



Sistema de reconocimiento de rostros con tapabocas a través de los clasificadores Haar cascade, LBPH, Eigenface y Fisherface

Facial recognition system with facemask using Haar cascade, LBPH, Eigenface and Fisherface classifiers

Emmanuel Grisales-Londoño ^a, Oscar Ignacio Botero Henao ^b, Ignacio Calle-Pérez ^c, Oscar Julian Galeano Echeverri ^d & Diego Orozco-Gómez ^e

^a Institución Universitaria Pascual Bravo, Medellín, Colombia, emmanuel.grisales@pascualbravo.edu.co

^b Institución Universitaria Pascual Bravo, Colombia, oscar.botero@pascualbravo.edu.co

^c Institución Universitaria Pascual Bravo, Medellín, Colombia, jesus.calle@pascualbravo.edu.co

^d Institución Universitaria Pascual Bravo, Colombia, julian.galeano@pascualbravo.edu.co

^e Institución Universitaria Pascual Bravo, Medellín, Colombia, diego.orozco@pascualbravo.edu.co

Recibido: septiembre 30, 2022. Aceptado: enero 30, 2023

Resumen

La implementación de sistemas de acceso automatizados en lugares con alta afluencia, como sistemas de transporte y centros de salud, es una necesidad creciente para mitigar la congestión y el estrés laboral. En este contexto, el reconocimiento facial se presenta como una solución eficaz, ofreciendo un control de acceso personalizado y eficiente. La inteligencia artificial, junto con bases de datos robustas, permite la identificación precisa de rostros y, complementada con clasificadores de rostros, el reconocimiento facial. El clasificador Haar Cascade opera mediante pequeños clasificadores que analizan diferentes porciones de una imagen facial, las cuales se combinan para proporcionar un resultado de detección preciso, facilitando la creación de una base de datos que puede ser entrenada por algoritmos de reconocimiento. Este estudio presenta un sistema de reconocimiento facial utilizando el clasificador Haar Cascade para la recolección de imágenes, y los clasificadores de Histograma de Patrones Binarios Locales (LBPH), EigenFace (EF) y FisherFace (FF) para el proceso de reconocimiento. La recolección de datos incluyó imágenes de rostros de seis personas, obteniendo 350 imágenes sin tapabocas y 350 imágenes con tapabocas. Los tiempos de entrenamiento variaron entre 9.54 segundos y 9287.64 segundos. Una vez entrenados los modelos, el tiempo de reconocimiento facial osciló entre 0.0001 segundos y 0.4447 segundos. La precisión del reconocimiento con el clasificador LBPH se ubicó entre 80.9069% y 100%, con el clasificador EF entre 69.7542% y 100%, y con el clasificador FF entre 31.6017% y 91.3684%. Estos resultados demuestran la rapidez del sistema de reconocimiento facial propuesto, destacando la precisión y velocidad del clasificador LBPH.

Palabras clave: algoritmo de clasificación, entrenador, inteligencia artificial, visión computacional.

Abstract

The implementation of automated access systems in high-traffic areas, such as transportation systems and healthcare centers, is a growing necessity to mitigate congestion and work-related stress. In this context, facial recognition emerges as an effective solution, offering personalized and efficient access control. Artificial intelligence, combined with robust databases, enables precise facial identification, and when complemented with face classifiers, facilitates facial recognition. The Haar Cascade classifier operates through small classifiers that analyze different portions of a facial image, which are then combined to provide a precise detection result, facilitating the creation of a database that can be trained by recognition algorithms. This study presents a facial recognition system using the Haar Cascade classifier for image collection, and the Local Binary Patterns Histogram (LBPH), EigenFace (EF), and FisherFace (FF) classifiers for the recognition process. The data collection included images of six individuals, obtaining 350 images without face masks and 350 images with face masks. Training times varied between 9.54 seconds and 9287.64 seconds. Once the models were trained, the facial recognition time ranged from 0.0001 seconds to 0.4447 seconds. The recognition accuracy with the LBPH classifier ranged from 80.9069% to 100%, with the EF classifier from 69.7542% to 100%, and with the FF classifier from 31.6017% to 91.3684%. These results demonstrate the speed of the proposed facial recognition system, highlighting the accuracy and speed of the LBPH classifier.

Keywords: artificial intelligence, classification algorithm, computer vision, training

Citar como:

E. Grisales, O. Botero, I. Calle, O. Galeano & D. Orozco. "Sistema de reconocimiento de rostros con tapabocas a través de los clasificadores Haar cascade, LBPH, Eigenface y Fisherface". Revista CINTEX, Vol. 27(2), pp. 44-55. 2022. DOI:

<https://doi.org/10.33131/24222208.386>

1 INTRODUCCIÓN

Actualmente, las investigaciones enfocadas en visión artificial se encuentran en un constante crecimiento debido a que esta tecnología provee un amplio rango de aplicaciones a un costo decreciente sostenido, posibilitando dar solución a diversas necesidades [1], mediante procesos de adquisición, preprocesamiento, análisis y extracción de información de imágenes y videos [2]. Continuamente se implementan diferentes técnicas y métodos de reconocimiento de objetos [3], [4], varios de estos aplicados a la detección e identificación de rostros humanos, entre los que se encuentran el espacio de rostros generado por el algoritmo EigenFace [5], estimación de máxima verosimilitud [6], máquina de soporte vectorial [7], red dispersa SNoW [8], detector cascada [9], [10], modelos de apariencia activa [11], modelos de asociación-predicción [12], modelo cambiante en 3D [13] y modelo canónico del rostro [14]. La tecnología dedicada al desarrollo de sistemas de reconocimiento facial ha cobrado un interés significativo debido a las diversas aplicaciones de uso en procesos como educación [1], biometría [15], [16], seguridad [17]–[21] y accidentalidad vehicular [22], [23].

La implementación de sistemas de reconocimiento requiere del uso de cámaras de vídeo que permitan adquirir información visual de un objeto específico [24]. Por tanto, la calidad de la imagen, la distancia del objeto a la cámara, el ángulo de ubicación del sensor con el objeto a detectar, los cambios del fondo de la imagen, y las variaciones de iluminación son aspectos para tener en cuenta con el propósito de desarrollar un sistema de reconocimiento robusto [1]. Además, dependiendo de las características físicas del objeto a reconocer, se requiere sintonizar los parámetros de la cámara, entre los que se destacan la tasa de muestreo y la resolución espacial. En el caso del reconocimiento de rostros aspectos como los previamente indicados, así como la oclusión y las expresiones faciales [16], y adicionalmente, la correcta sintonización de los parámetros de la cámara, son fundamentales debido a las características propias de los rostros como ojos, nariz y boca.

El presente trabajo tiene por objeto proveer los resultados respecto al desarrollo e implementación de un sistema de reconocimiento de rostros haciendo uso de un clasificador Haar Cascade en el proceso de recolección de imágenes y de los clasificadores Histograma de Patrones Binarios Locales (LBPH), EigenFace (EF) y FisherFace (FF) en el proceso de reconocimiento. Este documento está dividido así: la sección 2 presenta un resumen de la revisión de la literatura, la sección 3 provee el método propuesto, su desarrollo e implementación; las secciones 4 y 5 indican los resultados experimentales y la discusión respectiva; por último, la sección 6 detalla las conclusiones obtenidas de este trabajo.

2 REVISIÓN DE LA LITERATURA

Los autores en [25] desarrollaron un sistema de identificación facial de cuatro personas en una imagen haciendo uso del método Histograma de Patrones Binarios Locales y del clasificador Haar Cascade. Utilizaron 60 imágenes faciales de cada individuo adquiridas por medio de una cámara VGA, las cuales fueron preprocesadas mediante las técnicas equalización de histograma y filtro de mediana. La precisión respecto al número de rostros correctamente reconocidos con respecto al número total de datos de chequeo fue de 99.67%, aunque esta evaluación no consideró condiciones de iluminación, identificación facial con vista lateral y un conjunto mayor de personas.

Haciendo uso de los dos métodos indicados en la anterior investigación, en [18] utilizaron imágenes de rostros escaladas a 150 x 150 píxeles, provenientes de un total de ocho personas, con el objeto de realizar identificación facial. Bajo diferentes condiciones ambientales y con diversos fondos de imagen, el sistema suministró una precisión de 100% en la identificación de cada persona. En línea similar a los dos trabajos previamente mencionados, en [15] compararon el rendimiento de los métodos Histograma de Patrones Binarios Locales y Haar Cascade. De acuerdo con los experimentos realizados, determinaron que el clasificador Haar Cascade, si bien demanda mayor tiempo de ejecución en el reconocimiento en una imagen de 20 rostros, 0.369 segundos respecto a 0.109 segundos destinado por el método patrón binario local, provee una mejor precisión, 96.24% en comparación a 94.74%.

Otra investigación similar a las anteriormente indicadas fue realizada por [1]. Haciendo uso del software Matlab implementaron los métodos Histograma de Patrones Binarios Locales y Haar Cascade, contrastando la efectividad en los procesos de reconocimiento facial con los algoritmos ResNet101 y ResNet50, desarrollados mediante técnicas de aprendizaje profundo. La precisión provista por el clasificador Haar Cascade fue 90.91% y con los algoritmos ResNet101 y ResNet50 fue de 100% y 91.67% respectivamente. El clasificador Haar Cascade, aunque suministró menor precisión,

demandó menos tiempo en realizar el proceso de entrenamiento, 1.09 segundos respecto a 139.5 segundos; mostrando que el clasificador Haar Cascade puede proveer mejores prestaciones en aplicaciones que requieren entrenamiento en tiempo real.

Los autores en [26] realizaron un algoritmo de reconocimiento de rostros con técnicas de aprendizaje profundo e identificación con el clasificador Haar Cascade. El objetivo de esta investigación fue asignar un identificador único con el propósito de evaluar el desempeño del algoritmo para eventualmente ser adecuado en la creación de un banco de imágenes personalizado. Utilizando el clasificador Haar Cascade y redes neuronales convolucionales, los autores en [2] propusieron un método de clasificación de siete emociones faciales correspondientes a enfado, disgusto, miedo, felicidad, tristeza, sorpresa y neutralidad. El conjunto de imágenes utilizadas en el proceso de entrenamiento correspondió a 28709, en tanto que se emplearon 7179 imágenes de prueba, todas las imágenes con resolución 48 x 48 píxeles. El rango de precisión en la clasificación de las emociones se ubicó entre 50% y 100%. Similar al trabajo anterior, y con las mismas emociones faciales, en [27] obtuvieron precisiones entre 44% y 100%.

En [28] implementaron un sistema conformado por un clasificador Haar Cascade, histograma de gradientes orientados y máquinas de soporte vectorial con el objeto de realizar reconocimiento y clasificación de rostros. Aunque los autores indicaron que el sistema de reconocimiento provee una alta precisión, no la cuantificaron. Los autores en [21] implementaron un sistema de monitoreo personal haciendo uso del clasificador Haar Cascade, histograma de gradientes orientados y EigenFace. El proceso de entrenamiento se realizó con 30, 60, 90 y 120 imágenes por persona, alcanzando precisiones de 64%, 85%, 97% y 98% respectivamente.

A partir de métricas de distancias y ángulos aplicadas a diversas características propias faciales, en [29] confrontaron el clasificador Haar Cascade con la técnica de puntos de referencia faciales. El sistema de identificación de rostros suministró precisiones de 60% con el clasificador Haar Cascade y 85% con la técnica de puntos de referencia faciales. Los autores en [17] propusieron un algoritmo con el propósito de mejorar el desempeño por parte del clasificador Haar Cascade en el reconocimiento de rostros aplicado en sistemas de seguridad; el conjunto de datos a partir del cual se presentaron los rostros a los clasificadores arrojó una precisión del 96,3 % con una velocidad de reconocimiento de 8,2 segundos, mejorando la precisión de reconocimiento en un 3,4% con respecto a otros algoritmos como Eigenface, el reconocedor LBPH y una red neuronal artificial.

Otra investigación con enfoque a sistemas de seguridad fue la realizada por [19]. El clasificador Haar Cascade se implementó con la librería OpenCV en una tarjeta Raspberry Pi. Por medio de una Pi Camera se realizó la adquisición visual de los rostros con un ángulo entre ± 40 grados y a una distancia entre 0.4 metros y 1.2 metros. La precisión del sistema de identificación de rostros se ubicó entre 4% y 56%. Similar al trabajo anterior, aunque direccionado al área biométrica, en [16] implementaron un clasificador Haar Cascade con funciones provistas por la librería OpenCV y haciendo uso de un conjunto de 180 imágenes adquiridas mediante la cámara de un teléfono móvil. Debido a la presencia de sombras y rostros alargados en las imágenes, la precisión promedio del sistema de reconocimiento fue 95.16%.

En [30] propusieron un sistema de control de silla de ruedas para personas con discapacidad a partir de la orientación de la cabeza. El sistema de detección se basó en identificar el rostro y la nariz de la persona haciendo uso del clasificador Haar Cascade y la orientación mediante un algoritmo de seguimiento realizado con el filtro de correlación por kernel, suministrando una precisión de 82%. A partir del clasificador Haar Cascade aplicado en el reconocimiento de los ojos y la nariz en un rostro, los autores en [31] propusieron un método para mejorar la estabilidad en el proceso de grabación de vídeo. Los resultados indicaron que el tiempo promedio de procesamiento requerido en la detección de los ojos fue 27.72 milisegundos, mientras que para la detección de la nariz fue 61.2 milisegundos.

3 MÉTODO PROPUESTO

3.1 Clasificador Haar Cascade

El algoritmo Haar Cascade propuesto por P. Viola and M. Jones [9], [10], es una técnica de aprendizaje automático comúnmente utilizada en procesos de detección de rostros humanos en imágenes [25] a partir de características relevantes del rostro como pueden ser los labios, nariz, cejas y ojos [17], tal como se observa en la Fig. 1. Con el objeto de llevar a cabo el proceso de detección, el algoritmo requiere varias fotos positivas y negativas [18].

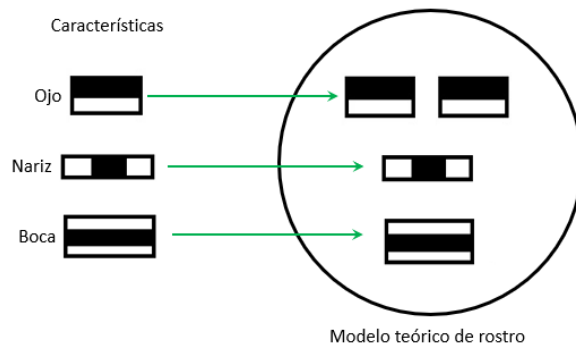


Fig. 1. Clasificador Haar Cascade

Esta técnica ofrece computación de alta velocidad según la cantidad de píxeles dentro de la característica del rectángulo y no según el valor de cada píxel de la imagen [23], e implementa una función en cascada para realizar el entrenamiento de imágenes a partir de cuatro etapas: selección de características de Haar, obtención de una imagen integral, entrenamiento AdaBoost y clasificadores en cascada [1], [18], [25]. Cada característica es un valor individual, que se adquiere restando la suma de píxeles en el rectángulo blanco de la suma de píxeles en el rectángulo negro. La característica similar a Haar de cualquier tamaño se puede calcular en tiempo constante debido a las imágenes integrales [15], [16].

3.2 Clasificador Histograma de Patrones Binarios Locales (LBPH)

Este clasificador apareció originalmente como un descriptor de textura. El operador asigna una etiqueta a cada valor de píxel de la imagen en un vecindario de 3 x 3 con un valor establecido en el píxel central. El algoritmo provee como resultado un valor binario representativo [32]. La capacidad de discriminación y simplicidad del clasificador LBPH permite que pueda ser utilizado en diversas aplicaciones [33]. Dos de las características que sobresalen de este clasificador son su desempeño en aplicaciones con imágenes que presentan variaciones de iluminación y su simplicidad computacional, lo cual posibilita procesar imágenes con entornos complejos en tiempo real [34].

Respecto al reconocimiento de rostros, el clasificador LBPH extrae características particionando la imagen del rostro en regiones locales y luego las confronta con las demás imágenes de rostros, por ejemplo, con aquellas que hacen parte de una base de datos. De cada región se extrae el descriptor de textura, posteriormente los descriptores se concatenan para formar una descripción global del rostro [35]. El clasificador asigna etiquetas a cada uno de los píxeles de la imagen tomando en cuenta la distribución de los vecinos [36].

El proceso de reconocimiento con este clasificador requiere de una máscara que recorre la imagen de manera iterativa seleccionando cada vez un píxel central y sus vecinos. El píxel central se confronta con cada uno de sus vecinos de forma ordenada. Si el píxel central es mayor que el píxel con el que se confronta se asigna como etiqueta un cero, en caso contrario se asigna como etiqueta un uno. El número binario resultante se convierte en un número decimal que es contado en el histograma para formar la descripción. El histograma de las etiquetas de todos los píxeles es posteriormente utilizado como una descripción de la textura de la imagen [37].

3.3 Clasificador EigenFace (EF)

Este clasificador se basa en el método de la distancia euclidiana para calcular la distancia entre el EigenVector (vector propio) y el EigenFace (rostro propio) [32]. Estos vectores propios [38] se pueden considerar como un conjunto de elementos que caracterizan la variación entre las imágenes de rostros. Cada ubicación de los elementos en la imagen del rostro como pueden ser los labios, nariz, cejas y ojos contribuye a cada vector propio, de modo que es posible mostrar el vector propio como una especie de rostro fantasmal llamado rostro propio o "eigenface" [5].

La estrategia del método EigenFace consiste en extraer las características del rostro y representar el rostro en cuestión como una combinación lineal de los denominados rostros propios. Se tienen en cuenta por tanto los elementos principales de los rostros en el proceso de entrenamiento. El reconocimiento se logra mediante la proyección del rostro en el espacio formado por los rostros propios. Se realiza una comparación sobre la base de la distancia euclidiana de los vectores propios de los rostros propios y el rostro propio de la imagen analizada [39]. Si la distancia es pequeña, se

identifica a la persona, mientras que una distancia demasiado grande indica que el modelo requiere mayor entrenamiento para realizar una correcta identificación [32].

3.4 Clasificador FisherFace (FF)

Este clasificador es una versión modificada del clasificador EigenFace. Mediante éste se determina el rostro promedio por clase [32]. Las características principales de este clasificador son su capacidad tanto para interpolar y extrapolar sobre la iluminación como la identificación con variaciones en expresiones faciales [36].

La base de este clasificador para llevar a cabo el reconocimiento parte de la técnica de análisis discriminante lineal (LDA) [33]. El clasificador realiza un LDA haciendo uso de la información provista de las imágenes de entrenamiento encontrando una proyección que maximiza la separación entre imágenes de distintas personas (clases) y minimiza la distancia entre imágenes de una misma clase, permitiendo que exista un mejor desempeño en el proceso de reconocimiento [37].

3.5 Procedimiento desarrollado

El sistema de reconocimiento propuesto tuvo como estrategia crear procesos de recolección, entrenamiento y reconocimiento de rostros. Para tal propósito se desarrollaron tres códigos computacionales asociados a cada etapa haciendo uso del lenguaje de programación Python y la librería OpenCV. La Fig. 2 detalla el diagrama de bloques del sistema propuesto de reconocimiento de rostros.



Fig. 2. Diagrama de bloques del sistema de reconocimiento de rostros propuesto

El procedimiento partió de la recolección de imágenes de rostros de seis personas sin tapabocas y con tapabocas. Este proceso de recolección se realizó a partir de la toma de videos haciendo uso de una cámara de celular con resolución 1080p a una tasa de muestreo de 30 cuadros por segundo. Un primer código computacional empleando el clasificador Haar Cascade permitió obtener dos conjuntos de imágenes de rostros frontales por persona, para un total de 350 imágenes sin tapabocas y 350 imágenes con tapabocas, con una resolución espacial de 150 x 150 píxeles. La Fig. 3 muestra ejemplos de estas imágenes de rostros.



Fig. 3. Ejemplos de rostros con ausencia y presencia de tapabocas

La técnica Haar Cascade requirió etiquetar por persona las imágenes con el fin de discriminar un rostro de otro y si este posee o no tapabocas. El conjunto de imágenes, por tanto, se almacenó en carpetas etiquetándolas como I1ST a I6ST para las personas de 1 a 6 con rostros sin tapabocas y I1CT a I6CT para las personas de 1 a 6 con rostros con tapabocas. Una vez ajustado el banco de imágenes, se creó un código computacional con el objeto de llevar a cabo el proceso de entrenamiento haciendo uso de los métodos Histograma de Patrones Binarios Locales (LBPH), EigenFace (EF) y FisherFace (FF). Finalizado el entrenamiento se obtuvo un archivo XML por cada método con el modelo entrenado.

Finalmente, se desarrolló un código computacional con el objeto de evaluar el desempeño de cada modelo para llevar a cabo el reconocimiento. Este proceso requirió de imágenes diferentes a aquellas utilizadas en el proceso de entrenamiento, estas imágenes corresponden a las seis personas con ausencia y presencia de tapabocas y a una persona diferente etiquetada como ID. Las imágenes se obtuvieron a partir de la fragmentación de videos de corta y aleatoria duración adquiridos con una cámara de celular con resolución 1080p a una tasa de muestreo de 30 cuadros por segundo, por tanto, existe por clase, diversidad en la cantidad de imágenes de prueba utilizadas en el proceso de evaluación, tal como se observa en la Tabla 1.

TABLA 1. NÚMERO DE IMÁGENES UTILIZADAS EN EL PROCESO DE EVALUACIÓN DEL DESEMPEÑO DE LOS CLASIFICADORES

I1ST	I2ST	I3ST	I4ST	I5ST	I6ST	I1CT	I2CT	I3CT	I4CT	I5CT	I6CT	ID
300	329	374	320	486	623	354	317	339	339	531	147	671

4 RESULTADOS

Los algoritmos de entrenamiento y reconocimiento de rostros se ejecutaron en un equipo de cómputo con procesador Intel Core i7-5557U a 3.10 GHz y memoria RAM de 16 GB. El tiempo que demandó el entrenamiento, así como el tamaño del modelo en formato XML provisto por cada método están indicados en la Tabla 2.

TABLA 2. CARACTERÍSTICAS DE LOS MODELOS OBTENIDOS EN EL PROCESO DE ENTRENAMIENTO

	LBPH	EF	FF
Tiempo de entrenamiento (s)	9.5464	7596.7633	9287.6451
Tamaño (KB)	503749	2975232	8898

Se observa en la Tabla 2 que no es requerido un tiempo relevante para llevar a cabo el entrenamiento haciendo uso del método LBPH, lo cual difiere con los métodos EF y FF. Sin embargo, el modelo obtenido con el método LBPH tiene un tamaño considerable que puede generar inconvenientes en su portabilidad, lo mismo sucede con el modelo provisto por el método EF. Una vez obtenidos los modelos, estos se evaluaron en cada una de las imágenes de prueba. La Tabla 3 indica, por clase, los tiempos de carga del modelo para ser utilizado por el algoritmo de reconocimiento, así como los tiempos mínimo, máximo y promedio que demandó cada método en proveer una respuesta ante cada imagen de prueba.

TABLA 3. TIEMPOS DE PROCESAMIENTO REQUERIDOS POR EL ALGORITMO DE RECONOCIMIENTO

Clase	Tiempo de carga (s)			Tiempo mínimo (s)			Tiempo máximo (s)			Tiempo promedio (s)		
	LBPH	EF	FF	LBPH	EF	FF	LBPH	EF	FF	LBPH	EF	FF
I1ST	22.2331	68.9901	0.2031	0.2437	0.2152	0.0001	0.3437	0.3125	0.0156	0.2623	0.2456	0.0021
I2ST	19.0194	69.0278	0.2031	0.2385	0.2031	0.0001	0.4375	0.2969	0.0156	0.2603	0.2232	0.0015
I3ST	18.9729	70.3777	0.2187	0.2344	0.2031	0.0001	0.3437	0.2969	0.0156	0.2586	0.2215	0.0020
I4ST	19.0554	68.8959	0.2069	0.2642	0.2031	0.0001	0.3750	0.3124	0.0156	0.2769	0.2216	0.0022
I5ST	18.9751	68.7833	0.2031	0.2508	0.2031	0.0001	0.3098	0.2969	0.0156	0.2580	0.2198	0.0022
I6ST	18.9586	68.6842	0.2228	0.2656	0.2031	0.0001	0.3594	0.2969	0.0177	0.2814	0.2220	0.0020
I1CT	19.0784	74.4985	0.2031	0.2494	0.2131	0.0001	0.3594	0.3159	0.0156	0.2627	0.2297	0.0025
I2CT	19.9289	73.2304	0.2187	0.2344	0.2031	0.0001	0.4062	0.2969	0.0156	0.2602	0.2210	0.0014
I3CT	21.5480	68.8995	0.2031	0.2436	0.2154	0.0001	0.3750	0.2968	0.0156	0.2632	0.2252	0.0020
I4CT	18.9724	68.9788	0.2031	0.2812	0.2083	0.0001	0.3593	0.2812	0.0156	0.2944	0.2225	0.0023
I5CT	18.8667	70.1139	0.2031	0.2500	0.2187	0.0001	0.4218	0.3125	0.0156	0.2731	0.2257	0.0021
I6CT	19.8148	68.7054	0.2210	0.2656	0.2031	0.0001	0.3750	0.2969	0.0156	0.2846	0.2210	0.0019
ID	21.5636	69.8389	0.2031	0.2656	0.2031	0.0001	0.3906	0.2812	0.0156	0.2938	0.2235	0.0017

Se observa en la Tabla 3 que el método FF demandó menores tiempos tanto de carga del modelo como de ejecución, aunque esto no es indicativo de un mejor desempeño por parte de este método en el proceso de reconocimiento. Comparando los métodos LBPH y EF se visualiza que el método LBPH provee un menor tiempo de carga del modelo en todas las clases, sin embargo, este método requiere mayor tiempo en suministrar una respuesta ante cada clase evaluada.

Con el objeto de determinar el desempeño de cada modelo en el proceso de reconocimiento, inicialmente se realiza para cada método una clasificación multiclase en una matriz de confusión, la cual es una herramienta utilizada para resolver problemas de clasificación evaluando un algoritmo o comparando el desempeño de diferentes algoritmos [40]. Las matrices de confusión multiclase hacen uso de conjuntos de Verdaderos Positivos que indican la cantidad de ejemplos positivos clasificados con precisión, Falsos Positivos que corresponden al número de ejemplos negativos reales clasificados como positivos, y Falsos Negativos relacionados al número de ejemplos positivos reales clasificados como negativos [41]. Por tanto, se definieron los conjuntos de Verdaderos Positivos los cuales corresponden a aquellas imágenes de cada rostro evaluado que son correctamente identificadas, Falsos Positivos asociados a imágenes de rostros que el algoritmo predice erróneamente como correctamente identificadas y Falsos Negativos relacionados a imágenes de cada rostro evaluado que son erróneamente identificadas. Las Fig. 4, 5 y 6 muestran la matriz de confusión obtenida a partir de los métodos LBPH, EF y FF, respectivamente.

Matriz de confusión: método LBPH

Actual \ Predicción	11ST	12ST	13ST	14ST	15ST	16ST	11CT	12CT	13CT	14CT	15CT	16CT	ID
11ST	300	0	0	0	0	0	0	0	0	0	0	0	0
12ST	0	329	0	0	0	0	0	0	0	0	0	0	0
13ST	0	1	370	0	0	0	0	0	1	0	0	0	2
14ST	0	0	0	320	0	0	0	0	0	0	0	0	0
15ST	6	0	0	0	450	0	0	0	0	0	0	0	30
16ST	0	0	0	0	0	623	0	0	0	0	0	0	0
11CT	0	0	0	0	2	0	352	0	0	0	0	0	0
12CT	0	0	0	0	1	0	0	301	0	0	0	0	15
13CT	0	0	0	0	0	0	0	0	339	0	0	0	0
14CT	0	0	0	0	0	0	0	0	0	339	0	0	0
15CT	0	0	0	0	17	0	0	0	0	80	409	0	25
16CT	0	0	0	0	0	0	0	0	0	0	0	147	0
ID	0	0	0	0	0	0	0	0	0	0	0	0	671

Fig. 4. Matriz de confusión obtenida con el método LBPH

Matriz de confusión: método EigenFace

Actual \ Predicción	11ST	12ST	13ST	14ST	15ST	16ST	11CT	12CT	13CT	14CT	15CT	16CT	ID
11ST	300	0	0	0	0	0	0	0	0	0	0	0	0
12ST	0	329	0	0	0	0	0	0	0	0	0	0	0
13ST	0	0	370	0	2	0	1	0	0	1	0	0	0
14ST	0	0	0	320	0	0	0	0	0	0	0	0	0
15ST	0	0	0	1	264	0	0	0	0	19	160	0	42
16ST	0	0	0	0	0	623	0	0	0	0	0	0	0
11CT	2	0	0	0	0	0	352	0	0	0	0	0	0
12CT	0	0	1	0	3	0	0	295	0	0	0	0	18
13CT	0	0	0	0	0	0	0	0	331	0	0	0	8
14CT	0	0	0	0	0	0	0	0	0	339	0	0	0
15CT	0	0	0	0	44	0	13	1	0	1	369	0	103
16CT	0	0	0	0	0	0	0	0	0	0	0	147	0
ID	0	0	0	0	0	0	0	0	0	0	0	0	671

Fig. 5. Matriz de confusión obtenida con el método EF

Matriz de confusión: método FisherFace

Actual \ Predicción	I1ST	I2ST	I3ST	I4ST	I5ST	I6ST	I1CT	I2CT	I3CT	I4CT	I5CT	I6CT	ID
I1ST	146	0	0	1	0	0	0	3	2	88	57	0	3
I2ST	21	256	0	0	2	0	0	2	0	0	0	0	48
I3ST	107	16	210	0	22	1	1	0	7	0	0	0	10
I4ST	1	0	0	316	0	0	0	0	0	2	0	0	1
I5ST	54	15	123	2	201	14	0	0	13	0	51	4	9
I6ST	0	0	0	0	17	434	0	0	12	0	0	1	159
I1CT	0	1	0	8	0	0	302	0	1	11	28	0	3
I2CT	70	13	0	0	1	1	3	166	6	34	21	0	2
I3CT	7	7	11	16	73	6	3	0	68	0	100	0	48
I4CT	7	0	0	26	0	0	3	39	0	250	14	0	0
I5CT	19	26	2	6	20	4	66	5	34	34	192	95	28
I6CT	19	0	0	2	1	15	4	1	0	2	1	80	22
ID	11	0	0	55	0	0	69	2	0	21	4	0	509

Fig. 6. Matriz de confusión obtenida con el método FF

Una vez adecuada la matriz de confusión se evaluó el sistema de reconocimiento a partir de las métricas Precisión, Sensibilidad y F1-Score. Las ecuaciones 1 a 3 establecen las fórmulas matemáticas en la obtención de cada métrica.

$$\text{Precisión} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Positivos}} \quad (1)$$

$$\text{Sensibilidad} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos}} \quad (2)$$

$$\text{F1 - Score} = 2 \times \frac{\text{Precisión} \times \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}} \quad (3)$$

La métrica *Precisión* indica la calidad que el modelo provee en el proceso de reconocimiento de rostros. La *Sensibilidad* indica la cantidad que el modelo es capaz de reconocer rostros. En tanto que la métrica *F1-Score* combina las métricas *Precisión* y *Sensibilidad* en un solo valor. El modelo relacionado al método LBPH suministró una *Precisión* de 96.4912%, mientras que para los métodos EF y FF la *Precisión* fue de 91.8128% y 61.0136% respectivamente. La Tabla 4 indica los valores de las métricas obtenidas por clase con los tres métodos.

TABLA 4. DESEMPEÑO DEL ALGORITMO DE RECONOCIMIENTO

Clase	Precisión (%)			Sensibilidad (%)			F1-Score (%)		
	LBPH	EF	FF	LBPH	EF	FF	LBPH	EF	FF
I1ST	98.0392	99.3377	31.6017	100	100	48.6666	99.0099	99.6677	38.3202
I2ST	99.6969	100	76.6467	100	100	77.8115	99.8482	100	77.2247
I3ST	100	99.7304	60.6936	98.9304	98.9304	56.1497	99.4623	99.3288	58.3333
I4ST	100	99.6884	73.1481	100	100	98.7500	100	99.8439	84.0425
I5ST	95.7446	84.3450	59.6439	92.5925	54.3209	41.3580	94.1422	66.0826	48.8456
I6ST	100	100	91.3684	100	100	69.6629	100	100	79.0528
I1CT	100	96.1748	66.9623	99.4350	99.4350	85.3107	99.7167	97.7777	75.0310
I2CT	100	99.6621	76.1467	94.9526	93.0599	52.3659	97.4110	96.2479	62.0560
I3CT	99.7058	100	47.5524	100	97.6401	20.0589	99.8527	98.8059	28.2157
I4CT	80.9069	94.1666	56.5610	100	100	73.7463	89.4459	96.9957	64.0204
I5CT	100	69.7542	41.0256	77.0244	69.4915	36.1581	87.0212	69.6226	38.4384
I6CT	100	100	44.4444	100	100	54.4217	100	100	48.9296
ID	90.3095	79.6912	60.4513	100	100	75.8569	94.9080	88.6979	67.2835

Realizando una comparación en las 13 clases, se observa que el modelo asociado al método LBPH provee siete valores más altos de *Precisión* en relación con cuatro suministrados por el método EF y ninguno por el método FF. En el reconocimiento del rostro de la persona 6 sin y con tapabocas los métodos LBPH y EF dan como resultado el máximo valor de *Precisión*. Respecto a la *Sensibilidad*, el método LBPH provee cuatro valores más altos y nueve en conjunto con el método EF. La métrica F1-Score indica que existen ocho valores más altos con el modelo relacionado al método LBPH, tres con el modelo asociado al método EF y dos en conjunto.

Comparando el desempeño de los modelos en el proceso de reconocimiento de rostros sin tapabocas, el método LBPH provee tres valores más altos de *Precisión* en relación con dos suministrados por el método EF y uno en conjunto. Respecto a la *Sensibilidad*, el método LBPH provee un valor más alto y cinco en conjunto con el método EF. La métrica F1-Score indica que existen tres valores más altos con el modelo relacionado al método LBPH, dos con el modelo asociado al método EF y uno en conjunto.

Con relación al desempeño de los modelos en el proceso de reconocimiento de rostros con tapabocas, el método LBPH provee tres valores más altos de *Precisión* con respecto a los dos suministrados por el método EF y uno en conjunto. Respecto a la *Sensibilidad*, el método LBPH provee tres valores más altos y tres en conjunto con el método EF. La métrica F1-Score indica que existen cuatro valores más altos con el modelo relacionado al método LBPH, uno con el modelo asociado al método EF y uno en conjunto.

4.1 Discusión

El método LBPH provee el mejor desempeño en el reconocimiento de personas sin y con tapabocas, la *Precisión* de este modelo se ubica entre 95.7466% y 100% para reconocer personas sin tapabocas que hacen parte de la base de datos y en el rango de 80.9069% a 100% en el reconocimiento de personas con tapabocas. La *Sensibilidad* del modelo se ubica entre 92.5925% y 100% en rostros sin tapabocas y 77.0244% a 100% en rostros con tapabocas. Mientras que la métrica F1-Score se ubica entre 94.1422% y 100% en rostros sin tapabocas y 87.0212% a 100% en rostros con tapabocas. El método FF, aunque demanda menor tiempo en ejecutarse provee el peor desempeño.

En contraste con otros trabajos, esta investigación provee información de desempeño en el reconocimiento de rostros con tapabocas haciendo uso de los métodos LBPH, EF y FF. Varios autores han reportado resultados similares para llevar a cabo el reconocimiento de rostros sin tapabocas. Tal es el caso de los trabajos en [34], [35] quienes determinaron que el método LBPH suministró mejores resultados. Bajo esta premisa, la investigación en [33] indica *Precisiones* en el reconocimiento de rostros entre 92% y 100% haciendo uso de este método. Por otro lado, otros trabajos como el presentado en [37] detalla mejor desempeño con el método EF, aunque igual a esta investigación determinaron que el método FF presenta el peor resultado.

5 CONCLUSIONES

El clasificador Haar Cascade es una técnica ampliamente utilizada en los procesos de detección de rostros debido a su capacidad para caracterizar elementos faciales como labios, nariz, cejas y ojos con alta *precisión* y *velocidad* de cómputo. En este trabajo, se utilizó este clasificador para realizar el recorte de rostros en cada imagen adquirida de una muestra de seis personas, tanto con cómo sin tapabocas. A partir de esta recolección de imágenes, fue posible evaluar el desempeño de los clasificadores LBPH, EigenFace y FisherFace en el proceso de reconocimiento facial.

Los resultados obtenidos indican que, bajo el clasificador LBPH, es posible tener un sistema de reconocimiento aceptable que no solo identifica a una persona, sino que también detecta si la persona está usando o no un tapabocas. Dado que los tiempos computacionales requeridos por el clasificador LBPH para el procesamiento del algoritmo de reconocimiento se encuentran en torno a 0.25 segundos, existe la posibilidad de adaptar un sistema en tiempo real para aplicaciones en reconocimiento facial diferenciado, como en procesos de control de acceso de personal.

Es importante destacar que el proceso de recolección de imágenes de rostros con tapabocas presenta diversas limitaciones para el clasificador Haar Cascade. Estas limitaciones incluyen condiciones de baja luminosidad, fondos no uniformes, tipo de luz incidente sobre el rostro con tapabocas y el uso de tapabocas de colores oscuros, lo que impide generar un banco de imágenes de forma autónoma. Por tanto, el desarrollo de un sistema de reconocimiento de rostros con tapabocas en diversos ambientes (abiertos o cerrados) bajo estas condiciones no es una tarea sencilla.

La matriz de confusión es una forma estándar y muy usual de informar sobre el grado de veracidad de las clases derivadas de un banco de imágenes, lo que garantiza su utilización y un análisis robusto de los resultados de la detección

de rostros con tapabocas.

Futuros trabajos podrían involucrar la aplicación de la metodología propuesta en este estudio a una muestra mayor, la proposición de otra metodología de reconocimiento de rostros basada en redes neuronales convolucionales para comparar el desempeño de diferentes modelos de reconocimiento facial, o la unificación de diversos métodos en circuitos embebidos de alto rendimiento para desarrollar un sistema de reconocimiento más robusto, con la capacidad de aislar el tapabocas del rostro independientemente de sus características.

AGRADECIMIENTOS

Los autores expresan sus agradecimientos a la Institución Universitaria Pascual Bravo por el apoyo brindado en la consecución de este trabajo investigativo.

REFERENCIAS

- [1] S. O. Adeshina, H. Ibrahim, S. S. Teoh, y S. C. Hoo, «Custom Face Classification Model for Classroom Using Haar-Like and LBP Features with Their Performance Comparisons», *Electronics*, vol. 10, n.º 2, p. 102, ene. 2021, doi: <https://doi.org/10.3390/electronics10020102>
- [2] P. A. Riyantoko, Sugiarto, y K. M. Hindrayani, «Facial Emotion Detection Using Haar-Cascade Classifier and Convolutional Neural Networks», *J. Phys. Conf. Ser.*, vol. 1844, n.º 1, p. 012004, mar. 2021, doi: <https://doi.org/10.1088/1742-6596/1844/1/012004>.
- [3] C. A. Amaya Corredor, C. H. Contreras, N. Pedroza Rosas, y R. S. Cáceres Quintero, «Estrategias de adaptación y mitigación al cambio climático de las Unidades Tecnológicas de Santander», *Rev. CINTEX*, vol. 22, n.º 2, pp. 89-109, dic. 2017, doi: <https://doi.org/10.33131/24222208.301>.
- [4] A. Uribe Churta, «Desarrollo de un sistema de reconocimiento del estado de los cultivos de café en tiempo real usando redes neuronales artificiales», *Rev. CINTEX*, vol. 25, n.º 2, pp. 37-44, dic. 2020, doi: <https://doi.org/10.33131/24222208.362>.
- [5] M. Turk y A. Pentland, «Eigenfaces for Recognition», *J. Cogn. Neurosci.*, vol. 3, n.º 1, pp. 71-86, ene. 1991, doi: <https://doi.org/10.1162/jocn.1991.3.1.71>.
- [6] B. Moghaddam y A. Pentland, «Probabilistic visual learning for object representation», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 19, n.º 7, pp. 696-710, jul. 1997, doi: <https://doi.org/10.1109/34.598227>.
- [7] E. Osuna, R. Freund, y F. Girosit, «Training support vector machines: an application to face detection», en *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Juan, Puerto Rico, 1997, pp. 130-136. doi: <https://doi.org/10.1109/CVPR.1997.609310>.
- [8] M.-H. Yang, D. Roth, y N. Ahuja, «A SNoW-Based Face Detector», en *Advances in Neural Information Processing Systems*, 1999, vol. 12. [En línea]. Disponible en: <https://proceedings.neurips.cc/paper/1999/file/3e15cc11f979ed25912dff5b0669f2cd-Paper.pdf>
- [9] P. Viola y M. Jones, «Rapid object detection using a boosted cascade of simple features», en *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, Kauai, HI, USA, 2001, vol. 1, p. I-511-I-518. doi: <https://doi.org/10.1109/CVPR.2001.990517>.
- [10] P. Viola y M. J. Jones, «Robust Real-Time Face Detection», *Int. J. Comput. Vis.*, vol. 57, n.º 2, pp. 137-154, may 2004, doi: <https://doi.org/10.1023/B:VISI.0000013087.49260.fb>.
- [11] T. F. Cootes, K. Walker, y C. J. Taylor, «View-based active appearance models», en *Proceedings Fourth IEEE International Conference on Automatic Face and Gesture Recognition (Cat. No. PR00580)*, Grenoble, France, 2000, pp. 227-232. doi: <https://doi.org/10.1109/AFGR.2000.840639>.
- [12] Q. Yin, X. Tang, y J. Sun, «An associate-predict model for face recognition», en *CVPR 2011*, Colorado Springs, CO, USA, jun. 2011, pp. 497-504. doi: <https://doi.org/10.1109/CVPR.2011.5995494>.
- [13] V. Blanz y T. Vetter, «A morphable model for the synthesis of 3D faces», en *Proceedings of the 26th annual conference on Computer graphics and interactive techniques - SIGGRAPH '99*, Not Known, 1999, pp. 187-194. doi: <https://doi.org/10.1145/311535.311556>.

- [14] K.-K. Sung y T. Poggio, «Example-based learning for view-based human face detection», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 20, n.º 1, pp. 39-51, ene. 1998, doi: <https://doi.org/10.1109/34.655648>.
- [15] A. B. Shetty, Bhoomika, Deeksha, J. Rebeiro, y Ramyashree, «Facial recognition using Haar cascade and LBP classifiers», *Glob. Transit. Proc.*, vol. 2, n.º 2, pp. 330-335, nov. 2021, doi: 10.1016/j.gltp.2021.08.044.
- [16] S. Pal, «Human Face Detection Technique using Haar-like Features», *Int. J. Comput. Appl.*, vol. 175, n.º 32, pp. 56-60, nov. 2020, doi: <https://doi.org/10.5120/ijca2020920883>.
- [17] I. Gangopadhyay, A. Chatterjee, y I. Das, «Face Detection and Expression Recognition Using Haar Cascade Classifier and Fisherface Algorithm», en *Recent Trends in Signal and Image Processing*, vol. 922, S. Bhattacharyya, S. K. Pal, I. Pan, y A. Das, Eds. Singapore: Springer Singapore, 2019, pp. 1-11. doi: https://doi.org/10.1007/978-981-13-6783-0_1.
- [18] F. M. Javed Mehedi Shamrat, A. Majumder, P. R. Antu, S. K. Barmon, I. Nowrin, y R. Ranjan, «Human Face Recognition Applying Haar Cascade Classifier», en *Pervasive Computing and Social Networking*, vol. 317, G. Ranganathan, R. Bestak, R. Palanisamy, y Á. Rocha, Eds. Singapore: Springer Nature Singapore, 2022, pp. 143-157. doi: https://doi.org/10.1007/978-981-16-5640-8_12.
- [19] A. H. Ahmad *et al.*, «Real time face recognition of video surveillance system using haar cascade classifier», *Indones. J. Electr. Eng. Comput. Sci.*, vol. 21, n.º 3, p. 1389, mar. 2021, doi: <https://doi.org/10.11591/ijeecs.v21.i3.pp1389-1399>.
- [20] J. J. Castro-Maldonado, J. A. Patiño-Murillo, A. E. Florian-Villa, y O. E. Guadrón-Guerrero, «Application of computer vision and low-cost artificial intelligence for the identification of phytopathogenic factors in the agro-industry sector», *J. Phys. Conf. Ser.*, vol. 1126, p. 012022, nov. 2018, doi: <https://doi.org/10.1088/1742-6596/1126/1/012022>.
- [21] Z. Abal Abas *et al.*, «The implementation of personal monitoring system using Histogram of Gradient, Haar classifier and eigenfaces for human detection and recognition», *ARPN J Eng Appl Sci*, vol. 10, n.º 19, pp. 8799-8806, 2015.
- [22] B. G. Amira, M. M. Zoulikha, y P. Hector, «Driver Drowsiness Detection and Tracking Based on Yolo with Haar Cascades and ERNN», *Int. J. Saf. Secur. Eng.*, vol. 11, n.º 1, pp. 35-42, feb. 2021, doi: <https://doi.org/10.18280/ijss.110104>.
- [23] N. Kamarudin *et al.*, «Implementation of Haar Cascade Classifier and Eye Aspect Ratio for Driver Drowsiness Detection Using Raspberry Pi», *Univers. J. Electr. Electron. Eng.*, vol. 6, n.º 5B, pp. 67-75, dic. 2019, doi: <https://doi.org/10.13189/ujeee.2019.061609>.
- [24] C. Adarve Gómez, D. A. Castillo Carvajal, E. J. Restrepo Zapata, y H. Villar-Vega, «A review of virtual reality videogames for job-training applications», *Rev. CINTEX*, vol. 24, n.º 1, pp. 64-70, dic. 2019, doi: <https://doi.org/10.33131/24222208.346>.
- [25] R. Rizal Isnanto, A. Rochim, D. Eridani, y G. Cahyono, «Multi-Object Face Recognition Using Local Binary Pattern Histogram and Haar Cascade Classifier on Low-Resolution Images», *Int. J. Eng. Technol. Innov.*, vol. 11, n.º 1, pp. 45-58, ene. 2021, doi: <https://doi.org/10.46604/ijeti.2021.6174>.
- [26] V. Ravuri, S. Vasundra, S. Ramasubbareddy, y K. Govinda, «Face Recognition using Cascade Algorithm», *Int. J. Recent Technol. Eng.*, vol. 8, n.º 2S4, pp. 599-602, ago. 2019, doi: <https://doi.org/10.35940/ijrte.B1118.0782S419>.
- [27] School of Information Technology and Engineering, Vellore Institute of Technology, Vellore, Tamil Nadu, India, R. Shukla*, A. L. School of Information Technology and Engineering, Vellore Institute of Technology, Vellore, Tamil Nadu, India, P. M, y School of Information Technology and Engineering, Vellore Institute of Technology, Vellore, Tamil Nadu, India, «Facial Emotion Recognition by Deep CNN and HAAR Cascade», *Int. J. Innov. Technol. Explor. Eng.*, vol. 8, n.º 12, pp. 3433-3439, oct. 2019, doi: <https://doi.org/10.35940/ijitee.L2589.1081219>.
- [28] M. Maria Dominic Savio, T. Deepa, A. Bonasu, y T. S. Anurag, «Image Processing For Face Recognition Using HAAR, HOG, and SVM Algorithms», *J. Phys. Conf. Ser.*, vol. 1964, n.º 6, p. 062023, jul. 2021, doi: <https://doi.org/10.1088/1742-6596/1964/6/062023>.
- [29] N. Ibrahim, «Haar Cascade Vs Facial Landmarks Technique for Face Recognition Uniqueness», *Int. J. Adv. Trends Comput. Sci. Eng.*, vol. 8, n.º 1.6, pp. 525-530, dic. 2019, doi: <https://doi.org/10.30534/ijatcse/2019/7781.62019>.

- [30] F. Utaminingrum, Y. A. Sari, P. P. Adikara, D. Syauqy, y S. Adinugroho, «Hybrid Head Tracking for Wheelchair Control Using Haar Cascade Classifier and KCF Tracker», *TELKOMNIKA Telecommun. Comput. Electron. Control*, vol. 16, n.º 4, p. 1616, feb. 2018, doi: <https://doi.org/10.12928/telkomnika.v16i4.6595>.
- [31] R. Raj *et al.*, «Feature based video stabilization based on boosted HAAR Cascade and representative point matching algorithm», *Image Vis. Comput.*, vol. 101, p. 103957, sep. 2020, doi: <https://doi.org/10.1016/j.imavis.2020.103957>.
- [32] M. M. Ahsan, Y. Li, J. Zhang, M. T. Ahad, y K. D. Gupta, «Evaluating the Performance of Eigenface, Fisherface, and Local Binary Pattern Histogram-Based Facial Recognition Methods under Various Weather Conditions», *Technologies*, vol. 9, n.º 2, p. 31, abr. 2021, doi: <https://doi.org/10.3390/technologies9020031>.
- [33] A. M. Jagtap, V. Kangale, K. Unune, y P. Gosavi, «A Study of LBPH, Eigenface, Fisherface and Haar-like features for Face recognition using OpenCV», en *2019 International Conference on Intelligent Sustainable Systems (ICISS)*, Palladam, Tamilnadu, India, feb. 2019, pp. 219-224. doi: <https://doi.org/10.1109/ISS1.2019.8907965>.
- [34] D. Verdeguer Valderrama y N. Campos Vasquez, «Diseño E Implementación De Un Sistema De Identificación De Personas Para La Seguridad De Los Accesos A Condominios, Basado En El Algoritmo De Reconocimiento Facial LBPH Faces», en *Proceedings of the 19th LACCEI International Multi-Conference for Engineering, Education, and Technology: "Prospective and trends in technology and skills for sustainable social development" "Leveraging emerging technologies to construct the future"*, 2021. doi: <https://doi.org/10.18687/LACCEI2021.1.1.213>.
- [35] J. Paul *et al.*, «Evaluation of Face Recognition Schemes for Low-computation IoT System Design», en *2020 24th International Symposium on VLSI Design and Test (VDATE)*, Bhubaneswar, India, jul. 2020, pp. 1-6. doi: <https://doi.org/10.1109/VDATE50263.2020.9190569>.
- [36] M. Munlin, «Time Attendance Using FELE Face Identification Algorithms», en *2022 9th International Conference on Electrical and Electronics Engineering (ICEEE)*, Alanya, Turkey, mar. 2022, pp. 325-329. doi: <https://doi.org/10.1109/ICEEE55327.2022.9772596>.
- [37] C. H. Esparza Franco, C. Tarazona Ospina, E. E. Sanabria Cuevas, y D. A. Velazco Capacho, «RECONOCIMIENTO FACIAL BASADO EN EIGENFACES, LBPH Y FISHERFACES EN LA BEAGLEBOARD-xM», *Rev. Colomb. Tecnol. Av. RCTA*, vol. 2, n.º 26, pp. 145-152, ene. 2021, doi: <https://doi.org/10.24054/16927257.v26.n26.2015.395>.
- [38] C. A. Ramírez Gómez, «Aplicación del Machine Learning en agricultura de precisión», *Rev. CINTEX*, vol. 25, n.º 2, pp. 14-27, dic. 2020, doi: <https://doi.org/10.33131/24222208.356>.
- [39] M. üge Çarıkçı y F. Özen, «A Face Recognition System Based on Eigenfaces Method», *Procedia Technol.*, vol. 1, pp. 118-123, 2012, doi: <https://doi.org/10.1016/j.protcy.2012.02.023>.
- [40] I. Markoulidakis, I. Rallis, I. Georgoulas, G. Kopsiaftis, A. Doulamis, y N. Doulamis, «Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem», *Technologies*, vol. 9, n.º 4, p. 81, nov. 2021, doi: <https://doi.org/10.3390/technologies9040081>.
- [41] A. Kulkarni, D. Chong, y F. A. Batarseh, «Foundations of data imbalance and solutions for a data democracy», en *Data Democracy*, Elsevier, 2020, pp. 83-106. doi: <https://doi.org/10.1016/B978-0-12-818366-3.00005-8>.