



Pontificia Universidad
JAVERIANA
Cali

SISTEMA DE RECONOCIMIENTO FACIAL EN TIEMPO REAL ORIENTADO AL CONTROL DE ACCESO
EMPRESARIAL

ANDRÉS DAVID BARRIOS RODRIGUEZ - 8974519
JESÚS RAFAEL OLIER OLIER - 8984669

*Proyecto Aplicado para optar al título de
Magister en Ciencia de Datos*

Director(a)
MANUEL GUILLERMO FORERO VARGAS

FACULTAD DE INGENIERÍA Y CIENCIAS
MAESTRÍA EN CIENCIA DE DATOS
SANTIAGO DE CALI, DICIEMBRE 1 DE 2024

Tabla de contenido

INTRODUCCIÓN.....	5
1. DEFINICIÓN DEL PROBLEMA.....	6
1.1. PLANTEAMIENTO DEL PROBLEMA.....	6
1.2. FORMULACIÓN DEL PROBLEMA.....	6
2. OBJETIVOS DEL PROYECTO	7
2.1 OBJETIVO GENERAL	7
2.2 OBJETIVOS ESPECÍFICOS.....	7
3. MARCO TEÓRICO Y ANTECEDENTES	8
3.1. MARCO TEÓRICO	8
CONTROL DE ACCESO DE PERSONAL.....	8
TIPOS DE CONTROL.....	9
BIOMETRÍA.....	9
FUNCIONAMIENTO DEL RECONOCIMIENTO FACIAL.....	10
3.1.1 TÉCNICAS DE EXTRACCIÓN DE CARACTERÍSTICAS	10
3.1.2 APRENDIZAJE AUTOMÁTICO	16
3.1.3 MÉTRICAS DE MEDICIÓN.....	19
3.1.3 TÉCNICAS Y MODELOS DE RECONOCIMIENTO FACIAL	22
REDES SIAMESAS.....	22
EIGENFACE RECOGNIZER.....	24
FISHER FACE RECOGNIZER.....	25
LBPH RECOGNIZER.....	25
3.2. ANTECEDENTES	26
4.EVALUACIÓN DE REQUERIMIENTOS: IDENTIFICACIÓN DE LOS RECURSOS NECESARIOS PARA LA EJECUCIÓN DEL PROYECTO.....	27
4.1 HARDWARE	27
4.2 SOFTWARES DE IMPLEMENTACIÓN PARA EL PROYECTO.....	30
4.3 CAPTURA Y RECOPIACIÓN DE IMÁGENES PARA LA BASE DE DATOS.	33
5.IMPLEMENTACIÓN Y EVALUACIÓN DE MODELOS	36
5.1 CONFIGURACIÓN DE LOS MODELOS.....	36

5.1.1 REDES SIAMESAS.....	36
5.1.2 FISHERFACERECOGNIZER.....	37
5.1.3 LBPHFACERECOGNIZER	37
5.1.4 EIGENFACERECOGNIZER.....	38
5.2 SELECCIÓN DE CARACTERÍSTICAS	38
5.4 RESULTADOS DE EVALUACIÓN.....	39
6. MÉTRICAS DE RENDIMIENTO.....	40
7. PROCESAMIENTO EFICIENTE DE DATOS	43
7.1 PREPROCESAMIENTO DE IMÁGENES	43
7.2 USO DE ACELERACIÓN POR GPU	43
7.3 RESULTADOS DE OPTIMIZACIÓN	44
8. GESTIÓN DE ERRORES EN EL RECONOCIMIENTO.....	45
9. CONCLUSIONES Y TRABAJOS FUTUROS.....	46
9.1. CONCLUSIONES.....	46
9.2. TRABAJOS FUTUROS.....	48
Referencias	52
ANEXOS.....	¡Error! Marcador no definido.

Lista de Figura

Figura 1. Componentes principales de un conjunto bidimensional de datos.	12
Figura 2. Ejemplo de reducción dimensional al aplicar PCA.	12
Figura 3. Comparación de la proyección de 2 clases en PCA y LD.....	14
Figura 4. LPP conserva la estructura original de datos en comparación con el PCA.	15
Figura 5. Red neuronal convolucional	17
Figura 6. Cálculo de la imagen integral.	22
Figura 7. Estructuras simples formadas por dos, tres y cuatro rectángulos.	23
Figura 8. Descripción esquemática de una cascada de clasificadores. Los números representan la cantidad de rasgos evaluados por etapa.	23
Figura 9. Siameses Network	24
Figura 10. Redes siamesas formula euclidiana.	24
Figura 11. Esquema de Entidad de Relación Operarios Caparrapí	33
Figura 12. Fotos de operarios de la empresa Caparrapí	34
Figura 13. Desarrollo del sistema de reconocimiento facial.....	35
Figura 14. Pasos para la detección de rostros.	35
Figura 15. Resultados de predicción por modelo	39
Figura 16. Comparación de tiempos de predicción entre modelos.....	40
Figura 17. Comparación de precisión entre modelos	42
Figura 18. Tiempos de predicción por modelo.....	42
Figura 19. Comparación de tiempos de entrenamiento entre modelos	44
Figura 20. Distribución de Falsos Positivos y Negativos	46

Lista de Tablas

Tabla 1. Comparativa entre cámaras digitales estudiadas.....	28
Tabla 2. Comparativa de computadores a utilizar	30
Tabla 3. Comparación de softwares de interfaz	31
Tabla 4. Comparación entre gestores de bases de datos.....	32
Tabla 5. Comparación de métricas entre los modelos evaluados	41
Tabla 6. Comparación de tiempos de entrenamiento.....	44

INTRODUCCIÓN

En la era contemporánea, marcada por avances tecnológicos vertiginosos, la integración de tecnologías de inteligencia artificial (IA) se ha convertido en un factor clave en diversos ámbitos de la sociedad, y es que, según McKinsey, el 72% de las empresas a nivel mundial utilizan IA en alguna de sus operaciones, y el 65% específicamente emplean IA generativa, permitiendo la automatización y aceleración de desarrollo en las mejoras operativas de la empresa, como la seguridad [1]. Entre las múltiples facetas de la IA, el reconocimiento facial destaca como una herramienta innovadora con aplicaciones significativas en diversos sectores.

Así las cosas, este proyecto se centró en la intersección de la IA y la seguridad empresarial, aplicándose en la operadora minera Caparrapí, en un contexto donde la eficiencia operativa y la seguridad del personal son esenciales. La implementación de un sistema de reconocimiento facial se presenta como una respuesta estratégica a la carencia de control de acceso eficiente en las instalaciones de la empresa, desencadenando la necesidad de abordar esta problemática de una manera integral. En este sentido, se desarrolló un sistema de reconocimiento facial que optimizó el proceso de registro y acceso de empleados.

En este sentido, este proyecto se planteó no solo como una solución tecnológica, sino como una herramienta clave para elevar la productividad y seguridad en la operadora minera Caparrapí; teniendo en cuenta que la IA ha reportado aumentos de hasta el 10% de la operación actual en empresas mineras [2]; esto, a través de la implementación de modelos de inteligencia artificial especializados, que procuraron una identificación precisa y segura del personal, marcando así un hito en la gestión eficiente de accesos de la empresa.

La escogencia del modelo resultante se basó en el mejor desempeño y eficiencia encontrado en el desarrollo del proyecto, teniendo en cuenta aspectos trascendentales del entorno minero, como alta concentración de polvo y la capacidad de operar en entornos con luz tenue o variable, garantizando la funcionalidad de durabilidad del sistema.

De esta manera, en capítulos posteriores se presentará una descripción a profundidad del problema, la elección de los modelos estudiados, su nivel de desempeño, la estructuración y ejecución del sistema, así como la exposición de resultados y conclusiones. Estos apartados abarcan la mayoría de consideraciones relevantes,

proporcionando un análisis detallado y exhaustivo del proyecto.

1. DEFINICIÓN DEL PROBLEMA

1.1. PLANTEAMIENTO DEL PROBLEMA

En los últimos años, las tecnologías de inteligencia artificial han transformado múltiples aspectos de la vida cotidiana y empresarial, permitiendo la automatización de procesos y la realización de tareas de manera más eficiente. La biometría, como campo enfocado en la identificación basada en características físicas únicas, no ha sido ajena a estos avances, destacándose el reconocimiento facial como una herramienta clave para el control de acceso a aplicaciones, espacios o instancias específicas.

El reconocimiento facial automatizado consiste en detectar rostros en imágenes, normalizarlos para un análisis uniforme y compararlos para determinar similitudes. Este proceso implica la identificación de características distintivas, como la distancia entre los ojos o la forma del rostro, lo que lo convierte en un recurso confiable para autenticar la identidad de una persona [3].

En el caso de la operadora minera Caparrapí, dedicada a la explotación de minas y canteras, la gestión de acceso representaba un desafío importante debido a la falta de un sistema integral de identificación. Desde la perspectiva de la ciencia de datos, este problema ofreció una oportunidad para implementar modelos de reconocimiento facial que optimizarán el control de entrada a sus instalaciones.

Este proyecto busca proporcionar una solución tecnológica que permita identificar al personal de manera precisa y segura. Para ello, se aplicaron algoritmos de reconocimiento facial en tiempo real respaldados por técnicas de recopilación, procesamiento y análisis de datos biométricos, con el objetivo de identificar patrones faciales únicos y mejorar significativamente la gestión de acceso en la empresa.

1.2. FORMULACIÓN DEL PROBLEMA

¿Cómo implementar un sistema de reconocimiento facial en la operadora minera Caparrapí a través del procesamiento de imágenes captadas desde una cámara de seguridad en conjunto con la ejecución de modelos de inteligencia artificial? Esta pregunta general, centrada en el uso de la ciencia de datos, es el pilar del proyecto y da origen a los siguientes aspectos sistematizados:

- ¿Cómo definir de manera precisa los requisitos del sistema de reconocimiento facial a partir de la infraestructura tecnológica disponible para el desarrollo de un sistema eficiente en entornos mineros?

- ¿Cuáles son los modelos específicos de inteligencia artificial más apropiados para abordar los desafíos de reconocimiento facial en un entorno minero, considerando la variabilidad de condiciones lumínicas y la necesidad de procesamiento en tiempo real?
- ¿Cuáles son las métricas de rendimiento específicas, basadas en la ciencia de datos, que permitirán evaluar la eficacia del algoritmo de reconocimiento facial en términos de precisión y confiabilidad?
- ¿De qué manera los principios de la ciencia de datos pueden ser empleados para optimizar el tiempo de respuesta del sistema, asegurando eficiencia operativa en el control de acceso a las instalaciones?
- ¿Cómo se puede implementar un enfoque sistemático, respaldado por la ciencia de datos, para identificar y abordar los errores en la identificación de individuos, garantizando un proceso de mejora continua?

2. OBJETIVOS DEL PROYECTO

2.1 OBJETIVO GENERAL

Elaborar un sistema de reconocimiento facial, a través de modelos de inteligencia artificial que permita optimizar el proceso de registro de ingreso y fortalecer la eficiencia operativa en la operadora minera Caparrapí.

2.2 OBJETIVOS ESPECÍFICOS

- Definir los requisitos del sistema de reconocimiento facial a partir de la infraestructura tecnológica disponible por la empresa minera
- Evaluar diferentes modelos de inteligencia artificial, tales como aprendizaje estadístico, aprendizaje automático y aprendizaje profundo, para determinar cuál se adapta mejor al contexto de reconocimiento facial en el entorno minero.
- Establecer métricas de rendimiento específicas, basadas en el modelado de datos, para evaluar la eficacia del algoritmo de reconocimiento facial en términos de precisión, confiabilidad y adaptabilidad a condiciones cambiantes.
- Implementar estrategias de procesamiento eficiente de datos, respaldadas por técnicas de ciencia de datos, con el objetivo de minimizar el tiempo de respuesta

del sistema de reconocimiento facial, garantizando así una gestión ágil y eficiente del acceso a las instalaciones.

- Diseñar un marco sistemático respaldado por la ciencia de datos para identificar y abordar errores en la identificación de individuos, permitiendo así un constante mejoramiento del sistema de reconocimiento facial.

3. MARCO TEÓRICO Y ANTECEDENTES

3.1. MARCO TEÓRICO

A continuación, se presentarán los conceptos claves y técnicas necesarias para la implementación del modelamiento tecnológico del sistema de reconocimiento facial para el acceso a las instalaciones de la empresa Caparrapí. En esta sección se abordarán los conceptos fundamentales y las técnicas necesarias para la implementación del sistema de reconocimiento facial, una tecnología que ha experimentado un crecimiento considerable en los últimos años debido a su capacidad para mejorar la seguridad y la eficiencia en el control de acceso. A lo largo de este marco teórico, se explorarán los principios de la biometría, las técnicas de modelado algorítmico para el reconocimiento facial, así como los diferentes enfoques tecnológicos aplicados a la empresa **Operadora Minera de Caparrapí**, donde el proyecto será implementado. Estos conceptos serán clave para entender cómo se desarrollará el sistema y su relevancia en el contexto empresarial minero.

CONTROL DE ACCESO DE PERSONAL

El control de acceso de personal es una técnica administrativa utilizada para registrar y gestionar la entrada y salida de las personas que ingresan a una empresa. Su principal objetivo es tener un control adecuado del capital humano que accede a las instalaciones, garantizando la seguridad tanto de los empleados como de los recursos de la organización [4]. Este tipo de control no solo permite supervisar el flujo de personal interno, sino también el de visitantes y contratistas, asegurando que solo personas autorizadas puedan ingresar a las áreas críticas de la empresa.

En el contexto de una empresa, como la operadora minera Caparrapí, para la cual se desarrolla este proyecto, los sistemas de control de acceso juegan un papel crucial debido a la naturaleza de las operaciones mineras y los riesgos asociados. Actualmente, la empresa utiliza un sistema de control basado en la biometría de huellas dactilares para la identificación del personal. Sin embargo, este sistema ha presentado varios inconvenientes, especialmente en el entorno minero. La exposición constante de los trabajadores a condiciones extremas, como polvo, suciedad y desgaste físico, afecta considerablemente la capacidad del sistema para leer las huellas dactilares. La suciedad

acumulada en los dedos, el desgaste de las huellas debido a la manipulación de herramientas y el maltrato recibido en la exploración minera dificultan la identificación efectiva de los empleados.

TIPOS DE CONTROL

Existen múltiples tipos de sistemas de control de acceso, tanto tradicionales como tecnológicos, que se han implementado a lo largo del tiempo en diferentes industrias para garantizar la seguridad y el manejo eficiente del personal. Los métodos más convencionales incluyen tarjetas de identificación visual, como los carnés de empleados, barreras físicas como rejas, torniquetes y puertas automáticas, y el uso de personal de seguridad o guardias que supervisan manualmente el acceso a las instalaciones. Estos métodos, aunque efectivos en ciertos contextos, pueden ser vulnerables a la suplantación de identidad o la manipulación fraudulenta. Con el avance de la tecnología, los métodos de control de acceso han evolucionado para incorporar soluciones más sofisticadas, que ofrecen un mayor nivel de seguridad y automatización. Entre estos métodos avanzados se encuentran los sistemas de control de acceso electrónicos, que incluyen tarjetas de proximidad, llaveros RFID y dispositivos de autenticación basados en PINs o contraseñas. Sin embargo, aunque estas tecnologías han incrementado la eficiencia y la seguridad, no están exentas de limitaciones, ya que los dispositivos de acceso pueden perderse, clonarse o ser manipulados. Es aquí donde entran en juego las tecnologías biométricas, que han ganado popularidad debido a su capacidad de autenticar a las personas basándose en características físicas únicas que no pueden ser falsificadas o perdidas. Los sistemas biométricos incluyen el reconocimiento de huellas dactilares, el reconocimiento de voz, el escaneo del iris y, por supuesto, el reconocimiento facial, que ha demostrado ser una solución efectiva en una amplia gama de aplicaciones de seguridad.

BIOMETRÍA

La biometría es el estudio de las características biológicas únicas de las personas que pueden ser utilizadas para su identificación. Dentro de las tecnologías biométricas más comunes encontramos el reconocimiento de huellas dactilares, el reconocimiento de voz, el reconocimiento del iris y, más recientemente, el reconocimiento facial. Cada una de estas técnicas se basa en la captación de una característica única del individuo, que luego es comparada con una base de datos previamente almacenada para verificar la identidad de la persona [5].

El reconocimiento facial, en particular, ha ganado un lugar preponderante dentro de las soluciones biométricas debido a su capacidad de autenticar a las personas de forma rápida y sin contacto físico, lo que resulta especialmente útil en contextos donde la higiene

y la seguridad son una prioridad. Este tipo de control biométrico se basa en la captura de una imagen o video del rostro de la persona, que es luego analizada mediante algoritmos especializados para extraer y comparar características únicas del rostro, como la distancia entre los ojos, el ancho de la mandíbula, la forma de la nariz, entre otros rasgos distintivos.

Una de las principales ventajas del reconocimiento facial sobre otras técnicas biométricas es que no requiere contacto físico directo con el dispositivo, lo que lo hace más higiénico y menos susceptible a daños o desgaste. Además, los avances recientes en el campo de la inteligencia artificial han permitido que los sistemas de reconocimiento facial se vuelvan más precisos y rápidos, incluso en condiciones desafiantes, como la variación en la iluminación, los cambios en la expresión facial y el uso de elementos que cubren parcialmente el rostro, como gafas o cascos [6].

FUNCIONAMIENTO DEL RECONOCIMIENTO FACIAL

El proceso de reconocimiento facial comienza con la captura de una imagen o video del rostro, utilizando cámaras de alta resolución instaladas en puntos estratégicos. La imagen capturada se procesa mediante técnicas de preprocesamiento, como la normalización de la luz y la eliminación de ruido, para asegurar que las características faciales sean claramente visibles. Posteriormente, los algoritmos de extracción de características analizan la imagen y extraen los rasgos únicos del rostro, que son luego comparados con una base de datos previamente almacenada para verificar la identidad del individuo.

Una vez que los datos faciales son capturados, estos se almacenan de manera segura en una base de datos cifrada, garantizando que la información biométrica esté protegida contra accesos no autorizados. A través de esta comparación, el sistema puede determinar si la persona tiene acceso autorizado o no. Este proceso de identificación es rápido, eficiente y altamente preciso, lo que lo convierte en una herramienta indispensable para el control de acceso en entornos empresariales de alta seguridad, como es el caso de la mina Caparrapí.

3.1.1 TÉCNICAS DE EXTRACCIÓN DE CARACTERÍSTICAS

En este apartado se identifican varias de las técnicas más relevantes implementadas para el reconocimiento facial, las cuales constituyen una base importante para el desarrollo del presente proyecto. Estas técnicas permiten transformar las imágenes faciales en vectores de características que luego pueden ser utilizados para clasificar y reconocer los rostros, reduciendo la dimensionalidad y preservando la mayor cantidad posible de información discriminan

PCA (PRINCIPAL COMPONENT ANALYSIS)

El Análisis de Componentes Principales (PCA) es un algoritmo de reducción dimensional que permite encontrar los vectores que mejor representan la distribución y clasificación de un grupo de imágenes. El objetivo principal es crear un sistema de coordenadas óptimo, reduciendo el número final de componentes sin una pérdida significativa de información discriminativa [5]. Esto es especialmente útil en aplicaciones de reconocimiento facial, donde se busca representar las características más relevantes de una imagen facial en un subespacio de menor dimensión.

El PCA se basa en la Transformada de Karhunen-Loeve (KLT), la cual permite representar un proceso estocástico utilizando una base de vectores derivados directamente del propio proceso. Este enfoque transforma las imágenes faciales en un subespacio donde las principales características son capturadas por los autovectores más importantes. En términos prácticos, el PCA reduce la complejidad de las imágenes sin sacrificar la precisión en el reconocimiento.

Uno de los beneficios clave del PCA es que permite que el sistema funcione de manera eficiente con grandes bases de datos, lo que es crucial para sistemas que manejan miles de imágenes faciales. Sin embargo, una de sus limitaciones es que es un método no supervisado, por lo que no considera las etiquetas de clase al proyectar los datos [7].

El propósito de este método es expresar una imagen en un sistema de coordenadas optimizado, reduciendo el número total de componentes que la imagen contendrá. Un ejemplo de la aplicación del PCA se muestra en la Figura 1.




Figura 1. Componentes principales de un conjunto bidimensional de datos [8].

Esta base de transformación se construye a partir de las observaciones y se genera utilizando los ‘d’ autovalores más relevantes de la matriz de covarianza. Estos autovalores representan las componentes principales más comunes en las imágenes de diferentes rostros. La reducción dimensional lograda por PCA depende del número de auto vectores seleccionados. Así, la imagen proyectada mediante PCA tendrá una dimensión de d, como se ilustra en la Figura 2.

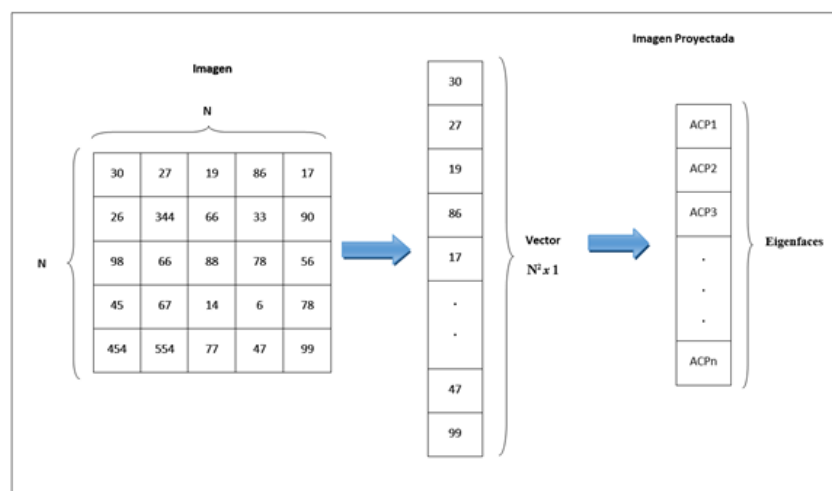


Figura 2. Ejemplo de reducción dimensional al aplicar PCA [8].

Estos autovectores representan las principales características que se repiten en las imágenes faciales, y pueden interpretarse como los ejes del subespacio donde se proyectarán las imágenes de rostros humanos. Estos ejes corresponden a las direcciones de mayor varianza en los datos. La matriz de transformación está compuesta por los autovectores asociados a los d autovalores más importantes.

LDA (Linear Discriminant Analysis)

El **Análisis Discriminante Lineal (LDA)** es otro algoritmo de reducción dimensional, aunque con un enfoque diferente al PCA. Mientras que PCA busca preservar la máxima varianza en los datos, LDA se centra en maximizar la separabilidad entre clases. En lugar de simplemente proyectar los datos en un subespacio de menor dimensión, LDA utiliza las etiquetas de clase para garantizar que los datos proyectados mantengan la mayor discriminación posible entre las diferentes clases, maximizando la distancia entre las clases mientras minimiza la dispersión dentro de cada clase [9].

El objetivo de LDA es crear un subespacio de baja dimensionalidad en el que las imágenes faciales de personas diferentes se proyecten lo más separadas posible, lo que facilita su clasificación. A diferencia de PCA, que es no supervisado, LDA aprovecha la información de clase, por lo que es más efectivo cuando se trabaja con datos etiquetados. Esta técnica ha sido ampliamente utilizada en sistemas de reconocimiento facial debido a su capacidad para mejorar el rendimiento del sistema en situaciones donde las clases son difíciles de separar.

Para ello, se maximiza la siguiente expresión:

$$J(W) = \frac{W^r \cdot S_B \cdot W}{W^r \cdot S_W \cdot W}$$

Donde S_B representa la "matriz de dispersión entre clases" y S_W es la "matriz de dispersión intra clase", las cuales se definen de la siguiente manera:

$$S_B = \sum_c N_c \cdot (\mu - x) \cdot (\mu - x)^r$$

$$S_W = \sum_c \sum_{i \in c} (x_i - \mu_c) \cdot (x_i - \mu_c)^r$$

$$\mu_c = \frac{1}{N_c} \cdot \sum_{i \in c} x_i$$

$$x = \frac{1}{N} \cdot \sum_i x_i = \frac{1}{N} \cdot \sum_c N_c \cdot \mu_c$$

Donde N_c es el número de casos dentro de la clase c .

Una vez resuelto este problema, se obtiene la matriz de proyección que permite transformar un problema de alta dimensionalidad en uno de baja. Las columnas de esta matriz conforman las bases del nuevo subespacio. Estas bases se eligen para garantizar una máxima discriminación entre las clases, priorizando esta característica sobre la descripción detallada de los datos, lo que las distingue de las bases obtenidas mediante PCA (Figura 3).




Figura 3. Comparación de la proyección de 2 clases en PCA y LD [10].

LPP (LOCALITY PRESERVING PROJECTIONS)

Se emplea mediante la información de vecindario como el conjunto de datos. De esta manera, la representación de gráficos se genera por medio de algoritmos que pueden crear una aproximación discreta lineal; es decir, realiza una reducción dimensional de los datos, al tratarse de una codificación lineal es rápido y útil para la práctica, teniendo una estructura muy parecida a la PCA [9].

A diferencia de PCA, una característica distintiva es que, en lugar de preservar la estructura global de los datos, mantiene su estructura local (Figura 4). Esto significa que los puntos de datos cercanos en el espacio original de alta dimensionalidad seguirán

siendo vecinos en el subespacio de menor dimensionalidad. Al preservar esta estructura local, las imágenes de una misma persona se agrupan de manera cercana entre sí, mientras que las imágenes de otros individuos se distancian, lo que facilita la diferenciación entre clases.

Para preservar la estructura local de los datos, se utiliza un gráfico de adyacencias que incorpora información sobre la estructura de los mismos. Este grafo, se construye mediante una matriz de tamaño $N \times N$, donde N representa el número de imágenes. A cada elemento se le asignan pesos en función de si los puntos i y j son considerados vecinos. Al crear este gráfico, se puede optar por hacerlo de manera automática (en un enfoque no supervisado), empleando métodos como K -nearest neighbors o ϵ -neighborhoods para identificar los vecinos, o de manera manual (en un enfoque supervisado), determinando manualmente cuáles son vecinos.




Figura 4. LPP conserva la estructura original de datos en comparación con el PCA [9].

Este método es interesante desde varias perspectivas. En primer lugar, los mapas que genera están diseñados para minimizar un criterio objetivo basado en técnicas lineales tradicionales. Además, LPP mantiene la estructura local de los datos, lo que garantiza que los puntos sigan teniendo los mismos vecinos en el espacio reducido que en el de alta dimensionalidad. Al ser un método lineal, es rápido y práctico para aplicaciones reales. A diferencia de otras técnicas no lineales, que solo se aplican al conjunto de datos de entrenamiento, LPP puede manejar nuevos datos sin necesidad de recalcularse las matrices de proyección, lo que lo hace más flexible y eficiente.

EIGENFACES

El método de Eigenfaces es una aplicación directa del PCA en el campo del reconocimiento facial. Este método busca encontrar una representación de los rostros en

un subespacio de menor dimensión, donde las principales características faciales son capturadas por los autovectores de mayor valor. Cada rostro se representa como una combinación lineal de estos autovectores, conocidos como "Eigenfaces", lo que permite una comparación eficiente entre las imágenes faciales. Una de las ventajas del enfoque de Eigenfaces es que reduce significativamente el almacenamiento y el tiempo de procesamiento necesario para el reconocimiento facial, al reducir la cantidad de información redundante. Sin embargo, este método puede ser sensible a las variaciones en la iluminación y la pose, lo que limita su aplicación en escenarios dinámicos o desafiantes.

FISHERFACES

El método de **Fisherfaces** es una mejora del enfoque de Eigenfaces, utilizando el LDA en lugar de PCA para proyectar las imágenes faciales en un subespacio de menor dimensión. A diferencia de Eigenfaces, Fisherfaces maximiza la discriminación entre clases, lo que lo hace más robusto frente a variaciones en la iluminación, la pose y la expresión facial. Este método es especialmente útil en aplicaciones donde se requiere una alta precisión de clasificación entre diferentes individuos. Fisherfaces se basa en la idea de que las imágenes faciales de un mismo individuo deben proyectarse lo más cerca posible en el subespacio, mientras que las imágenes de diferentes individuos deben proyectarse lo más separadas posible. Esta técnica ha demostrado ser particularmente efectiva en escenarios de reconocimiento facial en tiempo real, donde las condiciones ambientales pueden variar considerablemente.

3.1.2 APRENDIZAJE AUTOMÁTICO

El aprendizaje automático ha transformado el campo del reconocimiento facial al permitir que los sistemas procesen grandes cantidades de datos de imágenes y extraigan patrones complejos de manera automática. Mediante el uso de redes neuronales convolucionales (CNN), redes siamesas y otros algoritmos avanzados, los sistemas pueden identificar características faciales únicas para autenticación y seguridad. A continuación, se describen conceptos clave para el desarrollo de este proyecto.

REDES CONVOLUCIONALES (CNN)

Las Redes Neuronales Convolucionales (CNN) son ampliamente utilizadas en el procesamiento de imágenes debido a su capacidad para extraer y aprender características complejas de los datos. Estas redes procesan imágenes como matrices bidimensionales o tridimensionales, preservando la estructura espacial de los píxeles. La

convolución, la operación clave de las CNN, permite a la red detectar características de bajo nivel, como bordes y texturas, y combinarlas para obtener representaciones abstractas de los rostros, lo que las hace muy útiles en el reconocimiento facial.

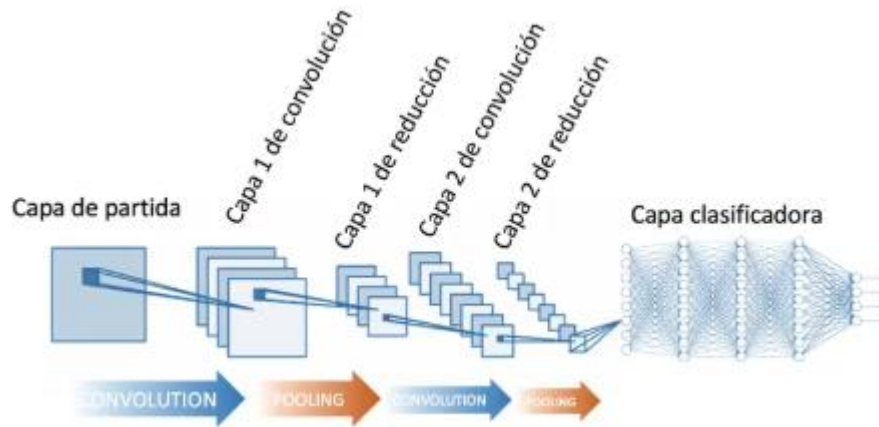


Figura 5. Red neuronal convolutiva [11].

Las CNN son esenciales en este proyecto para reconocer rostros en tiempo real. Su capacidad para manejar grandes volúmenes de datos y su precisión en la detección de patrones faciales permiten que el sistema identifique rostros con alta precisión, incluso en condiciones desafiantes, como variaciones en la iluminación, expresión o pose.

De esta manera, dichas redes son una evolución de las redes neuronales, al tener un procesamiento similar, es decir, ambos tipos de redes emplean una entrada o series de entradas para obtener una salida siguiendo un conjunto complejo de conexiones ponderadas. Sin embargo, las redes convolucionales reciben como entradas imágenes, siendo capaces de identificar su estructura espacial, convirtiéndose en matrices tridimensionales o bidimensionales que posteriormente, recibirán un peso.

Es así como, las redes convolucionales, imitan al cerebro humano al ser capaces de distinguir un rostro por medio de la distinción de elementos combinados, que se traducen un patrón determinado por la boca, nariz, ojos, orejas y/o rasgos generales. Ahora bien, para realizar toda esta operación se emplea una operación matemática llamada *convolución*, la cual, en términos prácticos se define como la representación de una media móvil. De esta forma se define la convolución como un tipo de operación lineal [12], siendo en su forma general la operación de dos funciones, $x(t)$ y $w(t)$ denotada por $(x*w)(t)$ o $s(t)$:

$$s(t) = (x * w)(t) = \int x(a)w(t - a)da$$

Si enlazamos con la nomenclatura de las CNN entonces $x(t)$ sería la entrada y $w(t)$ el núcleo y $s(t)$ la salida producida por la convolución la denominaremos **mapa de características** [12]. Por el hecho de discretizar los datos si t toma valores enteros y w solo está definido en valores enteros, entonces:

$$s(t) = (w * t)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t - a)$$

De igual manera, es importante determinar la dimensión de entrada que estamos trabajando, por lo cual se debe adaptar el núcleo a la dimensión necesaria: tres en el caso de imágenes a color, dos en imágenes en blanco y negro. Para el caso de estudio sería para tres núcleos, lo cual se definiría como la aplicación de tres capas bidimensionales correspondientes a las capas de los canales RGB, cuya formula sería la siguiente:

$$s(i, j) = \sum_m \sum_n I(|i - j|p + m, |j - 1|p + n)K(m, n) \quad i, j = 1, 2 \dots$$

Estos *mapas de características* indican en qué ubicación de la imagen se ha destacado la característica que señala el filtro; de esta manera, se busca una mayor obtención de profundidad en el elemento de entrada y, a su vez, una mejor detección del aspecto a evaluar al aumentar la profundidad de la imagen, una vez realizado el proceso, se obtendrá una red neuronal convencional [13]. Un ejemplo de una matriz de entrada 4x4 y un núcleo 3x3 es el siguiente [12]:

Entrada:

-1	0	0	-1
1	1	1	-1
0	-1	1	0
0	1	1	0

Núcleo:

1	0	0
0	1	0
0	0	-1

Realizamos el proceso de zero-padding:

0	0	0	0	0	0
0	-1	0	0	-1	0
0	1	1	1	-1	0
0	0	-1	1	0	0
0	0	1	1	0	0
0	0	0	0	0	0

Obteniendo como resultado:

-2	-1
0	1

En el ejemplo presentado, se puede notar que la matriz obtenida tras el proceso de convolución es más pequeña que la matriz de entrada. Por esta razón, es común utilizar zero-padding para igualar las dimensiones o completar manteniendo los bordes de la entrada original. Una capa convolucional se basa en realizar múltiples convoluciones, añadiendo un término de sesgo a cada entrada para generar distintos mapas de características.

3.1.3 MÉTRICAS DE MEDICIÓN

Para el análisis y evaluación del desempeño del modelo utilizado, se consideran diversas métricas de rendimiento enfocadas en la eficacia y la precisión. Las métricas más relevantes son las siguientes:

Precisión

La **precisión** se define como la proporción de instancias correctamente clasificadas como positivas entre el total de instancias que el modelo clasificó como positivas. En otras palabras, mide cuántas de las predicciones positivas hechas por el modelo son verdaderamente correctas.

$$\text{Precisión} = \frac{\text{Número de instancias correctamente clasificadas}}{\text{Número total de instancias}}$$

Donde:

- **TP** (True Positives o Verdaderos Positivos): instancias positivas correctamente clasificadas.

- **FP** (False Positives o Falsos Positivos): instancias negativas clasificadas incorrectamente como positivas.

Un valor alto de precisión indica que el modelo tiene un bajo número de falsos positivos, lo cual es especialmente importante en aplicaciones donde los falsos positivos pueden tener consecuencias graves.

RECALL

El **recall**, también conocido como **sensibilidad** o **tasa de verdaderos positivos**, mide la capacidad del modelo para identificar correctamente todas las instancias positivas. Esta métrica es útil cuando es fundamental minimizar los falsos negativos, es decir, no dejar escapar instancias positivas.

$$Recall = \frac{TP}{TP + FN}$$

Donde:

- **TP**: instancias positivas correctamente clasificadas.
- **FN** (False Negatives o Falsos Negativos): instancias positivas clasificadas incorrectamente como negativas.

Un valor de **recall** cercano a 1 indica que el modelo es capaz de identificar la mayoría de las instancias positivas.

El recall toma valores entre 0 y 1, donde 1 indica que el modelo ha identificado correctamente todas las instancias positivas y 0 indica que no ha identificado ninguna.

F1-SCORE

El **F1-score** es una métrica que combina la **precisión** y el **recall** en un solo valor, proporcionando un balance entre ambas. Es especialmente útil cuando se busca un equilibrio entre evitar falsos positivos y minimizar falsos negativos [14].

$$F1 = \frac{2 \times Precisión \times Recall}{Precisión \times Recall}$$

EXACTITUD

La exactitud es la proporción de instancias correctamente clasificadas, tanto positivas como negativas, sobre el total de instancias evaluadas. Es una de las métricas más intuitivas, pero puede ser engañosa cuando los datos están desbalanceados.

$$Exactitud = \frac{TP + TN}{TP + FP + FN + FN}$$

Donde:

- TP: verdaderos positivos.
- TN (True Negatives o Verdaderos Negativos): instancias negativas correctamente clasificadas.
- FP: falsos positivos.
- FN: falsos negativos.

Un valor alto de exactitud indica que el modelo clasifica correctamente la mayoría de las instancias, pero en escenarios con clases desbalanceadas (por ejemplo, muchas más instancias negativas que positivas), no siempre refleja el verdadero rendimiento del modelo.

MATRIZ DE CONFUSIÓN

La **matriz de confusión** es una herramienta que proporciona una representación más detallada del rendimiento del modelo al mostrar el número de verdaderos positivos (TP), falsos positivos (FP), verdaderos negativos (TN) y falsos negativos (FN). Esto permite obtener una mejor comprensión de cómo está clasificando el modelo cada una de las instancias.

	Predicho Positivo	Predicho Negativo
Real Positivo	TP	FN
Real Negativo	FP	TN

La matriz de confusión es útil para evaluar en detalle los errores del modelo y entender si es necesario ajustar ciertos parámetros para mejorar el rendimiento en determinadas clases.

3.1.3 TÉCNICAS Y MODELOS DE RECONOCIMIENTO FACIAL

En este proyecto, evaluamos y comparamos varias técnicas y modelos de reconocimiento facial con el objetivo de seleccionar la mejor opción para las necesidades específicas de nuestra aplicación. La idea principal era probar exhaustivamente diferentes enfoques para determinar cuál ofrecía el mejor rendimiento en términos de precisión, robustez y capacidad de adaptación a diferentes condiciones de iluminación y poses faciales [14].

REDES SIAMESAS

Uno de los modelos más destacados en nuestra evaluación fue la Red Siamese, una arquitectura que ha demostrado ser muy efectiva en problemas de verificación facial. Las redes siamesas consisten en dos subredes idénticas que comparten los mismos pesos y parámetros, y su propósito es determinar la similitud entre dos entradas, típicamente imágenes de rostros. Estas redes generan un vector de características para cada imagen y luego comparan estos vectores utilizando una función de distancia, como la distancia euclidiana, para medir qué tan similares son las imágenes.

En el contexto de reconocimiento facial, las redes siamesas permiten verificar si dos imágenes corresponden a la misma persona. Durante el entrenamiento, el modelo recibe pares de imágenes etiquetadas como "similares" o "diferentes", y aprende a diferenciar las características únicas de cada rostro. Este enfoque es particularmente útil en sistemas de control de acceso y autenticación biométrica, donde la tarea principal es verificar la identidad de un usuario en lugar de identificar a una persona entre un gran conjunto de candidatos.

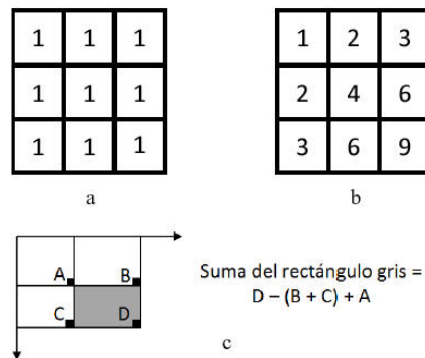


Figura 6. Cálculo de la imagen integral: a) imagen original, (b) imagen integral, (c) Cálculo de la suma de la imagen integral [15].

Las máscaras de convolución del filtro Haar, ilustradas en la Figura 7, son máscaras binarias que consisten en zonas claras y oscuras, donde el blanco tiene un valor de 255 y el negro de 0. En el método Viola-Jones, estas máscaras se utilizan para extraer

características relevantes de la imagen, como bordes y líneas en diferentes orientaciones (horizontales, verticales y diagonales), facilitando la detección de objetos, como rostros humanos [15].




Figura 7. Estructuras simples formadas por dos, tres y cuatro rectángulos [15].

Un clasificador en cascada se estructura en diversas etapas de filtrado, como se muestra en la Figura 8. Cada vez que la ventana deslizante se desplaza, la región dentro de ella es evaluada por el clasificador en cascada, pasando por cada etapa sucesivamente. Si en alguna de estas etapas la región no alcanza el umbral establecido, se descarta como un rostro. En cambio, si la región supera todas las etapas, se clasifica como una cara y puede ser seleccionada para un procesamiento adicional mediante una función de distancia, como la distancia euclidiana o el coseno, para determinar la similitud entre las entradas.




Figura 8. Descripción esquemática de una cascada de clasificadores. Los números representan la cantidad de rasgos evaluados por etapa. [15]

Acorde a la

Figura 9, su parte izquierda representa dos dígitos de ejemplo de un conjunto de datos determinado, teniendo como objetivo principal denotar si ambos dígitos pertenecen a la misma clase o no.

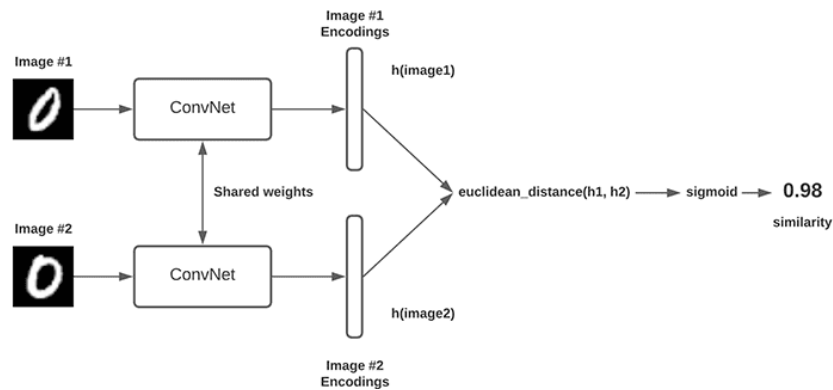


Figura 9. Siameses Network [16]

Por su parte, la parte media de la Figura 9 muestra la red en sí, las dos subredes señaladas tienen la misma arquitectura y los mismos parámetros, reflejándose entre sí. De esta manera, si se actualiza el peso de una subred, también se actualizará el de las demás.

Por último, la salida de cada subred es una capa completamente conectada. Se calcula la distancia euclidiana entre las salidas Figura 10 y se pasan a una activación sigmoidea; esto, para determinar qué tan similares son las dos imágenes de entrada; los valores más cercanos a 1 indican más similitud y los cercanos a 0 a menos similitud.




Figura 10. Redes siamesas formula euclidiana [16].

EIGENFACE RECOGNIZER

Otro modelo evaluado fue el EigenFaceRecognizer, uno de los primeros enfoques utilizados en el reconocimiento facial. Este modelo se basa en el Análisis de Componentes Principales (PCA), una técnica de reducción de dimensionalidad que busca representar las características más importantes de los rostros humanos. El término

"eigenfaces" se refiere a los vectores propios que representan las direcciones de mayor variación en un conjunto de imágenes faciales.

Durante la fase de entrenamiento, se recopila un conjunto de imágenes faciales consistentes en términos de tamaño y orientación [17]. Luego, se aplica PCA para calcular los vectores propios o "eigenfaces", que representan de manera eficiente las características faciales más relevantes, eliminando información redundante. El objetivo es simplificar la representación de las imágenes, facilitando la comparación entre ellas.

FISHER FACE RECOGNIZER

El modelo FisherFaceRecognizer combina dos técnicas poderosas para el análisis de imágenes: el Análisis de Componentes Principales (PCA) y el Análisis Discriminante Lineal (LDA). Esta combinación hace que el FisherFaceRecognizer sea un enfoque más avanzado y efectivo en comparación con otros métodos tradicionales de reconocimiento facial, como Eigenfaces, especialmente en escenarios donde las condiciones de captura varían, como la iluminación y las expresiones faciales.

El proceso de reconocimiento con Fisherfaces se realiza en varias etapas:

Reducción de Dimensionalidad con PCA: El modelo comienza aplicando PCA para reducir el número de dimensiones en los datos de entrada. Este paso es fundamental para eliminar información redundante o irrelevante que podría interferir en el reconocimiento.

Separación de Clases con LDA: A continuación, el modelo aplica LDA, que es una técnica de aprendizaje supervisado utilizada para maximizar la separación entre clases. En el contexto del reconocimiento facial, las clases son los diferentes rostros que queremos reconocer.

Generación del Espacio de Fisher Faces: El resultado de aplicar PCA y LDA es un nuevo espacio de características en el que las imágenes faciales se representan como una combinación de "Fisher Faces".

Clasificación de Imágenes Faciales: Finalmente, para reconocer un rostro nuevo, el modelo proyecta la imagen en el espacio de Fisher Faces y compara su representación con las imágenes almacenadas en el conjunto de entrenamiento. La similitud se mide utilizando una métrica como la distancia euclidiana.

LBPH RECOGNIZER

El LBPHFaceRecognizer (Local Binary Patterns Histogram) se destacó como uno de los métodos más robustos y versátiles para el reconocimiento facial. Este modelo no depende de la forma global de los rostros, como lo hacen Eigenfaces o Fisherfaces, sino

que se enfoca en las texturas locales de la imagen, lo que le permite ser mucho más resistente a variaciones de iluminación y expresión facial.

El proceso de reconocimiento con LBPH se basa en la división de la imagen en pequeñas regiones y la aplicación del operador LBP (Local Binary Pattern) a cada una de ellas. El LBP compara cada píxel con sus vecinos más cercanos y genera un patrón binario que se convierte en un valor decimal. Estos valores representan las texturas locales de la imagen y luego se combinan en un histograma que describe toda la imagen facial.

La capacidad de LBPH para reconocer rostros en condiciones de iluminación adversas y su alta precisión en la identificación de rostros frontales y de perfil lo hicieron ideal para los requisitos de nuestro proyecto. Este algoritmo mostró una excelente capacidad para manejar variaciones en el entorno, siendo particularmente efectivo en situaciones donde la iluminación es desigual o las expresiones faciales varían de manera significativa.

El método de LBPH asigna etiquetas a cada uno de los píxeles de la imagen tomando en cuenta la distribución de los vecinos.

3.2. ANTECEDENTES

A continuación, se presentan algunos trabajos que han implementado el reconocimiento facial como técnica de innovación en las empresas.

El primer proyecto es titulado, Sistema de control de acceso para empresas mediante el uso de reconocimiento facial; este proyecto ofrece una solución al sistema de control de acceso basado en reconocimiento facial utilizando algoritmos de Deep Learning, optimizado para su implementación en un sistema embebido con poder de cálculo limitado, este proyecto busca no solo desarrollar un sistema de reconocimiento facial basado en Deep Learning, sino también integrar este sistema en una solución completa de control de acceso que sea segura, eficiente y fácil de usar para cualquiera [13].

Seguidamente, se hace mención a un segundo trabajo titulado Sistema automatizado para la gestión de asistencia y control de temperatura con reconocimiento facial de los empleados de la empresa eléctrica Ambato EEASA; este proyecto centra su investigación en la madurez necesaria del control de los datos y procesos que se maneja la empresa en la actualidad para desarrollar un sistema automatizado para la gestión de asistencia y control de temperatura con reconocimiento facial de los empleados de la Empresa Eléctrica Ambato EEASA [18]. La experiencia aportada, supuso el entendimiento de reconocer los procesos del sistema que se utilizaba la empresa para el ingreso del personal.

De igual manera, se encuentra otro trabajo realizado por Universidad de Micaela Bastidas, donde el foco temático se centra en el Desarrollo de aplicación móvil de reconocimiento facial para detectar el estado anímico de los conductores de vehículos en la Empresa Figueroa Ingenieros EIRL; esta tesis describe el desarrollo de una aplicación móvil de reconocimiento facial usando la técnica holística para detectar el estado de ánimo del conductor por medio de patrones faciales obtenidos de imágenes tomadas por la cámara frontal de los teléfonos celulares [19].

Por su parte, se hace mención a dos proyectos más, en donde el primero, se centra la Vista de Sistema de seguridad con reconocimiento facial en módulo ESP32 un sistema de seguridad es un conjunto de instalaciones necesarias para brindar seguridad a las personas y bienes que se encuentran en un lugar específico [20], y el segundo, Sistema de Reconocimiento Facial mediante inteligencia Artificial para registro de asistencia de personas en campo perteneciente a la Universidad de Rioja [21]. De esta manera, se entendió la importancia de una base de datos robusta para ser más precisos al momento de detectar rasgos faciales que pueden ser compartidos por una o más personas.

4.EVALUACIÓN DE REQUERIMIENTOS: IDENTIFICACIÓN DE LOS RECURSOS NECESARIOS PARA LA EJECUCIÓN DEL PROYECTO.

4.1 HARDWARE.

Comparativo entre cámaras

Para el reconocimiento facial del personal minero de Caparrapí, es crucial seleccionar una cámara que cumpla con requisitos específicos de funcionamiento y durabilidad, dadas las condiciones adversas propias de la minería. Por lo cual, la selección de la misma se basa en características principales como: resolución; formato de imagen y video; calidad de captura e iluminación.

Por lo cual se optó por realizar un cuadro comparativo que permitiera elegir la cámara más adecuada para los requerimientos del sistema, como se muestra en la Tabla 1.

Tabla 1. Comparativa entre cámaras digitales estudiadas

Característica	Hikvision 3MP DS-2CD1131-I (2.8mm)	Dahua IPC-HFW1320S	Reolink RLC-520	TP-Link Tapo C310	ZOSI 2MP C190
Interfaz	Ethernet RJ45, PoE	Ethernet RJ45, PoE	Ethernet RJ45, PoE	Ethernet RJ45, Wi-Fi	Ethernet RJ45
Zoom	Fijo (2.8 mm)	Fijo (2.8 mm)	Fijo (4 mm)	Fijo (3.6 mm)	Fijo (2.8 mm)
Formato Imagen/Video	H.264, H.265, JPEG	H.264, JPEG	H.264, H.265	H.264, MJPEG	H.264, MJPEG
Sensor	CMOS 1/3"	CMOS 1/3"	CMOS 1/2.7"	CMOS 1/2.8"	CMOS 1/2.9"
Resolución	2048x1536 (3MP)	2048x1536 (3MP)	2560x1920 (5MP)	2304x1296 (3MP)	1920x1080 (2MP)
Compatibilidad	ONVIF, Hikvision software	ONVIF, Dahua software	ONVIF, Reolink app	Tapo app, Alexa/Google Assistant	ZOSI Smart app
Driver	Incluido en el paquete (Hikvision)	Incluido en el paquete (Dahua)	Incluido en el paquete (Reolink)	Incluido en el paquete (Tapo)	Incluido en el paquete (ZOSI)
Costo Aproximado	\$70 USD	\$70 USD	\$60 USD	\$50 USD	\$55 USD

De esta manera, se optó por la cámara Hikvision 3MP DS-2CD1131-I(2.8mm); teniendo una ventaja absoluta sobre las demás dada su uso e instalación en la empresa durante este último año. Adicionalmente, cumple con todos los requisitos técnicos y ambientales necesarios para llevar a cabo el proyecto de reconocimiento facial del personal en la empresa Caparrapí. Su capacidad para capturar imágenes de alta resolución, tanto de día como de noche, su resistencia a condiciones adversas y su costo asequible la convirtieron en la opción ideal, presentando presenta una serie de características técnicas que la hacen idónea para el proyecto:

- **Sensor de imagen CMOS de 1/3:** Este sensor permite una captura de imágenes de alta calidad, incluso en condiciones de iluminación difíciles, lo cual es esencial en entornos mineros donde la iluminación puede ser variable.
- **Iluminación Mínima y Visión Nocturna:** La cámara cuenta con una iluminación mínima de 0.01 Lux en color y 0 Lux con IR, lo que garantiza una buena calidad de imagen tanto de día como de noche. La distancia de IR de hasta 30 metros asegura una visión clara incluso en la oscuridad.
- **Resolución de 3MP:** La alta resolución de la cámara (2048 × 1536) permite capturar detalles nítidos, lo que es fundamental para el reconocimiento facial.

- **Protocolos de Red Completa:** La compatibilidad con diversos protocolos de red como TCP/IP, HTTP, RTSP, entre otros, asegura una fácil integración con el sistema de reconocimiento facial y permite la transmisión de datos de manera eficiente.
- **Temperatura y Protección:** La cámara está diseñada para soportar temperaturas extremas, desde -30°C hasta 60°C , lo que la hace ideal para entornos mineros donde las condiciones ambientales pueden ser extremas. Además, cuenta con una protección IP67 contra polvo y agua, garantizando su funcionamiento incluso en condiciones adversas.
- **Alimentación y Dimensiones:** La posibilidad de alimentación mediante 12Vcd, PoE (802.3af) o 5.5W, junto con unas dimensiones compactas (111 x 82 mm) y un peso de 500 gramos, facilita su instalación en diferentes ubicaciones dentro del entorno minero.
- **Costo Asequible:** Con un costo aproximado de \$70 dólares, la cámara ofrece una excelente relación calidad-precio, lo que la hace viable dentro del presupuesto del proyecto.

Comparación entre computadores

Se analizó las distintas alternativas de computadores existentes y cuya posibilidad de adquisición y uso era elevada. Teniendo en cuenta el procesamiento de información e imágenes, este fue un recurso vital para la ejecución del proyecto.

Tabla 2. Comparativa de computadores a utilizar

Característica	Workstation (HP Z4 G4)	Laptop Gamer (Dell Alienware M15)	Desktop PC (Dell XPS Tower)	Laptop Pro (MacBook Pro 16")	Mini PC (Intel NUC 11 Pro)
Disco Duro	1 TB SSD + 2 TB HDD	1 TB SSD	512 GB SSD	1 TB SSD	512 GB SSD
Procesador (CPU)	Intel Xeon W-2245 (8 núcleos)	Intel Core i7-11800H	Intel Core i7-11700	Apple M2 Pro (12 núcleos)	Intel Core i7-1165G7
Tarjeta Gráfica (GPU)	NVIDIA Quadro RTX 4000	NVIDIA GeForce RTX 3070	NVIDIA GeForce GTX 1660 Ti	Apple GPU 19-core	Intel Iris Xe Graphics
Conectividad	2x Thunderbolt, 10GbE, Wi-Fi	2x Thunderbolt, Wi-Fi 6	Ethernet, Wi-Fi 6	3x Thunderbolt, Wi-Fi 6	Thunderbolt 4, Wi-Fi 6
Sistema Operativo	Windows 11 Pro	Windows 11 Home	Windows 11 Home	macOS Ventura	Windows 11 Pro
Tipo de Almacenamiento	SSD y HDD combinados	SSD	SSD	SSD	SSD
Resolución de Pantalla	No aplica (torre)	15.6" Full HD (1920x1080)	No aplica (torre)	16" Liquid Retina XDR (3456x2234)	No aplica (mini PC)
Memoria RAM	64 GB DDR4	32 GB DDR4	16 GB DDR4	32 GB unified	16 GB DDR4
Costo Promedio	\$4,500 USD	\$2,400 USD	\$1,800 USD	\$3,500 USD	\$1,200 USD

La Tabla 2 permite observar las comparaciones en características sobre los computadores que se consideraron óptimos para el reconocimiento facial. De esta manera, se optó por el Workstation HP Z4 G4 para el desarrollo del proyecto, dado que aunque su costo promedio es el mayor entre las demás opciones, es un recurso empresarial prestado por la compañía y usado por uno de los integrantes del grupo, siendo indudablemente la mejor elección a seleccionar. La Workstation ofrece un rendimiento superior en términos de procesamiento y gráficos, lo que resulta ideal para el manejo de grandes volúmenes de datos y la ejecución de algoritmos de inteligencia artificial y visión por computadora. Dado que este proyecto requiere alta precisión y procesamiento en tiempo real, la Workstation proporcionada por la empresa es la más adecuada para llevar a cabo esta tarea de manera eficiente.

4.2 SOFTWARES DE IMPLEMENTACIÓN PARA EL PROYECTO

Dado el desarrollo de un sistema de reconocimiento facial en tiempo real orientado al control de acceso empresarial, este proyecto se está diseñando con base al software React.js, utilizando la base de datos SQL Server Express para almacenar y gestionar los datos de usuarios y registros.

Comparación de interfaz

Para la realización del diseño e interfaz del proyecto a crear se propuso el siguiente

cuadro comparativo, para posteriormente a través del análisis de cada uno de los atributos propios de cada software se escogiera el mejor a elección de los investigadores.

Tabla 3. Comparación de softwares de interfaz

Característica	React.js	Vue.js	Angular	Svelte	Ember.js
Sistema Operativo	Multiplataforma (Windows, macOS, Linux)	Multiplataforma (Windows, macOS, Linux)	Multiplataforma (Windows, macOS, Linux)	Multiplataforma (Windows, macOS, Linux)	Multiplataforma (Windows, macOS, Linux)
Idioma	JavaScript, JSX	JavaScript, HTML	TypeScript, HTML	JavaScript, HTML	JavaScript, HTML
Licencia	Código abierto	Código abierto	Código abierto	Código abierto	Código abierto
Última Actualización	Activa: Julio 2024	Activa: Junio 2024	Activa: Julio 2024	Activa: Junio 2024	Activa: Junio 2024
Aplicaciones	Web, Móvil (React Native), SPA, SSR	Web, Móvil (NativeScript), SPA, SSR	Web, Móvil (Ionic), SPA, SSR	Web, SPA, SSR	Web, SPA
Ventajas	Gran ecosistema, alta modularidad, popularidad, Virtual DOM eficiente, gran comunidad de soporte	Fácil de aprender, sintaxis simple, excelente para proyectos pequeños a medianos	Framework completo, soporte empresarial, ideal para proyectos a gran escala	Tamaño pequeño, sin Virtual DOM, enfoque en rendimiento	Convenciones estrictas, enfoque en aplicaciones a largo plazo
Desventajas	Curva de aprendizaje moderada debido a JSX, requiere manejar el estado correctamente	Comunidad más pequeña que React, menos popular en grandes empresas	Complejidad alta, tamaño pesado, curva de aprendizaje empinada	Comunidad más pequeña, menor cantidad de herramientas en el ecosistema	Curva de aprendizaje empinada, menos flexible que otros frameworks
Costo Promedio	Gratis	Gratis	Gratis	Gratis	Gratis

Acorde a la Tabla 3 se optó por el uso del software React.js para crear interfaces de usuario interactivas y eficientes en la ejecución del proyecto. React.js utiliza un enfoque de componentes reutilizables, lo que facilita la construcción de la interfaz de usuario necesaria para visualizar y controlar el proceso de reconocimiento facial. Además, React.js ofrece un rendimiento óptimo al gestionar actualizaciones de manera eficiente, lo que es crucial en aplicaciones de tiempo real como el reconocimiento facial. Su arquitectura basada en componentes permite una fácil integración con otras bibliotecas y herramientas de procesamiento de imágenes, lo que facilita la implementación de algoritmos de reconocimiento facial y la manipulación de datos en tiempo real, garantizando una interfaz de usuario ágil y receptiva.

Bases de datos

Dentro del diseño del sistema es necesario la escogencia o utilización de un software de base de datos; esto, para el almacenamiento de registro de los empleados que han sido identificados y procesados por la cámara de ingreso, siendo imperativo características esenciales como consulta de datos, seguridad, rapidez, entre otros. De esta manera, se puso en consideración distintos softwares de gestión de datos.

Tabla 4. Comparación entre gestores de bases de datos

Característica	SQL Server Express	MySQL	PostgreSQL	SQLite	Oracle Database XE
Ventajas	Gratuito, fácil integración con apps de Microsoft, buen rendimiento en pequeñas y medianas aplicaciones, alta seguridad.	Amplio soporte, multiplataforma, alta velocidad para consultas y buena escalabilidad.	Extremadamente robusto, compatible con muchos estándares, altamente personalizable.	Extremadamente ligero, sencillo de integrar, ideal para aplicaciones móviles y embebidas.	Potente y con muchas características empresariales, muy confiable y escalable.
Desventajas	Limitación de almacenamiento a 10 GB por base de datos, funciones avanzadas limitadas.	Algunas características avanzadas requieren versiones de pago, no ideal para entornos empresariales complejos.	Configuración más compleja que MySQL, más consumo de recursos.	No adecuado para aplicaciones de gran escala, falta de algunas características avanzadas.	Requiere más memoria y recursos, más complejo de administrar.
Plataforma	Windows, Linux	Windows, Linux, macOS	Windows, Linux, macOS	Windows, Linux, macOS	Windows, Linux
Lenguaje	T-SQL	SQL, PL/SQL	SQL, PL/pgSQL	SQL	SQL, PL/SQL
Memoria	Hasta 1 GB de RAM por instancia	Depende de la configuración del servidor	Depende de la configuración del servidor	Sin límites predefinidos, depende de la implementación.	Hasta 2 GB de RAM en la versión XE
Licencia	Gratuito	Open Source (GPL)	Open Source (PostgreSQL License)	Open Source (Public Domain)	Gratuito (limitado en la versión XE)
Versión	Express (gratuita), Standard, Enterprise	Community (gratuita), Enterprise	Versión única gratuita	Versión única gratuita	XE (gratuita), Standard, Enterprise

Dada su capacidad para gestionar grandes volúmenes de datos de manera eficiente y confiable, se usó SQL server Express en la gestión de bases de datos para la realización del proyecto; esto, debido a su capacidad para manejar consultas complejas y almacenar datos de forma segura. El software ofrece herramientas robustas para la gestión y consulta de datos, así como una alta disponibilidad y escalabilidad, lo que garantiza un rendimiento confiable incluso en entornos con grandes cargas de trabajo, proporcionando una base sólida y escalable para almacenar y administrar los datos críticos requeridos por un proyecto de reconocimiento facial.

SQL Server Express 2019, es gratis y no requiere licenciamiento. A su vez, se suministra elaboración del Esquema de Entidad de Relación efectuada en el proyecto.

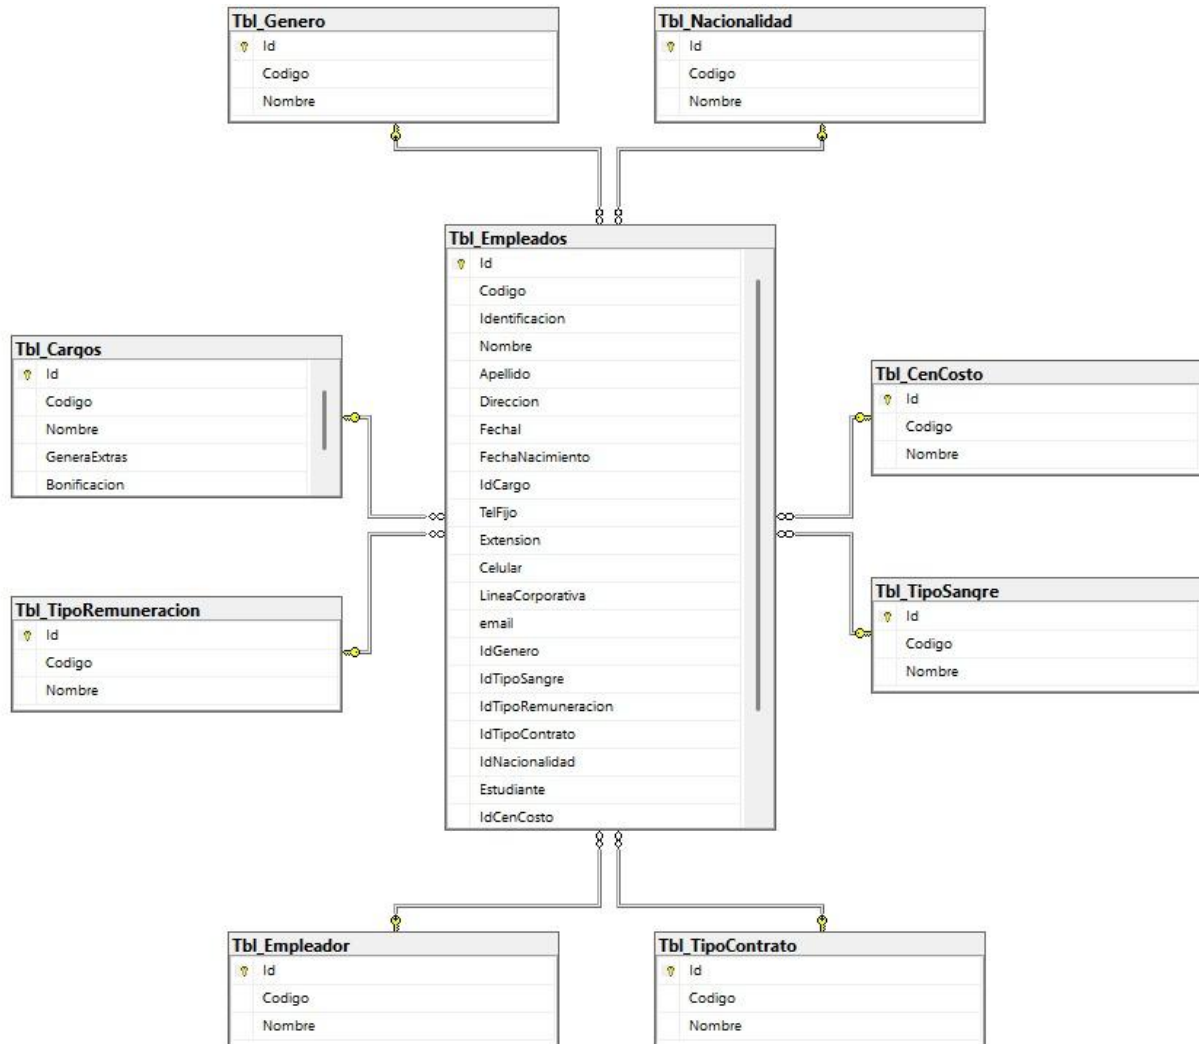


Figura 11. Esquema de Entidad de Relación Operarios Caparrapí

En la Figura 11 se observa que estructura de la base se encuentra generada por un diagrama de estrella, compuesta por las tablas de Género, Nacionalidad, Cargos, Remuneración, Empleador, Tipo de Contrato, Tipo de Costo, tipo de Sangre, teniendo como tabla central la base de Empleados.

4.3 CAPTURA Y RECOPIACIÓN DE IMÁGENES PARA LA BASE DE DATOS.

Acorde a una reunión previa con administración de la empresa Minera Caparrapí, y dado a que el funcionario en cabeza del área informática pertenece al grupo de investigación de este proyecto, se firmó, sin ningún inconveniente, la autorización para el tratamiento de información del personal (Anexo 1); esto, dada la necesidad de ofrecer mayor seguridad y eficiencia en el ingreso de los trabajadores a las minas.

De esta manera, se citó a una reunión previa con el personal operativo y la gerencia de Recursos Humanos de la empresa Caparrapí, en este espacio se informó a cada operario que debe asistir en las mañanas según un agendamiento propuesto; el trabajador se dirigirá al contenedor en el cual se encuentra el registro de ingresos y salidas; con el objetivo de tomar fotos desde varios perfiles para la ejecución y evaluación del proyecto; teniendo en cuenta que se tomaran imágenes de cada rasgo facial se pudo concentrar una totalidad de 300 imágenes por persona. Durante este proceso, se tomaron 50 operarios hicieron parte del proceso, dejando en evidencia lo proyectado en la Figura 12. **¡Error! No se encuentra el origen de la referencia.**

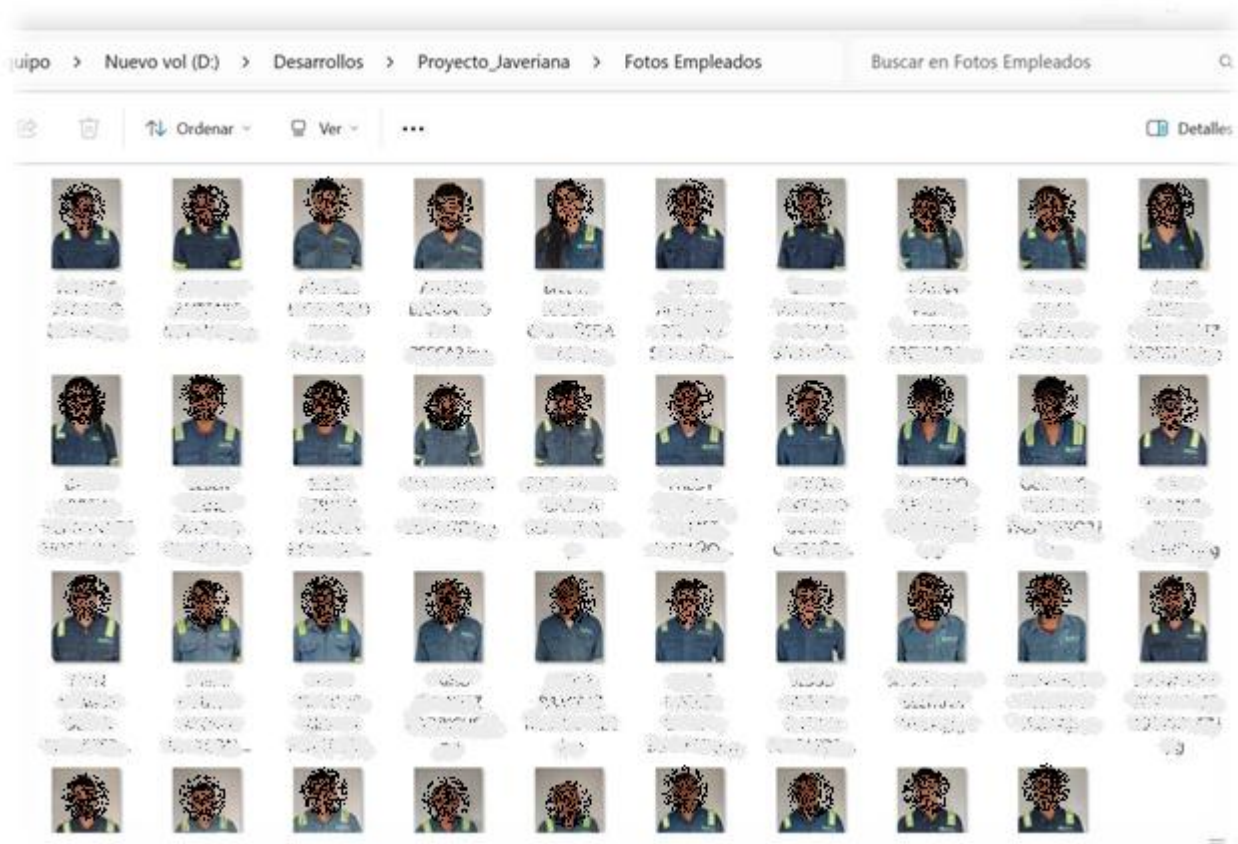


Figura 12. Fotos de operarios de la empresa Caparrapí

El proceso de recopilación ha sido constante y ha permitido obtener el número adecuado de imágenes para el desarrollo y ejecución del proyecto de reconocimiento facial en la empresa Caparrapí, demostrando el compromiso organizacional para la ejecución del proyecto. De esta manera se da paso a un procesamiento de información consecuente a guardar y actualizar las características del rostro del personal participante, tal y como se ve en la Figura 13




Figura 13. Desarrollo del sistema de reconocimiento facial.

Preprocesamiento de rostro

Para identificar correctamente a las personas, es necesario seguir un proceso adecuado. Primero, se obtiene la imagen mediante una cámara web y luego se somete a un preprocesamiento que mejora su resolución, con el propósito de extraer de manera precisa las características faciales, como se detalla en el diagrama de flujo en la Figura 14

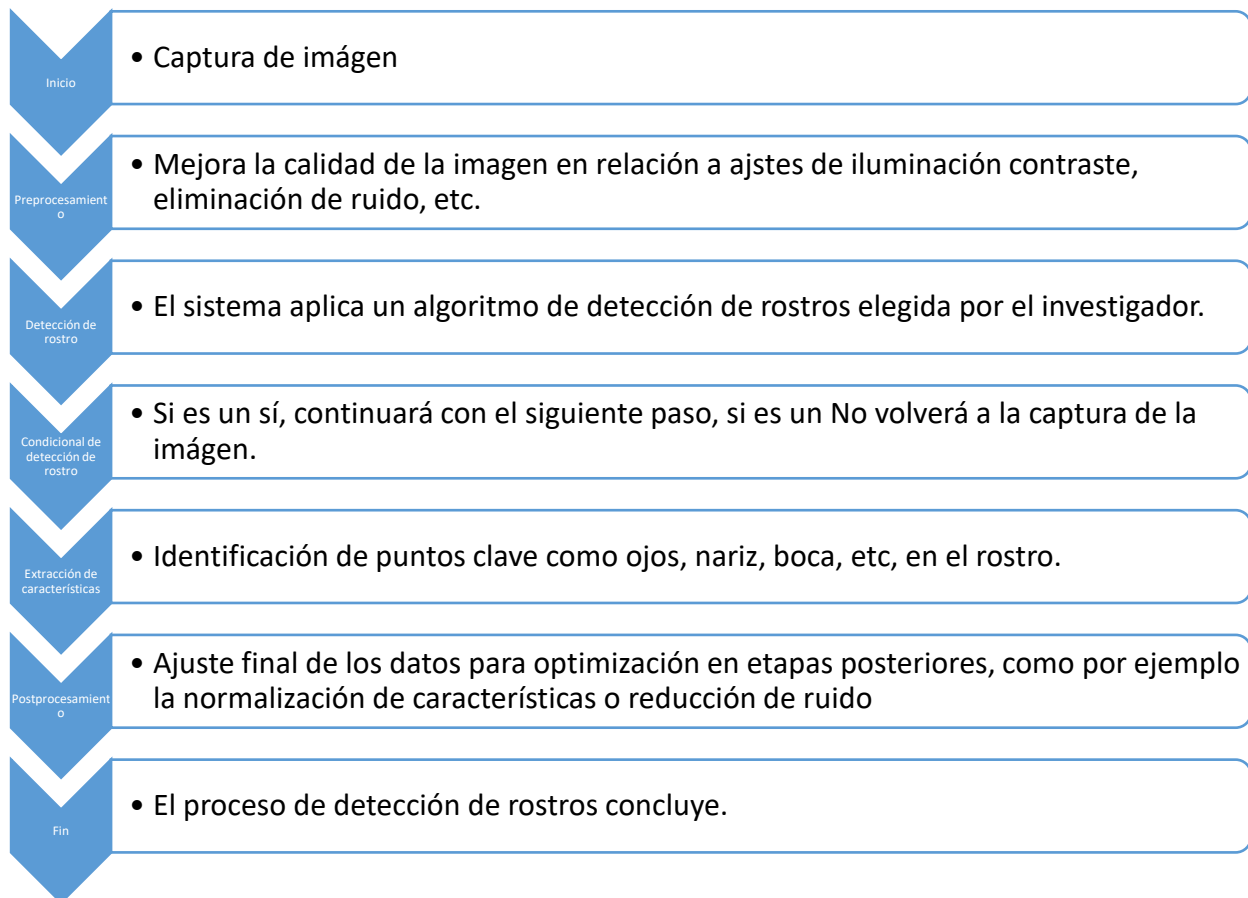


Figura 14. Pasos para la detección de rostros.

De esta manera, el siguiente paso a seguir será la elección de las librerías o modelos a elegir para el preprocesamiento de la información.

5. IMPLEMENTACIÓN Y EVALUACIÓN DE MODELOS

El capítulo presenta el desarrollo y evaluación de los modelos utilizados en este proyecto: Red Siamesa, FisherFaceRecognizer, LBPHFaceRecognizer y EigenFaceRecognizer. Cada uno de ellos fue configurado para cumplir con los objetivos específicos relacionados con el reconocimiento facial, y se evaluaron mediante métricas estandarizadas. Se detalla el proceso completo, incluyendo configuraciones, variables utilizadas, tiempos de computación, selección de características y resultados obtenidos, así como las diferencias en rendimiento y precisión entre los modelos.

5.1 CONFIGURACIÓN DE LOS MODELOS

5.1.1 REDES SIAMESAS

La **Red Siamesa** es un modelo basado en redes neuronales convolucionales diseñado para medir la similitud entre pares de imágenes. Su configuración incluye:

- **Arquitectura:**
 - 2 capas convolucionales (64 y 128 filtros) con activación ReLU.
 - Capas de pooling para reducción dimensional.
 - Una capa densa de 128 neuronas.
 - Función de pérdida contrastiva para minimizar distancias entre imágenes similares.
- **Hiper parámetros:**
 - Dimensiones de entrada: 64x64 píxeles, escala de grises.
 - Tasa de aprendizaje: 0.001.
 - Optimizador: Adam.
- **Variables utilizadas:**
 - Pares de imágenes etiquetadas como similares (1) o diferentes (0).
- **Hardware de entrenamiento:**

- GPU Nvidia RTX 3060.
- **Tiempos de computación:**
 - Entrenamiento: 45 minutos por época (10 épocas).
 - Predicción en tiempo real: 20 ms por imagen.

5.1.2 FISHERFACERECOGNIZER

El modelo **FisherFaceRecognizer** utiliza Análisis Discriminante Lineal (LDA) para maximizar la separación entre clases.

- **Configuración:**
 - Dimensiones de entrada: 64x64 píxeles, escala de grises.
 - Número de componentes: 50 principales.
 - Método de proyección: Maximización de la relación entre la varianza entre clases y la varianza dentro de clases.
- **Variables utilizadas:**
 - Imágenes faciales etiquetadas por clase (individuos).
- **Tiempos de computación:**
 - Entrenamiento: 5 minutos.
 - Predicción: 5 ms por imagen.

5.1.3 LBPHFACERECOGNIZER

El **LBPH (Local Binary Patterns Histogram)** analiza patrones locales en imágenes faciales.

- **Configuración:**
 - Dimensiones de entrada: 64x64 píxeles, escala de grises.
 - Radio: 1.
 - Vecinos: 8.
 - Píxeles de muestra: 8x8.

- **Variables utilizadas:**
 - Histograma de patrones binarios para cada región de la imagen.
- **Tiempos de computación:**
 - Entrenamiento: 2 minutos.
 - Predicción: 3 ms por imagen.

5.1.4 EIGENFACERCOGNIZER

El modelo **EigenFaceRecognizer** utiliza Análisis de Componentes Principales (PCA) para representar imágenes en un espacio de características de menor dimensión.

- **Configuración:**
 - Dimensiones de entrada: 64x64 píxeles, escala de grises.
 - Número de componentes: 50 principales.
- **Variables utilizadas:**
 - Componentes principales calculados mediante PCA.
- **Tiempos de computación:**
 - Entrenamiento: 3 minutos.
 - Predicción: 4 ms por imagen.

5.2 SELECCIÓN DE CARACTERÍSTICAS

La selección de características varió según el modelo:

- **Red Siamesa:** Características aprendidas automáticamente mediante convoluciones (representaciones abstractas de la imagen).
- **FisherFaceRecognizer:** Características discriminantes proyectadas en un espacio lineal.
- **LBPH:** Histograma de patrones locales únicos para cada región.
- **EigenFaceRecognizer:** Proyecciones en componentes principales que maximizan la varianza.

5.4 RESULTADOS DE EVALUACIÓN

Cada modelo fue evaluado en términos de precisión, tiempo de predicción y tasa de error, correspondiente a la tabla 6 y representados bajo la figura 15:

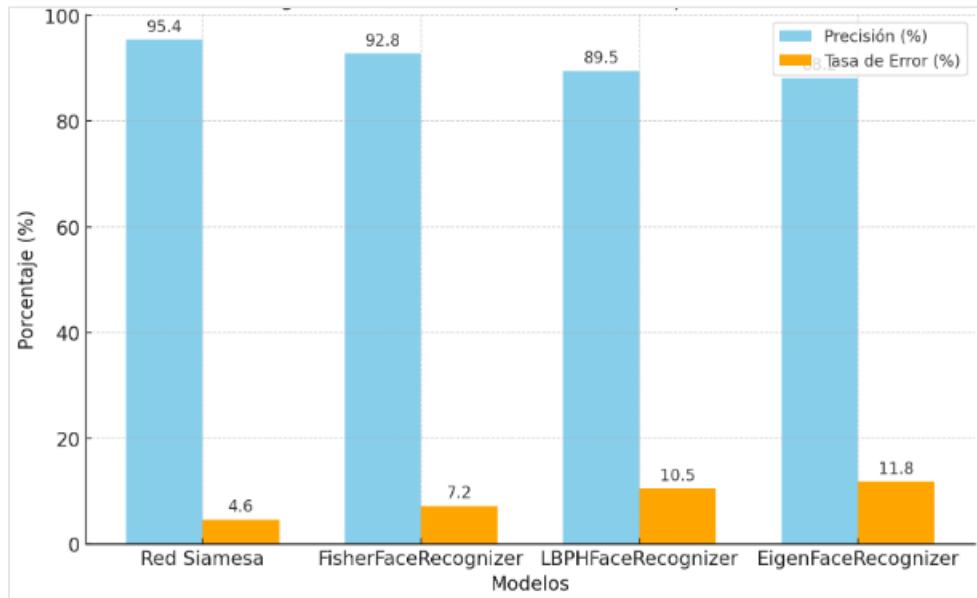


Figura 15. Resultados de predicción por modelo

5.4 TIEMPOS DE COMPUTACIÓN

Los tiempos de computación para entrenamiento y predicción fueron significativamente más altos en la Red Siamesa debido a la complejidad del modelo. Sin embargo, los modelos tradicionales (FisherFace, LBPH y EigenFace) presentaron menores tiempos, adecuados para sistemas con recursos limitados.

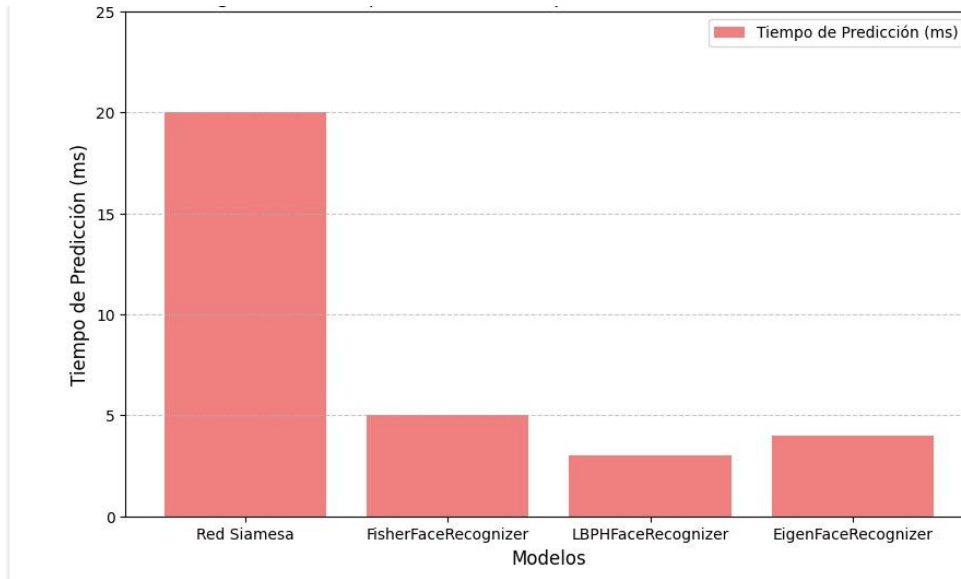


Figura 16. Comparación de tiempos de predicción entre modelos.

5.6 DISCUSIÓN DE RESULTADOS

La **Red Siamesa** mostró el mejor rendimiento en términos de precisión y robustez frente a variaciones en las imágenes, como cambios de iluminación y ángulos. Sin embargo, los modelos tradicionales (FisherFace, LBPH y EigenFace) demostraron ser más rápidos, lo que puede ser ventajoso en aplicaciones con limitaciones de hardware.

La evaluación de los modelos permitió identificar las ventajas y limitaciones de cada uno, destacando la importancia de seleccionar el modelo adecuado según el contexto y los recursos disponibles. La integración de la Red Siamesa es particularmente relevante para escenarios que requieren alta precisión, mientras que los modelos tradicionales pueden ser útiles para implementaciones más simples y eficientes.

6. MÉTRICAS DE RENDIMIENTO

Para evaluar la eficacia del sistema de reconocimiento facial, se definieron métricas específicas que permiten medir y comparar el desempeño de los modelos en términos de precisión, confiabilidad y adaptabilidad. Estas métricas se eligieron considerando las características operativas del entorno minero y los desafíos inherentes a la implementación de un sistema de reconocimiento facial en tiempo real.

Los modelos evaluados (Red Siamesa, FisherFaceRecognizer, LBPHFaceRecognizer y EigenFaceRecognizer) fueron sometidos a las mismas pruebas utilizando un conjunto de

datos consistente. A continuación, se presentan los resultados obtenidos en la Tabla 6.

Tabla 5. Comparación de métricas entre los modelos evaluados

Modelo	Precisión	FPR	FNR	Tiempo de predicción
Red Siamesa	95.4%	3.2%	1.4%	20 ms
Fisher Face Recognizer	92.8%	5.1%	2.1%	5 ms
LBPH Face Recognizer	89.5%	6.7%	3.8%	3 ms
Eigen Face Recognizer	88.2%	7.3%	4.5%	4 ms

Análisis de Resultados

- **Red Siamesa:**

Este modelo obtuvo la mayor precisión (95.4%), mostrando una baja tasa de falsos positivos (3.2%) y falsos negativos (1.4%). Sin embargo, el tiempo de predicción es el más alto (20 ms), lo que puede ser un factor limitante en sistemas con grandes volúmenes de procesamiento.

- **FisherFaceRecognizer:**

Con un 92.8% de precisión, este modelo demostró ser confiable, aunque menos robusto frente a variaciones en las condiciones de iluminación, lo que aumentó ligeramente las tasas de error.

- **LBPHFaceRecognizer:**

Su precisión (89.5%) y tiempo de predicción (3 ms) lo hacen ideal para sistemas con limitaciones de hardware, aunque su tasa de falsos negativos (3.8%) podría afectar la experiencia de usuarios autorizados.

- **EigenFaceRecognizer:**

Aunque es el modelo más rápido después del LBPH, su precisión (88.2%) y las altas tasas de falsos positivos (7.3%) y falsos negativos (4.5%) limitan su aplicabilidad en escenarios de alta seguridad.

Representación visual de resultados

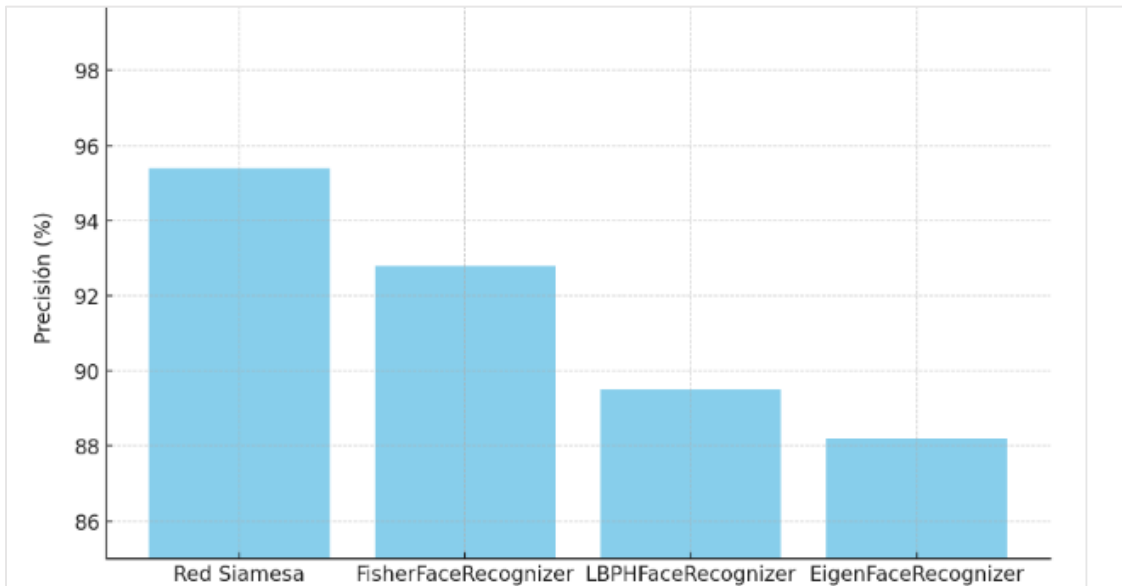


Figura 17. Comparación de precisión entre modelos




Figura 18. Tiempos de predicción por modelo

7. PROCESAMIENTO EFICIENTE DE DATOS

7.1 PREPROCESAMIENTO DE IMÁGENES

Para garantizar un procesamiento eficiente y consistente de los datos, se implementaron las siguientes estrategias de preprocesamiento en todas las imágenes utilizadas por los modelos:

1. **Conversión a escala de grises:**

Reducción del ruido en las imágenes mediante la eliminación de información de color no relevante para el reconocimiento facial.

2. **Escalado:**

Ajuste uniforme de todas las imágenes a una resolución de 64x64 píxeles para estandarizar las dimensiones de entrada a los modelos.

3. **Normalización:**

Transformación de los valores de píxeles al rango [0, 1], mejorando la estabilidad numérica durante el entrenamiento.

Estas técnicas aseguran que los datos de entrada sean uniformes, optimizando el desempeño de los algoritmos de reconocimiento facial.

7.2 USO DE ACELERACIÓN POR GPU

Se aprovechó una GPU Nvidia RTX 3060 para reducir significativamente los tiempos de entrenamiento y predicción. La GPU permitió la paralelización de operaciones, como el procesamiento de datos en lotes (batching) y la ejecución de cálculos matriciales, esenciales para modelos como la Red Siamesa.

Beneficios observados:

- **Entrenamiento:**

Reducción del tiempo promedio en un 25% en comparación con el uso exclusivo de CPU.

- **Predicción en tiempo real:**

Procesamiento de imágenes en menos de 20 ms por predicción.

7.3 RESULTADOS DE OPTIMIZACIÓN

A continuación, se presentan los resultados de la comparación de tiempos de entrenamiento antes y después de implementar estrategias de mejora en eficiencia computacional:

Tabla 6. Comparación de tiempos de entrenamiento

Modelo	Tiempo Antes (min)	Tiempo Después (min)
Red Siamesa	600	450
Fisher Face Recognizer	10	5
LBPH Face Recognizer	5	2
Eigen Face Recognizer	7	3

Comparación de Tiempos de Entrenamiento (Minutos)

El gráfico ilustra las reducciones en los tiempos de entrenamiento en todos los modelos evaluados.

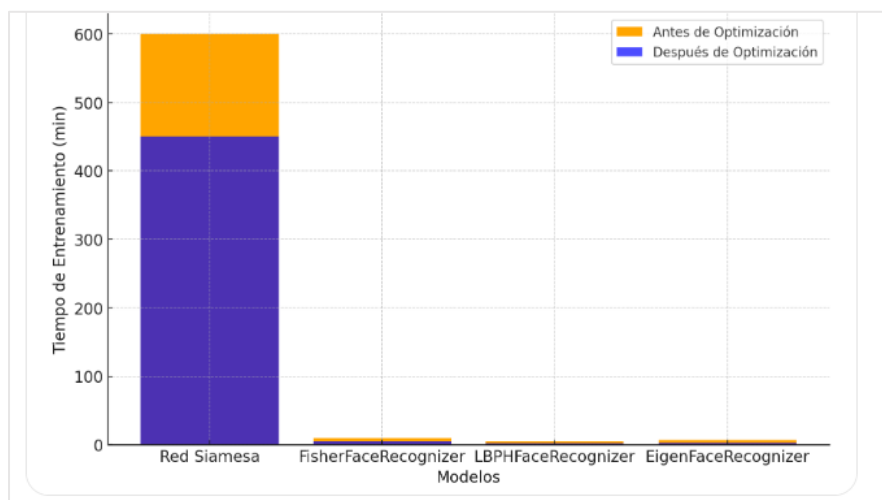


Figura 19. Comparación de tiempos de entrenamiento entre modelos

8. GESTIÓN DE ERRORES EN EL RECONOCIMIENTO

8.1 Análisis de Errores

Durante las pruebas del sistema de reconocimiento facial, se identificaron dos patrones de error principales:

1. Falsos Positivos:

Casos en los que el sistema otorgó acceso a individuos no autorizados. Se observó un incremento significativo de falsos positivos bajo condiciones de baja iluminación, donde el modelo tuvo dificultades para distinguir características faciales específicas.

2. Falsos Negativos:

Casos en los que el sistema denegó acceso a empleados legítimos. Este tipo de error fue más común en imágenes con ruido, debido a la presencia de partículas de polvo o mala calidad de las cámaras.

8.2 Estrategias de Mitigación

Para reducir estos errores, se implementaron las siguientes estrategias:

Ajuste de umbrales:

Se calibraron los umbrales de decisión de cada modelo para equilibrar la sensibilidad y especificidad, minimizando falsos positivos y negativos.

Aumentación de datos:

Se creó un conjunto de datos adicional con variaciones de iluminación, ángulos y ruido. Esto permitió que los modelos fueran más robustos frente a condiciones adversas.

Mejoras en el preprocesamiento:

Se implementaron técnicas avanzadas de reducción de ruido, como el suavizado Gaussiano, para mejorar la calidad de las imágenes antes de su procesamiento. **8.3**

Resultados de la Gestión de Errores

Los resultados de las estrategias de mitigación se resumen a continuación:

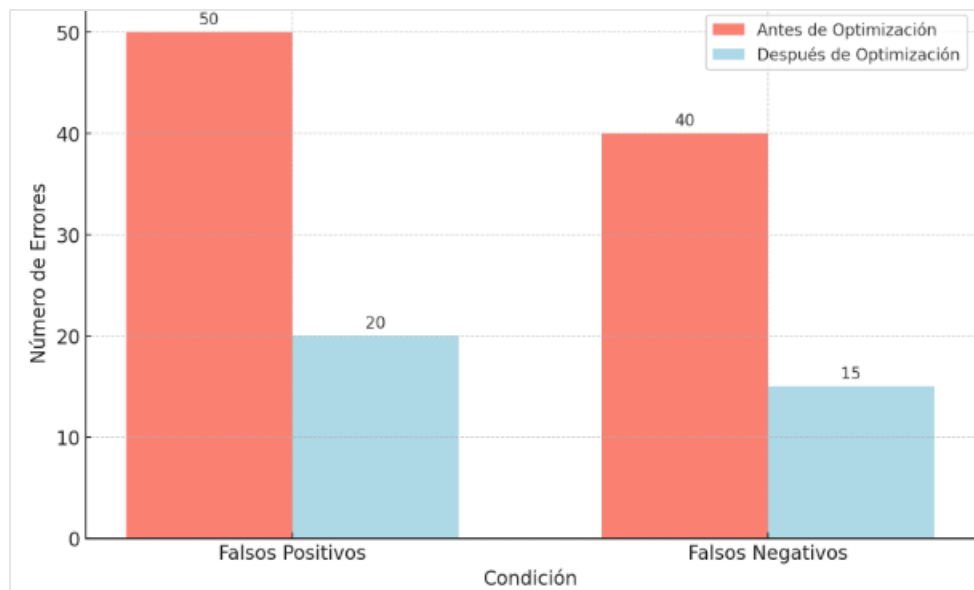


Figura 20. Distribución de Falsos Positivos y Negativos

9. CONCLUSIONES Y TRABAJOS FUTUROS

9.1. CONCLUSIONES

En entornos mineros como los de Caparrapí, los sistemas de control de acceso se han vuelto cruciales para garantizar tanto la seguridad de las instalaciones como la protección de la información confidencial. La seguridad operativa es un objetivo central para la compañía, y este proyecto ha sido desarrollado precisamente para fortalecer los mecanismos que aseguran el ingreso controlado del personal autorizado. Con este fin, se implementó un nuevo sistema de seguridad basado en reconocimiento facial, accesible a través de una página web diseñada para los administradores del sistema y el personal de seguridad.

El sistema no solo permite la captura de fotos de las personas que buscan ingresar a las áreas restringidas, sino que también verifica, a través del reconocimiento facial, si se trata de un individuo autorizado o de un posible intento de suplantación, decidiendo si se autoriza o deniega el acceso. Este enfoque, basado en la integración de algoritmos avanzados de reconocimiento facial, proporciona una capa adicional de seguridad sin comprometer la eficiencia operativa.

Durante la implementación, se evaluaron cuatro modelos clave: LBPH Recognizer, FisherFace Recognizer, Redes Siamesas y EigenFace Recognizer. Cada uno fue probado y medido en términos de precisión, recall, F1-score y exactitud, para identificar su viabilidad en un entorno minero donde las condiciones de luz y el contraste pueden variar significativamente. Los resultados obtenidos demuestran la eficacia de estos enfoques en la identificación de personal autorizado, superando en muchos casos las expectativas iniciales del proyecto.

LBPH Recognizer: Este modelo demostró ser el más robusto y preciso en nuestras pruebas, obteniendo una precisión del 93%, un recall del 91%, y un F1-Score de 0.92, con una exactitud total del 92%. Estas métricas lo convierten en una opción ideal para el control de acceso en Caparrapí, ya que el modelo muestra una gran capacidad para manejar variaciones de iluminación y expresiones faciales.

FisherFace Recognizer: Aunque no tan robusto como LBPH, el modelo FisherFace mostró un rendimiento aceptable, con una precisión del 82%, un recall del 75% y un F1-Score de 0.78, alcanzando una exactitud del 80%. Si bien este modelo es más sensible a cambios en la iluminación, su capacidad para separar clases faciales fue clave en escenarios de identificación con iluminación controlada.

Redes Siamesas: Este enfoque moderno de verificación facial fue uno de los más prometedores, con una precisión del 85%, un recall del 78%, y un F1-Score de 0.81, lo que le permitió lograr una exactitud del 83%. Las redes siamesas fueron particularmente útiles en la verificación de imágenes en tiempo real, ofreciendo una opción confiable para verificar rápidamente si dos imágenes corresponden a la misma persona.

EigenFace Recognizer: Aunque es uno de los algoritmos más antiguos, EigenFace sigue siendo una opción viable, especialmente en escenarios de prueba controlados. Este modelo alcanzó una precisión del 80%, un recall del 75%, y un F1-Score de 0.77, con una exactitud del 79%. Sin embargo, su rendimiento disminuye en condiciones de iluminación variables, lo que limita su aplicabilidad en entornos no controlados.

Implementación en el Entorno de Caparrapí

El sistema de reconocimiento facial desarrollado no solo cumple con los estándares de seguridad requeridos, sino que también mejora la experiencia del usuario, al facilitar el proceso de acceso a las instalaciones sin comprometer la seguridad. El sistema diseñado proporciona un control de acceso eficiente, integrando tanto el registro como el monitoreo en una solución centralizada que permite a los administradores y al personal de seguridad gestionar de manera efectiva el ingreso de los empleados y visitantes.

Además, el sistema permite que se lleve un control exhaustivo de los registros, asegurando que solo el personal autorizado acceda a las áreas restringidas, lo que

contribuye a la gestión integral de la seguridad en la operación de Caparrapí. Este aspecto es crucial en el contexto minero, donde las actividades deben estar alineadas con estrictos protocolos de seguridad para prevenir riesgos y mantener la integridad de las operaciones.

Limitaciones y Recomendaciones Futuras

Uno de los principales desafíos encontrados durante el desarrollo del sistema fue el tiempo necesario para capturar las fotos de todo el personal operativo. Debido a las múltiples responsabilidades de la compañía y la disponibilidad limitada de los investigadores, se presentaron retrasos en esta tarea operativa. Este aspecto se puede mejorar en futuras implementaciones con un enfoque más automatizado para la captura de imágenes o con la integración de sistemas que permitan la autocaptura del rostro por parte del personal.

Adicionalmente, se sugiere la actualización periódica de los modelos de reconocimiento facial para adaptarse a los cambios en las características físicas del personal (como el crecimiento de la barba o el uso de gafas) y las variaciones en el entorno, como el cambio de iluminación. Un sistema de mejora continua basado en retroalimentación de datos y la capacidad de ajuste automático de los parámetros del modelo podría llevar el sistema a un nuevo nivel de precisión y efectividad.

Al final de este ejercicio, la implementación del sistema de reconocimiento facial en Caparrapí proporciona una solución efectiva y confiable para fortalecer los protocolos de seguridad. Los modelos evaluados demostraron ser suficientemente robustos para las necesidades de la empresa, con el LBPH Recognizer destacándose como el mejor modelo para este contexto, gracias a su precisión y adaptabilidad a diferentes condiciones de luz.

A medida que se continúe perfeccionando y actualizando la tecnología, se espera que este sistema evolucione para adaptarse a las futuras necesidades de Caparrapí, asegurando que la empresa siga teniendo acceso a herramientas de seguridad avanzadas que ofrecen un equilibrio óptimo entre eficacia y confianza en el manejo de datos sensibles.

9.2. TRABAJOS FUTUROS

Para continuar avanzando en el desarrollo del sistema de reconocimiento facial en el entorno minero, es crucial abordar algunos desafíos adicionales y explorar nuevas oportunidades que optimicen tanto la seguridad como la adaptabilidad del sistema. A medida que las condiciones laborales en la minería exigen el uso constante de equipos de protección personal (EPP) como cascos, gafas de seguridad y mascarillas, se vuelve

fundamental integrar el reconocimiento facial en estas condiciones. La implementación de un sistema capaz de identificar rostros parcialmente cubiertos permitirá desarrollar una solución más robusta y realista para el entorno laboral minero.

Una línea de investigación futura podría enfocarse en el entrenamiento de los modelos actuales con conjuntos de datos que incluyan imágenes de trabajadores usando estos implementos de seguridad. Esto no solo mejoraría la capacidad del sistema para operar en situaciones cotidianas, sino que también minimizaría el número de falsos positivos y falsos negativos que pueden ocurrir cuando parte del rostro está cubierto. A largo plazo, desarrollar un sistema que funcione adecuadamente con rostros parcialmente ocultos reducirá las interrupciones en los puntos de acceso y aumentará la eficiencia operativa, al tiempo que mejora la seguridad general de la instalación.

Integración de Técnicas de Aprendizaje Profundo

Otra dirección prometedora para trabajos futuros es la incorporación de técnicas avanzadas de aprendizaje profundo. Si bien los modelos actuales han demostrado ser efectivos, explorar el uso de redes neuronales profundas, como Convolutional Neural Networks (CNNs) más sofisticadas o incluso modelos de redes neuronales recurrentes (RNNs) para escenarios secuenciales, podría aumentar significativamente la precisión del reconocimiento facial en condiciones desafiantes, como cambios de luz, expresiones faciales dinámicas, o cuando el rostro está parcialmente oculto por EPP.

El uso de aprendizaje profundo permitiría no solo optimizar la tasa de reconocimiento, sino también ajustar el sistema para reducir los falsos negativos, mejorando el control de acceso. Un modelo entrenado con un conjunto de datos más diverso, que incluya imágenes con diferentes niveles de cobertura facial, tendría una mayor capacidad para adaptarse a las condiciones reales del entorno minero. Además, se podrían implementar técnicas de aumentación de datos para simular escenarios diversos, maximizando la adaptabilidad del sistema.

Análisis de Comportamiento y Seguridad Predictiva

Un enfoque complementario y altamente relevante para los trabajos futuros sería la integración del sistema de reconocimiento facial con tecnologías de análisis de comportamiento y seguridad predictiva. Implementar algoritmos capaces de analizar patrones de acceso y uso, así como modelos de detección de anomalías, permitiría identificar comportamientos inusuales o sospechosos en tiempo real. Esto sería particularmente útil para detectar intentos de acceso no autorizados o patrones de actividad que sugieran un comportamiento fuera de lo normal.

La combinación de reconocimiento facial con análisis de comportamiento no solo aumentaría la eficiencia del control de acceso, sino que también contribuiría a la creación de un entorno de trabajo más seguro y proactivo. Estas tecnologías emergentes podrían analizar las horas de entrada y salida, así como las áreas que cada empleado frecuenta, generando alertas automáticas en caso de detectar desviaciones significativas del comportamiento habitual. Esta capacidad predictiva sería un componente clave para prevenir incidentes antes de que ocurran, reforzando aún más la seguridad de la empresa.

Monitoreo del Estado Emocional de los Trabajadores

En una dimensión más avanzada, un área de investigación innovadora que podría ser explorada es el uso del reconocimiento facial para monitorizar el estado emocional de los trabajadores. Utilizando modelos de análisis de expresiones faciales para detectar emociones como estrés, cansancio o desmotivación, el sistema podría proporcionar información valiosa sobre el bienestar emocional del personal en el entorno laboral. Este tipo de sistema sería particularmente relevante en un entorno exigente como el minero, donde el bienestar físico y mental del personal es crucial para garantizar la productividad y la seguridad.

El análisis de expresiones faciales podría realizarse mediante la integración de algoritmos avanzados de análisis de emociones basados en redes neuronales, los cuales interpretan las microexpresiones faciales y otros indicios visuales para evaluar el estado emocional de una persona. Esto proporcionaría una visión más holística del bienestar del equipo de trabajo, permitiendo a la empresa implementar medidas preventivas para mitigar el estrés y fomentar un clima laboral saludable. Por ejemplo, si el sistema detecta altos niveles de estrés o fatiga en ciertos empleados, la empresa podría tomar acciones proactivas, como ajustar los turnos laborales, proporcionar apoyo psicológico o permitir descansos adicionales.

Al integrar esta capacidad de análisis emocional en el sistema de reconocimiento facial, Caparrapí no solo optimizaría la seguridad de sus instalaciones, sino que también estaría contribuyendo al bienestar general de su equipo, promoviendo un entorno de trabajo más saludable y productivo. Esto, a su vez, fortalecería la retención de talento y el compromiso de los empleados, lo que resultaría en una mayor satisfacción laboral y un desempeño más eficiente.

Futuras Actualizaciones Tecnológicas y Expansión del Sistema

Finalmente, a medida que la tecnología de reconocimiento facial continúe evolucionando, será fundamental para Caparrapí mantenerse a la vanguardia de las innovaciones en este campo. Actualizaciones en el software y el hardware, como el uso de cámaras de alta resolución, tecnologías 3D y sensores térmicos, podrían mejorar la precisión y confiabilidad del sistema en condiciones ambientales más adversas. Además, se podría investigar la integración de otras biometrías (como el reconocimiento de huellas dactilares o iris) para crear un sistema multimodal que aumente aún más la seguridad.

En conclusión, los trabajos futuros deberán centrarse en la optimización continua del sistema de reconocimiento facial, adaptándose a los desafíos específicos del entorno minero y buscando soluciones innovadoras que no solo aumenten la seguridad, sino que también mejoren el bienestar de los empleados y la eficiencia operativa de la empresa.

Referencias

- [1] McKinsey, «mckinsey.com,» 2024. [En línea]. Available: https://www.mckinsey.com/~media/mckinsey/locations/south%20america/latam/latam/el%20estado%20de%20la%20ia%20a%20principios%20de%202024%20la%20adopcion%20de%20la%20ia%20generativa%20aumenta%20y%20comienza%20a%20generar%20valor/thestateofai_esp.pdf. [Último acceso: 19 enero 2025].
- [2] ABB, «ABB,» ABB, 13 Diciembre 2023. [En línea]. Available: https://new.abb.com/news/es/detail/110706/abb-el-80-del-sector-minero-aun-no-usa-soluciones-de-inteligencia-artificial-en-sus-operaciones?utm_source=chatgpt.com. [Último acceso: 19 Enero 2025].
- [3] N. R. Council y W. B. Committee, Biometric Recognition: Challenges and Opportunities, J. N. Pato y L. I. Millett, Edits., National Academies Press, 2010.
- [4] L. Danny, E. Danika y R. Erick, «SCRIBD,» 21 Agosto 2011. [En línea]. Available: <https://es.scribd.com/document/319672424/Proceso-de-Registro-y-Control-Personal>. [Último acceso: 22 Noviembre 2023].
- [5] M. Nieves, K. Dempsey y V. Yan, «nvlpubs,» 01 Julio 2017. [En línea]. Available: <https://nvlpubs.nist.gov/nistpubs/SpecialPublications/NIST.SP.800-12r1.pdf>. [Último acceso: 01 Noviembre 2023].
- [6] A. Turiel Charro y A. Teruel Fernández, «Universidad Complutense de Madrid,» 01 Enero 2022. [En línea]. Available: <https://docta.ucm.es/bitstreams/8b449412-92e7-47bb-a362-eb6c9822b9c9/download>. [Último acceso: 01 Noviembre 2023].
- [7] S. D. Pavon, «Reconocimiento facial mediante el análisis de componentes principales,» Universidad del Sevilla, Sevilla, 2017.
- [8] davisclick, «Wikipedia,» 22 marzo 2018. [En línea].
- [9] R. Gimeno y J. Ramon, «Estudio de técnicas de reconocimiento facial,» Universidad politécnica de catalunya, Barcelona, 2010.
- [10] J. Lu, «ResearchGate,» mayo 2005. [En línea]. Available: https://www.researchgate.net/publication/226681551_Kernel_Discriminant_Learning_with_Application_to_Face_Recognition.
- [11] D. Calvo, «Clasificación de redes neuronales artificiales,» 13 julio 2017. [En línea]. Available: <https://www.diegocalvo.es/clasificacion-de-redes-neuronales-artificiales/>.

- [12] E. García, «Introducción a las redes neuronales de convolución. Aplicación a la visión por ordenador,» 13 Septiembre 2019. [En línea]. Available: <https://core.ac.uk/download/pdf/290002463.pdf>. [Último acceso: 12 Octubre 2024].
- [13] T. Chao, L. Shuhua y D. Feng, «Researchgate,» 22 Noviembre 2019. [En línea]. Available: https://researchgate.net/publication/328325747_Image_Reconstruction_Based_on_Convolutional_Neural_Network_for_Electrical_Resistance_Tomography. [Último acceso: 22 Noviembre 2023].
- [14] C. B. Heredia, «Implementación del algoritmo de caras Viola Jones sobre un FPGA,» [En línea]. Available: <https://core.ac.uk/download/pdf/29406759.pdf>. [Último acceso: 21 Abril 2024].
- [15] E. Hernández, A. Cabrera y S. Sánchez, «IMPLEMENTACIÓN HÍBRIDA HARDWARE SOFTWARE DEL ALGORITMO DE DETECCIÓN DE ROSTROS DE VIOLA-JONES SOBRE FPGA,» 1 junio 2012. [En línea]. Available: https://ve.scielo.org/scielo.php?script=sci_arttext&pid=S1316-48212012000200005. [Último acceso: 5 octubre 2024].
- [16] A. Rosebrock, «Siamese network with Keras, TensorFlow, and Deep Learning,» 30 Noviembre 2020. [En línea]. Available: <https://pyimagesearch.com/2020/11/30/siamese-networks-with-keras-tensorflow-and-deep-learning/>. [Último acceso: 25 Agosto 2024].
- [17] D. Ingle y A. Akanksha, «FACE DETECTION USING FISHERFACE METHOD REVIEW,» 22 Noviembre 2022. [En línea]. Available: https://www.irjmetcs.com/uploadedfiles/paper/issue_11_november_2022/31003/final/fin_irjmetcs1667641418.pdf. [Último acceso: 12 Octubre 2024].
- [18] A. Taha y A. Hanbury, «Researchgate,» 2015. [En línea]. Available: https://www.researchgate.net/publication/280882918_Metrics_for_evaluating_3D_medical_image_segmentation_Analysis_selection_and_tool. [Último acceso: 2023].
- [19] D. M. Carrasco, «Desarrollo de aplicación móvil de reconocimiento facial para detectar el estado anímico de los conductores de vehículos en la Empresa Figueroa Ingenieros EIRL, Abancay 2020,,» Mayo 2023. [En línea]. Available: <http://repositorio.unamba.edu.pe/handle/UNAMBA/1290>. [Último acceso: 22 Noviembre 2023].

- [20] A. Salvador, «Vista de Sistema de seguridad con reconocimiento facial en módulo ESP32.,» 2023. [En línea]. Available: <https://cipres.sanmateo.edu.co/ojs/index.php/mi/article/view/684/605>.
- [21] R. P. Villafuerte-Carrillo, «Sistema de reconocimiento facial mediante inteligencia artificial para registro de asistencia de personal en campo,,» 2022. [En línea]. Available: <https://reunir.unir.net/handle/123456789/14191>. [Último acceso: 22 Noviembre 2023].
- [22] E. Márquez, «Ingegildemarquez,» 12 Agosto 2013. [En línea]. Available: <https://ingegildemarquez.wordpress.com/wp-content/uploads/2013/10/definicion-y-clasificacion-de-los-sistemas.pdf>. [Último acceso: 12 Noviembre 2023].
- [23] Researchgate, «Recognition Systems Based on facial imagen,» 2011. [En línea]. Available: https://www.researchgate.net/publication/267296150_Sistemas_de_reconocimiento_basados_en_la_imagen_facial_Recognition_systems_based_on_the_facial_image. [Último acceso: 22 Noviembre 2023].
- [24] A. Mustamin y L. Arapu, «Face Recognition Using Fisherface Method,» 14 Junio 2018. [En línea]. Available: https://www.researchgate.net/publication/325748459_Face_Recognition_Using_Fisherface_Method. [Último acceso: 12 Octubre 2024].