos son cóncavo-convexos entre sí. En los clastos más alargados se aprecia una orientación preferencial paralela a la estratificación. En promedio los clastos miden 150 μm .

Plagioclasas. Tienen formas subangulosas son de la variedad oligoclasa (An-28). Sus maclas son del tipo albíta y polisintética. Miden hasta 200 μm .

Ortosa. Presenta formas subredondeadas, están parcialmente sericitizadas. En promedio miden 150 μm .

Microclina. Tienen formas subangulosas, presentan sus típicas maclas en rejilla y en promedio miden 150 μm .

Muscovita. Tienen formas aciculares y tabulares, en algunos sectores muestran una orientación preferencial. Miden entre 100 y 300 μm .

Clorita. Presenta formas subredondeadas y fibrosas, miden hasta 180 μm .

Circón. Sus microcristales son subangulosos, miden hasta 80 μm .

Calcita. Presenta formas irregulares se encuentra cementando a los clastos en algunos sectores.

Materia Orgánica. Se encuentra como masas irregulares dispersas.

Menas de Hierro. Tienen formas muy variables desde redondeadas hasta subangulosas e irregulares. Miden entre 10 y 70 μm .

Textura. La roca tiene una textura detrítica

Clasificación. La roca se clasifica como una Subarcosa carbonatada de grano fino.



Sección No. 11

Nombre de la roca: Caliza Biomicrita

Descripción Mesoscópica

Fragmento de roca sedimentaria química de grano fino, es de color marrón rojizo, es muy competente y homogénea. Está compuesta por calcita (efervescente al entrar en contacto con ácido clorhídrico), microfósiles y aislados intraclastos de cuarzo. También existe un fósil braquiópodo (*Neoespirifer condor*) de 6 cm de largo y algunas vetillas de calcita.

Descripción microscópica.

Micrita	45%
Microfósiles	23%
Esparita	10%
Oolitos	10%
Intraclastos	5%
Hidróxidos de Hierro	5%
Cuarzo Hidrotermal	1%
Menas de hierro	1%
TOTAL	100%

Descripción Microscópica.

Micrita. Es el componente mayoritario en la roca, es masiva y sostiene a los microfósiles, oolitos e intraclastos.

Microfósiles. Están presentes diferentes especies de foraminíferos. Miden entre 100 μm y 700 μm .

Esparita. Se encuentra como microvetillas y reemplazando en algunos sectores a la micrita. Los cristales presentan maclas polisintéticas.

Oolitos. Tienen formas circulares, algunos tienen sus núcleos de esparita. Miden entre 100 y 300 μm .

Intraclastos. Están compuestos por cuarzo detrítico y en menor proporción plagioclasas, tienen formas subangulosas y redondeadas, en muchos casos se encuentran fracturados. En promedio miden 100 μm .

Hidróxidos de Hierro. Tienen formas irregulares, se encuentran reemplazando en algunos sectores a la micrita.


Cuarzo Hidrotermal. Se encuentra como microvetillas y relleno de algunas vesículas.

Menas de hierro. Tienen formas redondeadas y subangulosas, miden entre 10 y 70 μm .

Clasificación. La roca se clasifica como una Caliza biomicrita (Según la clasificación de Folk, 1962)



ANEXO D: Fotografías de la expedición geológica







ANEXO E: Imagen satelital de los puntos de recolección de muestras y de las muestras seleccionadas para laboratorio



ANEXO F: Punto totales de muestreo

Punto de muestreo	X	Y	Z
1	696385.26	8291000.63	883
2	696546.77	8291060.73	913
3	697086.84	8291458.83	958
4	697179.08	8291436.52	964
5	697221.36	8291848.08	1007
6	697224.39	8291854.2	999
7	699819.49	8296805.76	785
8	699802.18	8296873.34	788
9	705283.86	8301937.93	542
10	707228.80	8310316.26	906
11	703332.34	8299733.91	605
12	699986.84	8290988.13	1254
13	700653.30	8290825.56	1105

ANEXO G: Fotografía de muestras de mano mandadas a laboratorio.

MUESTRA N° 3




MUESTRA N°7A



MUESTRA N° 11



ANEXO H: Mapa Geológico con las ubicaciones de las tomas de muestra



MARÍA FERNANDA ZENTENO CASTILLO

mariafernandazentenolp@gmail.com

Cel: 65149400 / 71505636



MINISTERIO DE DESARROLLO PRODUCTIVO Y ECONOMIA PLURAL



DIRECCIÓN DE DERECHO DE AUTOR Y DERECHOS CONEXOS
RESOLUCIÓN ADMINISTRATIVA NRO. 1-572/2024
La Paz, 5 de Marzo del 2024

VISTOS:

La solicitud de Inscripción de Derecho de Autor presentada en fecha 29 de Febrero del 2024, por MARIA FERNANDA ZENTENO CASTILLO con C.I. N° 6941503 LP, con número de trámite DA 325/2024, señala la pretensión de inscripción del Proyecto de Grado titulado: "DESARROLLO DE UN PROGRAMA PARA LA IDENTIFICACIÓN DE SECCIONES PETROGRÁFICAS MEDIANTE LA IMPLEMENTACIÓN DE REDES NEURONALES CONVOLUCIONALES", cuyos datos y antecedentes se encuentran adjuntos y expresados en el Formulario de Declaración Jurada.

CONSIDERANDO

Que, en observación al Artículo 4º del Decreto Supremo N° 27938 modificado parcialmente por el Decreto Supremo N° 28152 el "Servicio Nacional de Propiedad Intelectual SENAPI, administra en forma desconcentrada e integral el régimen de la Propiedad Intelectual en todos sus componentes, mediante una estricta observancia de los regímenes legales de la Propiedad Intelectual, de la vigilancia de su cumplimiento y de una efectiva protección de los derechos de exclusiva referidos a la propiedad industrial, al derecho de autor y derechos conexos; constituyéndose en la oficina nacional competente respecto de los tratados internacionales y acuerdos regionales suscritos y adheridos por el país, así como de las normas y regímenes comunes que en materia de Propiedad Intelectual se han adoptado en el marco del proceso andino de integración".

Que, el Artículo 16º del Decreto Supremo N° 27938 establece "Como núcleo técnico y operativo del SENAPI funcionan las Direcciones Técnicas que son las encargadas de la evaluación y procesamiento de las solicitudes de derechos de propiedad intelectual, de conformidad a los distintos regímenes legales aplicables a cada área de gestión". En ese marco, la Dirección de Derecho de Autor y Derechos Conexos otorga registros con carácter declarativo sobre las obras del ingenio cualquiera que sea el género o forma de expresión, sin importar el mérito literario o artístico a través de la inscripción y la difusión, en cumplimiento a la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina, Ley de Derecho de Autor N° 1322, Decreto Reglamentario N° 23907 y demás normativa vigente sobre la materia.

Que, la solicitud presentada cumple con: el Artículo 6º de la Ley N° 1322 de Derecho de Autor, el Artículo 26º inciso a) del Decreto Supremo N° 23907 Reglamento de la Ley de Derecho de Autor, y con el Artículo 4º de la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina.

Que, de conformidad al Artículo 18º de la Ley N° 1322 de Derecho de Autor en concordancia con el Artículo 18º de la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina, referentes a la duración de los Derechos Patrimoniales, los mismos establecen que: "la duración de la protección concedida por la presente ley será para toda la vida del autor y por 50 años después de su muerte, a favor de sus herederos, legatarios y cesionarios".



Handwritten signature and stamp



Oficina Central - La Paz
Av. Montes, N° 25,
entre Esp. Uruguay y
C. Batallón Héroes.
Telf.: 219200
219205 - 219201

Oficina - Santa Cruz
Av. Uruguay, Calle
prolongación Quijano,
N° 25, Edif. Bicefariano.
Telf.: 317192 - 77042936

Oficina - Cochabamba
Calle Bolívar, N° 721,
entre 16 de Julio y Arceana.
Telf.: 444443 - 77042937

Oficina - El Alto
Av. Juan Pablo II, N° 2560
Edif. Multicentro El Cerro
112a. Foa 1, Of. 54,
Zona 16 de Julio.
Telf.: 7141001 - 77042939

Oficina - Ortopléaca
Calle Kálmeco 1, N° 364
cas. esp. Urcuagaita,
Zona Parque Bolívar.
Telf.: 77005473

Oficina - Tarija
Av. La Paz, entre
Calle Cero Trigo y Avenida
Edif. Santa Clara, N° 243.
Telf.: 77009266

Oficina - Orma
Calle 6 de Octubre N° 5827
entre Apacheco y Junín,
Calleja Central, Of. 24.
Telf.: 6700008

Oficina - Potosí
Av. Villazón entre calles
Hernández Alba y San Alberto,
Edif. AR, Salinas N° 22,
Primer Piso, Of. 11.
Telf.: 7700010

www.senapi.gob.bo

Que, se deja establecido en conformidad al Artículo 4º de la Ley Nº 1322 de Derecho de Autor, y Artículo 7º de la Decisión 351 Régimen Común sobre Derecho de Autor y Derechos Conexos de la Comunidad Andina que: "...No son objeto de protección las ideas contenidas en las obras literarias, artísticas, o el contenido ideológico o técnico de las obras científicas ni su aprovechamiento industrial o comercial".

Que, el artículo 4, inciso e) de la ley 2341 de Procedimiento Administrativo, instituye que: "... en la relación de los particulares con la Administración Pública, se presume el principio de buena fe. La confianza, la cooperación y la lealtad en la actuación de los servidores públicos y de los ciudadanos ...", por lo que se presume la buena fe de los administrados respecto a las solicitudes de registro y la declaración jurada respecto a la originalidad de la obra.

POR TANTO

El Director de Derecho de Autor y Derechos Conexos sin ingresar en mayores consideraciones de orden legal, en ejercicio de las atribuciones conferidas

RESUELVE:

INSCRIBIR en el Registro de Tesis, Proyectos de Grado, Monografías y Otras Similares de la Dirección de Derecho de Autor y Derechos Conexos, el Proyecto de Grado titulado: "DESARROLLO DE UN PROGRAMA PARA LA IDENTIFICACIÓN DE SECCIONES PETROGRÁFICAS MEDIANTE LA IMPLEMENTACIÓN DE REDES NEURONALES CONVOLUCIONALES", a favor de la autora y titular: MARIA FERNANDA ZENTENO CASTILLO con C.I. Nº 6941503 LP, quedando amparado su derecho conforme a Ley, salvando el mejor derecho que terceras personas pudieren demostrar.

Regístrese, Comuníquese y Archívese.


Abg. Carlos Alberto Soruco Arroyo
DIRECTOR DE DERECHO DE AUTOR
Y DERECHOS CONEXOS
SERVICIO NACIONAL DE PROPIEDAD INTELECTUAL



Oficina Central - La Paz
Av. Montes, N° 515,
entre Esq. Uruguay y
C. Estación Elviani.
Telf.: 2192000
219276 - 219251

Oficina - Santa Cruz
Av. Uruguay, Calle
prolongación Pujato,
N° 29, Edif. Bicentenario.
Telf.: 320750 - 7004336

Oficina - Cochabamba
Calle Bolívar, N° 731,
entre 16 de Julio y Antezana.
Telf.: 444403 - 7004357

Oficina - El Alto
Av. Juan Pablo II, N° 2560
Edif. Multicentro El Cerro
Edif. Piso 1, Of. 58,
Zona 16 de Julio.
Telf.: 704001 - 7004309

Oficina - Chuquiaguana
Calle Kilómetro 1, N° 364
cruce exp. Umicaguana,
Zona Parque Bolívar.
Telf.: 7205873

Oficina - Tarija
Av. La Paz, entre
Calle Ciro Véliz y Avaroa
Edif. Santa Clara, N° 343.
Telf.: 7205286

Oficina - Oruro
Calle 6 de Octubre N° 5837
entre Apruebo y Junín,
Galería Central, Of. 4.
Telf.: 620088

Oficina - Potosí
Av. Villazón entre calles
Wenceslao Albo y San Alberto,
Edif. AN, Salinas N° 342,
Primer Piso, Of. 11.
Telf.: 7206810