

Evaluación de un prototipo de visión artificial para reconocimiento facial

Evaluation of a Computer Vision Prototype for Facial Recognition

José Luis Carvajal ¹

jose.carvajal@pucese.edu.ec

¹Universidad Nacional de Educación a Distancia (UNED), Madrid, España, 28015

¹Pontificia Universidad Católica del Ecuador Sede Esmeraldas, Esmeraldas, Ecuador, 08010065

Citación: Carvajal, J. L. (2026). Evaluation of a Computer Vision Prototype for Facial Recognition. *EKSIGMA*, 2(2), 51-63. <https://eksigma.com/index.php/principal/article/view/28>

Recibido: 03 de marzo 2026

Aceptado: 20 de abril 2026

Publicado: 15 de mayo 2026

EKSIGMA

ISSN: 3121-2689

Correspondencia:

jose.carvajal@pucese.edu.ec



Copyright © 2026. Los autores conservan los derechos de autor y los derechos de publicación. Asimismo, otorgan a EKSIGMA el derecho no exclusivo de primera publicación. Este es un artículo de acceso abierto distribuido bajo los términos de la licencia Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0). <https://creativecommons.org/licenses/by-nc/4.0/>

Resumen: El reconocimiento facial continúa siendo un problema relevante de visión por computador, especialmente cuando la iluminación, la postura, la oclusión y el número de personas cambian. El estudio evaluó un prototipo desarrollado en MATLAB con Computer Vision Toolbox para detectar rostros y componentes faciales, almacenar plantillas y reconocer identidades mediante correlación de imágenes binarias. Se aplicó un enfoque cuantitativo, aplicado y descriptivo sobre tres conjuntos de diez imágenes: fotografías con una persona, con dos personas y con tres o más personas; además, se examinó una galería de ocho identidades con una imagen de referencia por sujeto. El detector FrontalFaceCART alcanzó 100 % de efectividad reportada en imágenes con un rostro, 95 % con dos y 74,75 % con tres o más. La detección de nariz, boca y ojos disminuyó de 70 %, 60 % y 50 % en el primer escenario a 25 %, 37 % y 6,67 % en el tercero. El reconocimiento de personas fue correcto en tres de ocho casos (37,5 %), aunque uno de esos aciertos presentó una inconsistencia con el umbral de correlación de 0,30 documentado en el código. Los resultados muestran utilidad en condiciones frontales y controladas, pero una robustez limitada ante multitudes, accesorios, variaciones de luz y escasez de imágenes de referencia. Se recomienda sustituir la comparación píxel a píxel por representaciones profundas, validar con bases estandarizadas y aplicar salvaguardas de privacidad y equidad.

Palabras clave: reconocimiento facial; visión por computador; Viola-Jones; MATLAB; evaluación de software.

Abstract: Facial recognition remains a relevant computer vision problem, particularly when illumination, pose, occlusion, and the number of people vary. This study evaluated a prototype developed in MATLAB with Computer Vision Toolbox to detect faces and facial components, store templates, and recognize identities through binary-image correlation. A quantitative, applied, and descriptive approach was used with three sets of ten images: photographs containing one person, two people, and three or more people; an eight-identity gallery with one reference image per subject was also examined. The FrontalFaceCART detector achieved reported effectiveness values of 100% for single-face images, 95% for two-face images, and 74.75% for images with three or more faces. Nose, mouth, and eye detection decreased from 70%, 60%, and 50% in the first scenario to 25%, 37%, and 6.67% in the third. Identity recognition was correct in three of eight cases (37.5%), although one reported success was inconsistent with the 0.30 correlation threshold documented in the code. The results indicate usefulness under frontal and controlled conditions, but limited robustness to crowds, accessories, lighting variation, and sparse reference galleries. Replacing pixel-level comparison with deep representations, validating on standardized databases, and adopting privacy and fairness safeguards are recommended.

Keywords: facial recognition; computer vision; Viola-Jones; MATLAB; software evaluation.

1. INTRODUCCIÓN

El reconocimiento facial integra localización de rostros, extracción de rasgos y comparación de identidades. La literatura reciente describe una transición sostenida desde descriptores manuales y clasificadores en cascada hacia representaciones profundas aprendidas sobre grandes bases de datos. Este cambio ha elevado la precisión en condiciones controladas y en escenarios de alta variabilidad, pero no elimina los problemas asociados con la calidad de la imagen, el dominio de entrenamiento y la selección de métricas (Abidi et al., 2026; El Fadel, 2025).

Los prototipos basados en métodos clásicos conservan interés en contextos formativos, sistemas de bajo costo y dispositivos con recursos limitados. Su arquitectura permite observar de manera explícita cada etapa del procesamiento y estimar el costo computacional sin depender de aceleradores especializados. Sin embargo, los detectores frontales y las comparaciones directas entre imágenes suelen perder rendimiento cuando cambia la iluminación, aumenta la rotación del rostro o aparecen oclusiones. Las revisiones actuales identifican precisamente la postura, la iluminación, el desenfoque, la resolución y la oclusión como fuentes persistentes de error (Nani et al., 2025; Zhalgas et al., 2025).

La evaluación de un sistema de reconocimiento requiere separar dos tareas. La detección responde si existe un rostro y dónde se encuentra; la identificación determina a quién pertenece. Mezclar ambas etapas puede ocultar el origen de los fallos. Además, el uso de una sola imagen por identidad limita la variabilidad disponible para representar expresiones, edad, pose y condiciones de captura. Los estudios recientes recomiendan informar bases de datos, protocolos, métricas, umbrales y errores por subgrupo, porque la exactitud global no describe por sí sola la confiabilidad de un sistema (Nemavhola et al., 2025).

La aplicación de tecnologías biométricas también exige criterios de privacidad, consentimiento y equidad. Los datos faciales son identificadores persistentes y su reutilización sin una finalidad definida puede ampliar riesgos de vigilancia, exposición de datos y sesgos. La evolución técnica debe acompañarse de trazabilidad de las fuentes, minimización de datos, evaluación de desempeño por grupos y mecanismos de impugnación cuando el resultado tenga consecuencias para las personas (Conde et al., 2025).

El estudio tuvo como objetivo evaluar el desempeño de un prototipo de visión artificial desarrollado en MATLAB para detectar rostros y componentes faciales, así como reconocer identidades mediante correlación de imágenes. Para ello, se analizaron tres escenarios con diferente cantidad de personas, se diagnosticaron los principales patrones de fallo y se valoró la consistencia del procedimiento de reconocimiento, con el propósito de aportar criterios útiles para la mejora de sistemas biométricos educativos y de baja complejidad.

2. DESARROLLO

2.1 Fundamentos del reconocimiento facial

Un sistema facial automático suele organizarse en adquisición, detección, alineación, normalización, extracción de características y comparación. En la detección se delimitan

regiones candidatas; en la alineación se corrigen escala y orientación; en la extracción se transforma la imagen en una representación discriminante; y en la comparación se calcula una medida de similitud. Las revisiones recientes muestran que la robustez depende tanto de la arquitectura como del protocolo de evaluación y la diversidad de los datos (Abidi et al., 2026; Trigka & Dritsas, 2025).

El prototipo analizado implementó esta secuencia de forma simplificada. La detección se realizó con `vision.CascadeObjectDetector` y el clasificador `FrontalFaceCART`. Después de seleccionar un rostro, se aplicaron detectores en cascada para nariz, boca y par de ojos. La identidad se estimó mediante la correlación bidimensional entre una imagen binaria de consulta y las plantillas guardadas. Esta arquitectura facilita la inspección del proceso, aunque su representación conserva demasiada dependencia de la apariencia píxel a píxel.

2.2 Detectores en cascada y sistemas de baja complejidad

Los clasificadores en cascada combinan características simples y etapas sucesivas de rechazo para descartar rápidamente regiones que no contienen rostros. Su bajo costo favoreció aplicaciones en tiempo real y entornos integrados. En la actualidad, las redes ligeras ofrecen una alternativa con mayor capacidad de representación, pero la eficiencia sigue siendo un criterio central en dispositivos de borde. Ma et al. (2025) destacan que los modelos compactos deben equilibrar precisión, latencia y consumo de recursos, mientras que Mozaffari (2025) sitúa esa relación como uno de los retos generales de la visión por computador contemporánea.

La principal restricción de un detector frontal aparece cuando la geometría de la cara se aparta de los patrones aprendidos. La rotación, la reducción del tamaño del rostro y la superposición entre personas modifican la respuesta del clasificador. En fotografías con varios sujetos, cada rostro puede ocupar una escala distinta y presentar orientaciones heterogéneas, lo que aumenta las omisiones y los falsos positivos.

2.3 Preprocesamiento y representación de la identidad

El preprocesamiento busca reducir variaciones que no dependen de la identidad. Entre las operaciones habituales se encuentran el recorte, la normalización geométrica, el ajuste de iluminación, la conversión de color y la reducción de ruido. Soekarta y Ku-Mahamud (2025) señalan que estas decisiones influyen directamente en la estabilidad del reconocimiento, sobre todo cuando las imágenes proceden de cámaras y ambientes diferentes.

En el prototipo, cada rostro se redimensionó a 40 x 40 píxeles y se convirtió a formato binario antes de almacenarse en un archivo `.mat`. La comparación utilizó `corr2` y seleccionó el valor absoluto máximo. El código estableció un umbral de 0,30: por debajo de ese valor, la aplicación debía informar que la persona no había sido reconocida. Esta estrategia no genera una representación invariante frente a cambios de expresión, pose o iluminación, porque la correlación conserva una relación directa con la distribución espacial de los píxeles.

2.4 Variaciones de pose, iluminación y oclusión

La literatura reciente coincide en que la robustez debe evaluarse bajo condiciones adversas. Los métodos para rostros enmascarados y parcialmente ocluidos incorporan atención,

recuperación de regiones visibles o entrenamiento específico con oclusiones. Babu y Manne (2025) y Yalew et al. (2025) muestran que la presencia de máscaras u objetos sobre el rostro modifica tanto la detección como la identificación, por lo que un resultado obtenido con caras frontales despejadas no puede extrapolarse sin pruebas adicionales.

La iluminación produce cambios globales y locales que alteran bordes, texturas y contraste. La postura modifica la visibilidad relativa de ojos, nariz y boca, mientras que la distancia reduce la cantidad de detalle disponible. Zhalgas et al. (2025) describen estos factores como desafíos centrales incluso para modelos profundos. En sistemas clásicos, el efecto suele ser mayor debido a la menor capacidad para aprender invariancias.

2.5 Evaluación técnica y responsabilidad

Una evaluación reproducible debe declarar el tamaño de la muestra, la unidad de análisis, la forma de calcular los porcentajes, el criterio de acierto y el umbral de decisión. Para reconocimiento se recomiendan matrices de confusión, precisión, exhaustividad, F1, curvas ROC o DET y tasas de falsa aceptación y falso rechazo. Cuando se comparan imágenes con diferente cantidad de rostros, también debe distinguirse entre el promedio por fotografía y la tasa agregada por rostro, porque ambos cálculos pueden producir valores distintos (Nemavhola et al., 2025).

La responsabilidad metodológica incluye además documentar el origen de las imágenes y limitar inferencias demográficas no validadas. El manuscrito original incorporó una clasificación de categorías raciales basada en umbrales de intensidad de piel. Esa función no se presenta como resultado científico en este artículo, porque carece de una definición operacional válida, no controla la iluminación y puede reificar categorías sensibles. La decisión editorial se alinea con la necesidad de integrar salvaguardas éticas y legales en el análisis facial (Conde et al., 2025).

3. MATERIALES Y MÉTODOS

3.1 Enfoque y tipo de investigación

La investigación tuvo un enfoque cuantitativo y un alcance aplicado, descriptivo y evaluativo. Se reanalizaron los resultados de un prototipo funcional desarrollado como Trabajo Final de Máster durante el curso 2018-2019. El diseño fue no experimental y transversal en el sentido de que se observaron los resultados producidos por el software en conjuntos de imágenes predefinidos, sin asignación aleatoria de participantes ni manipulación de variables personales. La comparación se organizó por complejidad visual: una persona, dos personas y tres o más personas.

3.2 Población, muestra y justificación de la muestra

La población de interés estuvo conformada por imágenes digitales con rostros humanos que podían ser procesadas por el prototipo. La memoria describió la selección de diez fotografías por escenario como aleatoria y señaló que las imágenes fueron localizadas mediante Google; sin embargo, al no documentarse un marco muestral ni el procedimiento de aleatorización, esta versión editorial las considera una muestra no probabilística de conveniencia. La muestra principal reunió 30 fotografías: diez con una persona, diez con dos y diez con entre

tres y diez personas. Para la identificación se utilizó una galería adicional de ocho identidades, con una sola plantilla por identidad. Los criterios de inclusión fueron formato JPG legible, presencia visible de al menos un rostro y compatibilidad con la interfaz. Se excluyeron archivos corruptos o que no podían abrirse en la aplicación. Aunque el número de imágenes fue reducido, permitió comparar el comportamiento del prototipo bajo tres niveles de densidad facial. No se documentó la duración exacta de la fase de pruebas.

3.3 Técnicas e instrumentos de recolección de datos

La recolección se organizó en tres técnicas: observación del funcionamiento del software, registro estructurado de detecciones y comparación de similitud. La observación permitió identificar fallos asociados con postura, accesorios e iluminación; las matrices registraron rostros y componentes detectados; y la comparación calculó coeficientes de correlación entre consultas y plantillas. Los instrumentos fueron la interfaz gráfica desarrollada en MATLAB, las tablas de resultados y el archivo bd.mat que almacenó nombres, imágenes RGB redimensionadas e imágenes binarias.

El detector facial se configuró con FrontalFaceCART. Para nariz, boca y ojos se emplearon los clasificadores nose, mouth y EyePairBig, respectivamente, con MergeThreshold igual a uno. La identidad se obtuvo con corr2 sobre imágenes binarias de 40 x 40 píxeles. La memoria no documentó juicio de expertos, prueba piloto, estimación de confiabilidad ni validación externa de los instrumentos. La verificación disponible fue operativa y consistió en ejecutar el prototipo y registrar si cada elemento era detectado.

3.4 Procedimiento de la investigación

El procedimiento se organizó en tres etapas. En la primera etapa, configuración y línea base, se implementó la interfaz en MATLAB, se habilitó la lectura de imágenes o captura desde cámara y se configuraron los detectores. Cada rostro seleccionado podía guardarse en la base de datos después de redimensionarse y binarizarse. En la segunda etapa, evaluación de detección, se procesaron los tres conjuntos de diez imágenes y se registraron caras, narices, bocas y ojos detectados. En la tercera etapa, evaluación de identificación, se compararon ocho consultas con ocho plantillas y se seleccionó el coeficiente de correlación máximo; el código consideró no reconocida una consulta con similitud inferior a 0,30.

3.5 Consideraciones éticas

La memoria original no informó aprobación de un comité de ética, consentimiento de las personas representadas ni condiciones de licencia de las imágenes obtenidas en Internet. Por esta razón, el artículo no reproduce fotografías, nombres ni capturas que permitan atribuir identidad y presenta solo resultados agregados y códigos anónimos. La ausencia de trazabilidad y consentimiento limita cualquier reutilización del conjunto original. Estudios futuros deben emplear bases con licencia verificable, consentimiento o fundamento jurídico explícito, minimización de datos, almacenamiento seguro y evaluación de sesgos.

3.6 Análisis de datos

El análisis se basó en frecuencias, proporciones y porcentajes de efectividad. Para las imágenes con tres o más personas se recalculó también la tasa agregada por rostro a partir

de las tablas originales, porque el 74,75 % informado en la memoria corresponde al promedio simple de diez porcentajes por imagen. No se aplicaron pruebas inferenciales ni intervalos de confianza. Los datos se interpretaron junto con la evidencia bibliográfica reciente, los patrones de error, las limitaciones del procedimiento y los criterios útiles para el diseño de sistemas biométricos reproducibles.

4. RESULTADOS

Los resultados se organizan desde la configuración del prototipo hasta la comparación final de identidades, con el fin de mostrar el desempeño de la detección facial, la localización de componentes, los fallos asociados con condiciones de captura y la consistencia del umbral de reconocimiento.

4.1 Etapa 1: configuración y escenarios de prueba

El prototipo permitió abrir fotografías JPG o capturar una imagen desde cámara, detectar rostros, seleccionar una región facial y buscar nariz, boca y ojos. La base de datos almacenó una plantilla RGB y una versión binaria por identidad. La Tabla 1 sintetiza la configuración evaluada y las unidades de análisis utilizadas.

Tabla 1 Configuración del prototipo y diseño de la evaluación

Elemento	Configuración documentada
Entorno	MATLAB y Computer Vision Toolbox; interfaz gráfica bajo Windows
Detección facial	vision.CascadeObjectDetector con FrontalFaceCART
Componentes	Clasificadores nose, mouth y EyePairBig; MergeThreshold = 1
Preprocesamiento	Recorte del rostro, redimensionamiento a 40 x 40 y binarización
Identificación	Correlación corr2; máximo valor absoluto; umbral documentado = 0,30
Muestra de detección	30 imágenes: 10 con 1 rostro, 10 con 2 y 10 con 3 a 10 rostros
Galería de identidad	8 identidades con una imagen de referencia por sujeto

Fuente: elaboración propia.

La estructura hizo posible localizar el origen de los errores. Cuando la cara no era delimitada en la primera etapa, los detectores de componentes y la identificación no podían operar sobre esa persona. Por tanto, el desempeño final dependió de una cadena de decisiones sucesivas y no de un único clasificador.

4.2 Etapa 2: detección de rostros

El análisis de las 30 fotografías permitió identificar una disminución del rendimiento a medida que aumentó la cantidad de personas. En el conjunto de una persona se detectaron 10 de 10 rostros. En el conjunto de dos personas se detectaron 19 de 20. En las imágenes con tres o más personas se detectaron 40 de 55 rostros. La Tabla 2 presenta el porcentaje reportado por la tesis y la tasa agregada recalculada.

Tabla 2 Desempeño de la detección facial por escenario

Escenario	Imágenes	Rostros presentes	Rostros detectados	Tasa agregada	Promedio reportado
Una persona	10	10	10	100,00 %	100,00 %
Dos personas	10	20	19	95,00 %	95,00 %

Escenario	Imágenes	Rostros presentes	Rostros detectados	Tasa agregada	Promedio reportado
Tres o más	10	55	40	72,73 %	74,75 %

Fuente: elaboración propia.




Figura 1 Efectividad reportada de la detección de rostros

Fuente: elaboración propia.

Los datos muestran que el detector fue estable en fotografías de una persona y mantuvo un rendimiento alto con dos rostros. El descenso del tercer escenario fue sustancial: la tasa agregada cayó 27,27 puntos porcentuales respecto del primer conjunto. La diferencia entre 72,73 % y 74,75 % se explica por el método de cálculo. El valor original promedió el porcentaje de cada fotografía y otorgó el mismo peso a imágenes con tres y con diez rostros; la tasa agregada ponderó cada rostro por igual. Para comparación entre sistemas, la segunda medida resulta más interpretable.

4.3 Etapa 2: detección de nariz, boca y ojos

La detección de componentes presentó valores inferiores a la detección facial. La nariz fue el elemento más estable en imágenes de una y dos personas, mientras que los ojos mostraron la mayor sensibilidad a accesorios, escala y orientación. La Tabla 3 resume los porcentajes consignados en la memoria.

Tabla 3 Efectividad reportada en la detección de componentes faciales

Escenario	Nariz	Boca	Ojos
Una persona	70,00 %	60,00 %	50,00 %
Dos personas	60,00 %	40,00 %	20,00 %
Tres o más	25,00 %	37,00 %	6,67 %

Fuente: elaboración propia a partir.




Figura 2 Detección de componentes faciales por escenario

Fuente: elaboración propia.

El comportamiento problematiza el uso de detectores independientes sobre recortes pequeños. En el escenario de tres o más personas, los ojos se localizaron en apenas 6,67 % según el promedio reportado. La boca mostró 37 %, por encima de la nariz, pero las tablas individuales indican detecciones parciales y posibles respuestas sobre regiones que no correspondían a la boca. El hallazgo resulta útil porque muestra que una cara correctamente delimitada no garantiza una extracción confiable de componentes.

4.4 Etapa 3: reconocimiento de identidades

La evaluación de identificación utilizó ocho consultas y una plantilla por identidad. La memoria informó tres reconocimientos correctos y cinco fallos. El análisis de la matriz de correlación mostró que dos aciertos, P2 y P6, tuvieron el valor máximo en la plantilla correcta y superaron 0,30. P1 fue reportada como reconocida, aunque su máximo de 0,1390 se ubicó por debajo del umbral escrito en el código. La Tabla 4 detalla esa consistencia.

Tabla 4 Revisión de los resultados de reconocimiento de personas

Consulta	Máximo	Plantilla con máximo	Resultado reportado	Consistencia con umbral
P1	0,1390	P1	Sí (P1)	No: valor < 0,30
P2	0,5322	P2	Sí (P2)	Sí
P3	0,3842	P2	No	Sí: identidad incorrecta
P4	0,4226	P7	No	Sí: identidad incorrecta
P5	0,3510	P3	No	Sí: identidad incorrecta
P6	0,4120	P6	Sí (P6)	Sí
P7	0,2410	P5	No	Sí: valor < 0,30
P8	0,4819	P2	No	Sí: identidad incorrecta

Fuente: elaboración propia.




Figura 3 Resultado de reconocimiento reportado para ocho identidades

Fuente: elaboración propia a partir de los datos de la tesis.

Los tres aciertos reportados equivalen a 37,5 %. Si se aplicara de manera estricta el umbral de 0,30 documentado, P1 debería clasificarse como no reconocida y la tasa sería 25 %. Esta discrepancia no permite determinar si el umbral cambió durante las pruebas, si la tabla contiene un error de transcripción o si el resultado se decidió con un criterio distinto. El hallazgo limita la reproducibilidad y refuerza la necesidad de registrar versiones del código, parámetros y salidas automáticas.

4.5 Patrones de fallo observados

La observación cualitativa identificó condiciones recurrentes que afectaron la cadena de procesamiento. La Tabla 5 organiza los casos descritos en la memoria y su efecto sobre el prototipo.

Tabla 5 Condiciones asociadas con errores del prototipo

Condición	Efecto observado	Implicación técnica
Rostro no frontal o rotado	La cara no fue delimitada	El clasificador dependió de patrones frontales
Gafas u oclusión ocular	Los ojos no fueron reconocidos	La región visible no coincidió con EyePairBig
Iluminación insuficiente	Omisión de la cara o de sus componentes	El contraste alteró características y bordes
Varias personas y escalas distintas	Detección parcial de rostros	Aumentaron variaciones de tamaño, pose y superposición
Una plantilla por identidad	Confusión entre sujetos y baja tasa de acierto	La galería no representó variación intraindividual

Fuente: elaboración propia.

Estos patrones muestran una dependencia fuerte de condiciones controladas. La utilidad del prototipo se concentró en imágenes frontales, iluminadas y con pocos sujetos. Las dificultades no fueron incidentes aislados, sino consecuencias de la representación, la configuración de los detectores y la limitada diversidad de la galería.

5. DISCUSIÓN

El desempeño inicial de 100 % en fotografías con una persona indica que el detector en cascada puede resolver escenas simples cuando el rostro aparece frontal y con suficiente escala. Este resultado es coherente con el uso histórico de cascadas en aplicaciones de baja complejidad, pero no constituye una estimación generalizable debido al tamaño de la muestra y a la ausencia de un conjunto estandarizado. Las revisiones recientes insisten en que el rendimiento debe probarse bajo variaciones de dominio y no solo sobre imágenes favorables (El Fadel, 2025; Trigka & Dritsas, 2025).

La reducción a 72,73 % por rostro en escenas con tres o más personas puede explicarse por cambios de escala, postura y oclusión. En una imagen grupal, algunos rostros son pequeños, están parcialmente cubiertos o se orientan fuera del plano frontal. Zhalgas et al. (2025) describen esas condiciones como desafíos persistentes para el reconocimiento robusto. La diferencia entre el promedio por imagen y la tasa agregada muestra además que el método de resumen altera la lectura del desempeño; ambos valores deben declararse cuando el número de rostros por fotografía es desigual.

La extracción de componentes fue el punto más débil. Los ojos descendieron de 50 % a 6,67 %, y la memoria documentó fallos ante gafas. Los trabajos recientes sobre oclusión muestran que los sistemas actuales incorporan entrenamiento específico, atención sobre regiones visibles o modelos capaces de integrar información global del rostro (Babu & Manne, 2025; Yalaw et al., 2025). El prototipo, en cambio, aplicó detectores independientes y no propagó incertidumbre entre etapas, por lo que una detección imprecisa podía producir errores posteriores sin una medida de confianza.

La tasa de identificación reportada de 37,5 % fue baja y debe interpretarse junto con la composición de la galería. Una sola imagen por persona no representa variación intraindividual. La correlación de imágenes binarias de 40 x 40 píxeles tampoco separa adecuadamente identidad de iluminación, expresión y alineación. Los enfoques contemporáneos aprenden embeddings y márgenes discriminantes, y los sistemas ligeros buscan mantener esa capacidad con menor costo computacional (Abidi et al., 2026; Ma et al., 2025; Mozaffari, 2025). La inconsistencia de P1 muestra, además, que un umbral sin registro automático de la decisión puede introducir errores de reporte.

Entre las limitaciones metodológicas se encuentran la muestra pequeña, la procedencia no trazable de las imágenes, la ausencia de particiones de entrenamiento y prueba, la falta de múltiples plantillas por identidad, la inexistencia de métricas de falsa aceptación y falso rechazo y la falta de validación externa. Tampoco se documentaron consentimiento, licencias ni análisis por características demográficas. La función de clasificación racial basada en intensidad de piel fue metodológicamente inadecuada y no debe trasladarse a aplicaciones reales. La investigación actual subraya que el avance técnico debe integrar privacidad, equidad y gobernanza de datos (Conde et al., 2025).

Una mejora futura debería reemplazar corr2 por embeddings faciales normalizados, ampliar la galería con varias imágenes por sujeto y separar conjuntos de desarrollo, validación y prueba. También conviene evaluar modelos ligeros en el mismo hardware, aplicar aumento de datos para iluminación y pose, calibrar umbrales con curvas ROC o DET

y reportar intervalos de confianza. El preprocesamiento debe documentarse como parte del protocolo y no como una operación secundaria, porque influye en la estabilidad del resultado (Soekarta & Ku-Mahamud, 2025). Para cambios temporales de apariencia, las actualizaciones controladas de embeddings constituyen una línea relevante (Tosidis et al., 2024).

Los hallazgos aportan una ruta de análisis y aplicación para prototipos biométricos de baja complejidad, al integrar evaluación por etapas, revisión de los criterios de decisión y examen de las condiciones de fallo. Su utilidad radica en que ofrece criterios aplicables para docentes, desarrolladores e investigadores, especialmente en contextos donde se requiere distinguir una demostración funcional de un sistema suficientemente validado para uso operativo.

6. CONCLUSIONES

El principal hallazgo fue la relación inversa entre complejidad visual y desempeño. La detección facial alcanzó 100 % en imágenes con una persona y 95 % con dos, pero descendió a 72,73 % por rostro en escenas con tres o más personas. El promedio de 74,75 % reportado originalmente respondió a una media por imagen y no a una proporción agregada.

Los problemas más frecuentes estuvieron asociados con postura no frontal, iluminación insuficiente, oclusiones y reducción del tamaño facial. La detección de ojos fue particularmente inestable y llegó a 6,67 % en el escenario de mayor densidad. Estos patrones muestran que la correcta localización de la cara no garantiza una extracción confiable de componentes.

El reconocimiento por correlación de imágenes binarias resultó insuficiente para una galería con una sola plantilla por identidad. La memoria reportó tres aciertos de ocho, pero uno presentó un valor inferior al umbral documentado, lo que reduce la reproducibilidad. La comparación píxel a píxel debe sustituirse por representaciones más invariantes y por un protocolo que registre automáticamente umbrales, predicciones y errores.

El principal aporte del estudio fue integrar una ruta práctica de evaluación aplicable por docentes, desarrolladores e investigadores que trabajan con prototipos de visión artificial. Desde esta perspectiva, se recomienda continuar la investigación con bases autorizadas, múltiples imágenes por identidad, modelos ligeros de embeddings, métricas biométricas completas y análisis de privacidad y equidad, a fin de comprobar si las mejoras se mantienen bajo condiciones reales y en el tiempo.

7. CONFLICTO DE INTERÉS

El autor declara que no existen conflictos de interés relacionados con la preparación de este manuscrito.

9. REFERENCIAS

Abidi, S. M. H., Hassan, S. A., Raza, S. M., & Beliatas, M. J. (2026). Advances in face recognition: A comprehensive review of feature extraction and dataset evaluation. *Electronics*, 15(2), 338. <https://doi.org/10.3390/electronics15020338>

- Babu, K. N., & Manne, S. (2025). A novel approach for accurate identification in masked and unmasked scenarios using Glowworm Swarm Optimization and neural networks. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-024-20093-2>
- Conde, J., Speelman, C., & Johnstone, M. (2025). A new epoch of face analytics: Technological evolution through ethical and legal challenges. *AI and Ethics*. <https://doi.org/10.1007/s43681-025-00678-9>
- El Fadel, N. (2025). Facial recognition algorithms: A systematic literature review. *Journal of Imaging*, 11(2), 58. <https://doi.org/10.3390/jimaging11020058>
- Ma, H., Guo, D., Wang, J., Li, P., Xu, C., & Wang, Y. (2025). Real-time face recognition algorithm based on lightweight neural network in the field of computer vision. *Discover Applied Sciences*. <https://doi.org/10.1007/s42452-025-08004-y>
- Mozaffari, M. H. (2025). Deep learning for computer vision application. *Electronics*, 14(14), 2874. <https://doi.org/10.3390/electronics14142874>
- Nani, P., Das, S., & Dey, S. (2025). Enhancing object recognition: A comprehensive analysis of CNN-based deep learning models considering lighting conditions and perspectives. *Evolutionary Intelligence*. <https://doi.org/10.1007/s12065-025-01061-7>
- Nemavhola, A., Chibaya, C., & Viriri, S. (2025). A systematic review of CNN architectures, databases, performance metrics, and applications in face recognition. *Information*, 16(2), 107. <https://doi.org/10.3390/info16020107>
- Soekarta, R., & Ku-Mahamud, K. R. (2025). Recent facial image preprocessing techniques: A review. *Engineering Proceedings*, 84(1), 39. <https://doi.org/10.3390/engproc2025084039>
- Tosidis, P., Passalis, N., & Tefas, A. (2024). Continual updates of face embeddings using deep reinforcement learning. In *Pattern Recognition*. https://doi.org/10.1007/978-3-031-87660-8_24
- Trigka, M., & Dritsas, E. (2025). A comprehensive survey of machine learning techniques and models for object detection. *Sensors*, 25(1), 214. <https://doi.org/10.3390/s25010214>
- Yalew, T. A., Gashaw, S. M., Ayalew, A. M., & Oussalah, M. (2025). Deep learning-based occlusion-aware face mask detection for airborne disease control. *Discover Computing*. <https://doi.org/10.1007/s10791-025-09684-1>
- Zhalgas, A., Amirgaliyev, B., & Sovet, A. (2025). Robust face recognition under challenging conditions: A comprehensive review of deep learning methods and challenges. *Applied Sciences*, 15(17), 9390. <https://doi.org/10.3390/app15179390>