

Evaluación de algoritmos de extracción de características para reconocimiento facial mediante ISO/IEC 25010

Evaluation of Feature Extraction Algorithms for Face Recognition Using ISO/IEC 25010

José Luis Carvajal¹, Menghy Raúl Sánchez Maila¹

jose.carvajal@pucese.edu.ec, menghy.sanchez@pucese.edu.ec

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

Citación: Carvajal, J. L., & Sánchez Maila, M. R. (2026). Evaluation of Feature Extraction Algorithms for Face Recognition Using ISO/IEC 25010. *EKSIGMA*, 2(3), 32-43. <https://eksigma.com/index.php/principal/article/view/33>

Recibido: 29 de junio 2026

Aceptado: 03 de agosto 2026

Publicado: 15 de septiembre 2026

EKSIGMA
ISSN: 3121-2689

Correspondencia:

Menghy Raúl Sánchez Maila

Resumen: El reconocimiento facial combina extracción de características, comparación de patrones y criterios de decisión, pero la precisión aislada no describe por completo la calidad de una implementación. El estudio tuvo como objetivo evaluar comparativamente los algoritmos EigenFace, FisherFace y Viola-Jones para la extracción de características faciales mediante un marco basado en ISO/IEC 25010. Se desarrolló un estudio experimental y comparativo con el conjunto Yale Face, dividido en datos de entrenamiento y prueba, y se implementaron los tres algoritmos en Python dentro de un entorno Anaconda/Jupyter, utilizando PCA como base común para EigenFace y FisherFace y procesamiento con OpenCV para Viola-Jones. La evaluación comprendió adecuación funcional, eficiencia de desempeño, usabilidad, fiabilidad, mantenibilidad y portabilidad mediante indicadores puntuados de 1 a 5. Viola-Jones alcanzó la mayor efectividad de reconocimiento (95,0%), seguido de FisherFace (90,0%) y EigenFace (86,6%); sin embargo, su tiempo de ejecución fue mayor (25 min frente a 9 y 7 min). En la valoración global de calidad, FisherFace obtuvo 56/70, EigenFace 54/70 y Viola-Jones 53/70. Los resultados muestran que la selección de un algoritmo no debe basarse únicamente en exactitud: el equilibrio entre funcionalidad, consumo de recursos, mantenibilidad y portabilidad modifica la decisión técnica. FisherFace presentó el balance más favorable dentro del entorno controlado analizado, mientras Viola-Jones destacó por precisión funcional.

Palabras clave: reconocimiento facial; extracción de características; calidad de software; ISO/IEC 25010; EigenFace; FisherFace.

Abstract: Face recognition combines feature extraction, pattern comparison, and decision criteria, but accuracy alone does not fully describe implementation quality. The study aimed to comparatively evaluate EigenFace, FisherFace, and Viola-Jones for facial feature extraction using an ISO/IEC 25010-based framework. An experimental comparative study was conducted with the Yale Face dataset, split into training and test data. The three algorithms were implemented in Python within an Anaconda/Jupyter environment, using PCA as a common comparison basis and OpenCV for image processing. Functional suitability, performance efficiency, usability, reliability, maintainability, and portability were assessed through indicators scored from 1 to 5. Viola-Jones achieved the highest recognition effectiveness (95.0%), followed by FisherFace (90.0%) and EigenFace (86.6%); however, its execution took longer (25 min versus 9 and 7 min). In overall software-quality scoring, FisherFace reached 56/70, EigenFace 54/70, and Viola-Jones 53/70. The findings indicate that algorithm selection should not rely solely on accuracy because functionality, resource utilization, maintainability, and portability affect the technical decision. FisherFace achieved the most favorable overall balance in the controlled environment, whereas Viola-Jones stood out for functional accuracy.

Keywords: face recognition; feature extraction; software quality; ISO/IEC 25010; EigenFace; FisherFace.



Copyright © 2026. El autor conserva los derechos de autor y los derechos de publicación. Asimismo, otorga 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/>

1. INTRODUCCIÓN

El reconocimiento facial es una de las aplicaciones biométricas más extendidas de la visión por computador. Su funcionamiento integra localización del rostro, normalización de la imagen, extracción de características y comparación de representaciones para verificar o identificar identidades. La literatura reciente muestra una transición sostenida desde descriptores estadísticos y subespacios lineales hacia redes profundas y modelos de gran escala; aun así, los enfoques clásicos continúan siendo útiles como líneas base por su menor costo computacional, trazabilidad matemática y facilidad de implementación (Wang & Deng, 2021; Siddiqi et al., 2022).

La evaluación técnica de un sistema de reconocimiento facial suele concentrarse en exactitud, tasa de falsos positivos, robustez frente a oclusión o desempeño entre grupos demográficos. Ese enfoque es necesario, pero incompleto cuando la solución debe integrarse en un producto de software. La eficiencia, facilidad de modificación, capacidad de instalación, tolerancia a fallos y posibilidad de aprendizaje por parte de quien mantiene el código también condicionan la viabilidad de una implementación. La investigación contemporánea sobre calidad de imagen, sesgo y robustez confirma que el desempeño biométrico depende tanto de los datos y del modelo como de las condiciones operativas y de evaluación (Schlett et al., 2022; Terhörst et al., 2022; Yucer et al., 2024).

Los algoritmos EigenFace y FisherFace representan dos estrategias clásicas de reducción y discriminación de características. EigenFace proyecta los rostros en un subespacio definido por componentes principales, mientras FisherFace incorpora información discriminante entre clases para mejorar la separabilidad. Viola-Jones, por su parte, se asocia principalmente con detección rápida mediante características tipo Haar y clasificadores en cascada. Aunque los métodos profundos dominan los sistemas actuales, la comparación de enfoques clásicos conserva valor pedagógico y metodológico porque permite observar con claridad la relación entre estructura algorítmica, consumo de recursos y desempeño funcional (Pann & Lee, 2022; Eman et al., 2023).

El problema central consiste en que un algoritmo con mayor efectividad de reconocimiento no necesariamente constituye la mejor alternativa desde la perspectiva de calidad de software. Un método puede alcanzar una precisión superior y, al mismo tiempo, requerir mayor tiempo de procesamiento, presentar una implementación más compleja o disponer de menor facilidad de mantenimiento. Esta tensión resulta especialmente relevante cuando el reconocimiento facial se ejecuta en hardware limitado o en aplicaciones que deben ser portables, auditables y sostenibles a lo largo del tiempo. Revisiones recientes subrayan además que robustez, privacidad, equidad y generalización deben considerarse junto con la precisión (Nemavhola et al., 2025; El Fadel, 2025; Amirgaliyev et al., 2025).

El estudio tuvo como objetivo evaluar los principales algoritmos utilizados para la extracción de características en reconocimiento facial mediante la implementación y ejecución de EigenFace, FisherFace y Viola-Jones, con el propósito de valorar su calidad como producto de software a partir de criterios derivados de ISO/IEC 25010. Para ello, se compararon la efectividad de reconocimiento, el tiempo de ejecución y un conjunto de

indicadores de adecuación funcional, eficiencia, usabilidad, fiabilidad, mantenibilidad y portabilidad.

2. DESARROLLO

2.1 Reconocimiento facial y extracción de características

Un sistema de reconocimiento facial transforma una imagen en una representación numérica que permita comparar identidades. El proceso suele incluir detección, alineación, normalización, extracción de rasgos y decisión. Los avances recientes emplean redes convolucionales, transformadores y funciones de pérdida que optimizan directamente la separabilidad de identidades; sin embargo, los principios de representación compacta y reducción de dimensionalidad continúan siendo fundamentales para comprender el problema (Wang & Deng, 2021; Abidi et al., 2026).

En condiciones reales, la calidad de la imagen, pose, iluminación, oclusión, resolución y composición demográfica alteran el rendimiento. La evaluación del algoritmo debe distinguir entre desempeño observado en un conjunto controlado y capacidad de generalización. Los trabajos sobre calidad facial y reconocimiento bajo condiciones difíciles han mostrado que una métrica agregada puede ocultar degradaciones específicas y que las decisiones de implementación deben documentar las condiciones de captura y prueba (Schlett et al., 2022; Zhalgas et al., 2025).

2.2 PCA, EigenFace, FisherFace y Viola-Jones

El análisis de componentes principales (PCA) reduce la dimensionalidad conservando las direcciones de mayor varianza. En el contexto de rostros, las proyecciones resultantes permiten representar cada imagen mediante un vector de menor dimensión y comparar similitudes. EigenFace explota este principio para construir un espacio facial a partir de vectores propios. Su ventaja reside en la simplicidad computacional y la interpretabilidad, aunque puede ser sensible a variaciones de iluminación y pose.

FisherFace parte de una representación reducida y busca maximizar la separación entre clases respecto de la variabilidad interna. Esta lógica discriminante puede mejorar la identificación cuando las clases presentan variaciones controladas. Viola-Jones utiliza una estrategia distinta: combina rasgos tipo Haar, imágenes integrales, selección de características y clasificadores en cascada para localizar estructuras faciales con rapidez. En la práctica, estas familias responden a compromisos diferentes entre exactitud, tiempo, complejidad y facilidad de mantenimiento.

2.3 Calidad de software aplicada a algoritmos biométricos

La calidad de un algoritmo implementado como software no se limita a su salida funcional. ISO/IEC 25010 organiza la calidad del producto en características que incluyen adecuación funcional, eficiencia de desempeño, compatibilidad, usabilidad, fiabilidad, seguridad, mantenibilidad y portabilidad. En el estudio se seleccionó un subconjunto de estas dimensiones para construir un marco comparativo homogéneo entre implementaciones.

El uso de un marco multidimensional resulta pertinente para sistemas biométricos porque el despliegue real exige además robustez, capacidad de actualización y control de recursos. La literatura reciente sobre privacidad y biometría multimodal refuerza la necesidad de

evaluar arquitecturas de manera sistémica, especialmente cuando el procesamiento involucra datos sensibles y entornos heterogéneos (Zhao et al., 2025; Kansal et al., 2025; Es-Sobbahi et al., 2025).

2.4 Robustez, sesgo y condiciones de operación

Los resultados de reconocimiento pueden depender de variables que no están representadas en una prueba controlada. Se han documentado diferencias asociadas con composición racial de los datos, oclusiones, calidad de captura y condiciones ambientales. Coe y Atay (2021) mostraron que la distribución racial puede modificar el comportamiento de modelos de reconocimiento, mientras Terhörst et al. (2022) ampliaron el análisis de sesgos más allá de categorías demográficas simples.

Las oclusiones constituyen otra fuente de variabilidad. Pann y Lee (2022) y Eman et al. (2023) muestran que la atención, segmentación y preprocesamiento pueden mejorar el desempeño cuando parte del rostro está cubierta. Estos hallazgos no invalidan los resultados obtenidos con conjuntos controlados, pero delimitan su alcance: una comparación interna permite estudiar diferencias relativas entre implementaciones, no garantizar desempeño en escenarios abiertos.

2.5 Criterios contemporáneos para seleccionar una implementación

La selección de un algoritmo debe equilibrar capacidad de reconocimiento, costo computacional, facilidad de integración y requisitos del contexto. Las revisiones recientes señalan que los sistemas actuales se evalúan cada vez más en términos de escalabilidad, privacidad, robustez y desempeño entre dominios, además de exactitud (Qadir et al., 2025; Muhammed et al., 2026). Desde esta perspectiva, una evaluación basada en calidad de software ofrece una lectura complementaria a las métricas biométricas.

Los métodos clásicos no compiten directamente con las arquitecturas profundas contemporáneas en escenarios masivos; su utilidad en este estudio reside en que permiten controlar la implementación y hacer visibles los procesos internos. Esta transparencia facilita analizar recursos, mantenibilidad y portabilidad, dimensiones que pueden quedar ocultas cuando se usan bibliotecas de alto nivel o modelos preentrenados.

3. MATERIALES Y MÉTODOS

3.1 Enfoque y tipo de investigación

Se desarrolló una investigación cuantitativa de alcance comparativo y experimental. La unidad de análisis fue cada implementación algorítmica: EigenFace, FisherFace y Viola-Jones. El diseño buscó mantener condiciones de ejecución equivalentes para comparar funcionalidad y atributos de calidad sin modificar el entorno de hardware entre pruebas.

3.2 Conjunto de datos y entorno de implementación

Se utilizó el conjunto Yale Face, organizado en subconjuntos de entrenamiento y prueba mediante una división del 80% y 20%, respectivamente. Las imágenes se procesaron en un entorno Python con Anaconda y Jupyter Notebook; OpenCV se empleó para operaciones de visión por computador. Las ejecuciones se realizaron en un computador portátil con procesador AMD Ryzen 5 2500U, 16 GB de memoria RAM y gráficos Radeon Vega 8 de 1 GB. Este entorno se mantuvo constante para los tres algoritmos.

Para hacer comparable la estructura de los procedimientos se utilizó PCA como base común de extracción o reducción de características. Esta decisión no implica que Viola-Jones sea conceptualmente un método PCA, sino que la implementación experimental incorporó PCA dentro del flujo de procesamiento definido en la investigación para homogeneizar el marco de comparación.

3.3 Variables, indicadores e instrumento de evaluación

La evaluación se organizó en seis dimensiones derivadas de ISO/IEC 25010: adecuación funcional, eficiencia de desempeño, usabilidad, fiabilidad, mantenibilidad y portabilidad. Se analizaron 14 indicadores mediante una escala ordinal de 1 a 5, donde valores mayores representaron mejor desempeño respecto del criterio examinado. La puntuación máxima posible fue de 70 puntos por algoritmo.

Tabla 1. Dimensiones e indicadores utilizados en la evaluación

Dimensión	Indicadores considerados
Adecuación funcional	Corrección funcional
Eficiencia de desempeño	Utilización de recursos; capacidad
Usabilidad	Capacidad de aprendizaje; capacidad para ser usado; protección contra errores
Fiabilidad	Madurez; disponibilidad; tolerancia a fallos
Mantenibilidad	Modularidad; capacidad para ser modificado
Portabilidad	Adaptabilidad; capacidad para ser instalado; capacidad para ser reemplazado

Fuente: elaboración propia a partir del marco de evaluación de la investigación.

3.4 Procedimiento de la investigación

El procedimiento se organizó en tres etapas. En la primera, selección y preparación, se revisaron los algoritmos candidatos, se organizó el conjunto Yale Face y se definió el entorno común de ejecución. En la segunda, implementación y prueba, se desarrollaron los flujos de EigenFace, FisherFace y Viola-Jones, se ejecutaron las rutinas de entrenamiento y reconocimiento y se registraron efectividad y tiempo. En la tercera, evaluación de calidad, cada implementación se valoró con los indicadores seleccionados de ISO/IEC 25010 y se consolidó una puntuación global.

La efectividad se calculó como proporción de reconocimientos correctos en el conjunto de prueba. El tiempo de ejecución se registró en minutos bajo el mismo hardware. Las puntuaciones de calidad se consolidaron por suma simple de los 14 indicadores para facilitar la comparación descriptiva.

3.5 Consideraciones éticas e integridad

La investigación utilizó un conjunto de imágenes de referencia destinado a experimentación académica y no realizó recolección directa de datos personales de participantes. El análisis se concentró en el comportamiento técnico de los algoritmos. Para la interpretación contemporánea se reconoce que los sistemas de reconocimiento facial implican riesgos de privacidad, sesgo y uso indebido, por lo que cualquier despliegue posterior requiere gobernanza de datos, evaluación de equidad y controles de seguridad (Zhao et al., 2025; Muhammed et al., 2026).

3.6 Análisis de datos

Los resultados se analizaron mediante estadística descriptiva. Se compararon porcentajes de efectividad, tiempos de ejecución y puntuaciones de calidad por indicador y por algoritmo. No se aplicaron pruebas inferenciales porque la investigación trabajó con una ejecución comparativa controlada y no con réplicas suficientes para estimar variabilidad estadística entre condiciones.

4. RESULTADOS

Los resultados se organizan desde el desempeño funcional hasta la valoración integral de calidad, con el fin de mostrar las diferencias entre exactitud de reconocimiento, costo temporal y atributos de software. La comparación evidencia que el algoritmo con mayor efectividad no fue el que obtuvo la mayor puntuación global de calidad.

4.1 Efectividad de reconocimiento

La comparación funcional mostró una ventaja de Viola-Jones en el entorno de prueba. Este algoritmo alcanzó 95,0% de efectividad, FisherFace 90,0% y EigenFace 86,6%. La diferencia de 8,4 puntos porcentuales entre el valor mayor y el menor indica que la elección del método de extracción y detección modifica el resultado aun cuando el entorno computacional se mantiene constante.




Figura 1. Efectividad de reconocimiento de los algoritmos evaluados

Fuente: elaboración propia a partir de los resultados de la investigación.

El mayor porcentaje de Viola-Jones favoreció su calificación en corrección funcional. Sin embargo, la literatura reciente advierte que la exactitud obtenida en un único conjunto de datos no debe interpretarse como evidencia suficiente de generalización; calidad de imagen, oclusión y composición demográfica pueden alterar sustancialmente el rendimiento en despliegues abiertos (Schlett et al., 2022; Zhalgas et al., 2025).

4.2 Eficiencia de desempeño

El tiempo de ejecución presentó un patrón inverso a la efectividad. EigenFace completó el proceso en 7 minutos, FisherFace en 9 minutos y Viola-Jones en 25 minutos. La mayor carga temporal de Viola-Jones se relacionó con su flujo de búsqueda y evaluación en cascada,

mientras los procedimientos basados en proyección presentaron menor costo en el entorno evaluado.




Figura 2. Tiempo de ejecución de los algoritmos evaluados
Fuente: elaboración propia a partir de los resultados de la investigación.

La diferencia fue relevante para la dimensión de utilización de recursos: EigenFace recibió 4 puntos, FisherFace 3 y Viola-Jones 2. El resultado muestra un compromiso claro entre precisión y costo temporal. Este tipo de compensación continúa siendo central en sistemas biométricos contemporáneos, especialmente cuando deben ejecutarse en dispositivos de borde o plataformas con recursos limitados (Amirgaliyev et al., 2025; Qadir et al., 2025).

4.3 Calidad de software por indicadores

La evaluación de los 14 indicadores produjo perfiles distintos. FisherFace destacó en madurez y modularidad; EigenFace obtuvo mejor valoración en utilización de recursos y capacidad de aprendizaje; Viola-Jones sobresalió en corrección funcional, madurez y modularidad, pero recibió menor valoración en utilización de recursos, capacidad de aprendizaje y facilidad de instalación. La Tabla 2 resume las puntuaciones.

Indicador	EigenFace	FisherFace	Viola-Jones
Corrección funcional	3	4	5
Utilización de recursos	4	3	2
Capacidad	4	4	4
Capacidad de aprendizaje	4	4	2
Capacidad para ser usado	4	4	4
Protección contra errores	3	3	3
Madurez	4	5	5
Disponibilidad	3	3	3
Tolerancia a fallos	2	2	2
Modularidad	4	5	5
Capacidad para ser modificado	4	4	4
Adaptabilidad	5	5	5
Capacidad para ser instalado	5	5	4
Capacidad para ser reemplazado	5	5	5

Indicador	EigenFace	FisherFace	Viola-Jones
Puntaje total	54	56	53

Fuente: elaboración propia a partir de la Tabla 7 de la investigación.

Los tres algoritmos obtuvieron el mismo puntaje en capacidad, protección contra errores, disponibilidad, tolerancia a fallos, capacidad de modificación, adaptabilidad y reemplazabilidad. Las diferencias decisivas se concentraron en corrección funcional, utilización de recursos, capacidad de aprendizaje, madurez, modularidad e instalación. Por tanto, la puntuación global fue sensible a características de ingeniería del código y no únicamente a la tasa de reconocimiento.

4.4 Comparación global

La suma de indicadores ubicó a FisherFace en primer lugar con 56/70, seguido de EigenFace con 54/70 y Viola-Jones con 53/70. La Figura 3 permite observar que el algoritmo más preciso no fue el mejor valorado en calidad global.




Figura 3. Puntuación global de calidad basada en ISO/IEC 25010

Fuente: elaboración propia a partir de los resultados de la investigación.

FisherFace presentó el mejor balance entre precisión, consumo de recursos, aprendizaje de la implementación, madurez, modularidad y portabilidad. Viola-Jones conservó una ventaja funcional clara, pero su mayor tiempo y complejidad redujeron la valoración agregada. EigenFace, aunque menos preciso, mostró el mejor tiempo de ejecución y una estructura comparativamente sencilla.

5. DISCUSIÓN

Los resultados muestran que la efectividad funcional y la calidad global representan dimensiones relacionadas, pero no equivalentes. Viola-Jones alcanzó 95,0% de reconocimiento y, al mismo tiempo, obtuvo la menor puntuación global entre los tres algoritmos. Este comportamiento respalda la necesidad de evitar evaluaciones unidimensionales. Wang y Deng (2021) describen una evolución del reconocimiento facial hacia representaciones cada vez más precisas, mientras la literatura sobre calidad biométrica enfatiza que la utilidad práctica depende también de las condiciones de captura, generalización y costo de procesamiento (Schlett et al., 2022).

El mejor resultado global de FisherFace se explica por su equilibrio. La diferencia de dos puntos respecto de EigenFace y de tres respecto de Viola-Jones es pequeña, pero revela que la incorporación de discriminación entre clases puede aportar precisión sin alcanzar el costo temporal observado en la cascada evaluada. La interpretación debe mantenerse dentro del entorno experimental, ya que los modelos actuales basados en aprendizaje profundo operan con representaciones y conjuntos de entrenamiento mucho más complejos (Siddiqi et al., 2022; Nemavhola et al., 2025).

El tiempo de ejecución fue uno de los hallazgos más contrastantes: 7 minutos para EigenFace, 9 para FisherFace y 25 para Viola-Jones. Esta diferencia condicionó la eficiencia de desempeño. En sistemas modernos, la misma tensión aparece entre precisión, tamaño del modelo, latencia y consumo energético. Amirgaliyev et al. (2025) destacan que la selección de arquitecturas para detección e identificación debe considerar restricciones del dispositivo y del escenario, mientras Qadir et al. (2025) señalan que la escalabilidad exige integrar almacenamiento vectorial y procedimientos de búsqueda eficientes.

La evaluación de usabilidad, fiabilidad, mantenibilidad y portabilidad amplió la lectura de los resultados. La modularidad elevada de FisherFace y Viola-Jones favorece modificaciones e integración de componentes, mientras la capacidad de aprendizaje menor de Viola-Jones refleja una estructura de implementación más compleja. En aplicaciones reales, esta complejidad se incrementa con requisitos de privacidad y protección de plantillas biométricas; los trabajos de Zhao et al. (2025), Kansal et al. (2025) y Es-Sobbahi et al. (2025) muestran que la calidad de una solución biométrica depende de decisiones arquitectónicas que exceden la clasificación.

Una limitación metodológica fue el uso de un conjunto controlado y una sola configuración de hardware. No se realizaron múltiples réplicas para estimar dispersión de tiempos, ni se compararon arquitecturas CNN o transformadores, ni se evaluó generalización entre bases. Tampoco se midieron diferencias por grupos demográficos, condición que la literatura contemporánea considera esencial para evitar conclusiones sesgadas sobre desempeño (Coe & Atay, 2021; Terhörst et al., 2022; Yucer et al., 2024).

Los resultados deben interpretarse como una comparación de ingeniería reproducible entre tres implementaciones clásicas bajo criterios homogéneos, no como una clasificación definitiva de los algoritmos disponibles actualmente. Trabajos recientes sobre reconocimiento robusto, arquitecturas federadas y evaluación de conjuntos muestran que

los sistemas contemporáneos requieren pruebas bajo ruido, oclusión, dominios distintos y restricciones de privacidad (Zhalgas et al., 2025; Muhammed et al., 2026; Abidi et al., 2026). Los hallazgos aportan una ruta de análisis aplicable a la selección de algoritmos biométricos al integrar efectividad, eficiencia y calidad de software. Su utilidad radica en que permite documentar los compromisos técnicos antes de elegir una solución, especialmente en contextos con recursos limitados o necesidades de mantenimiento prolongado. Como mejora futura, el marco debería repetirse con modelos profundos actuales, bases multicéntricas y métricas de equidad, seguridad, consumo energético y latencia.

6. CONCLUSIONES

La evaluación comparativa mostró que no existe una correspondencia automática entre mayor efectividad de reconocimiento y mayor calidad de software. Viola-Jones obtuvo la mejor efectividad (95,0%), pero FisherFace alcanzó la mayor puntuación integral (56/70), seguido de EigenFace (54/70) y Viola-Jones (53/70).

Los principales contrastes se localizaron en corrección funcional, utilización de recursos, capacidad de aprendizaje, madurez, modularidad y facilidad de instalación. EigenFace fue el más rápido con 7 minutos; FisherFace requirió 9 minutos y Viola-Jones 25 minutos. Este patrón evidencia que la decisión técnica cambia cuando se incorporan eficiencia y mantenibilidad a la comparación.

FisherFace presentó el balance más favorable dentro del entorno controlado porque combinó un 90,0% de efectividad con una puntuación elevada en madurez, modularidad, portabilidad y facilidad de uso. Viola-Jones resulta preferible cuando la prioridad es maximizar la precisión funcional en condiciones similares a las probadas, mientras EigenFace ofrece una alternativa simple y de menor costo temporal.

El principal aporte del estudio fue integrar una ruta práctica de evaluación multidimensional para algoritmos de reconocimiento facial. Se recomienda extenderla con arquitecturas profundas actuales, múltiples conjuntos de datos, repeticiones experimentales, pruebas de robustez, análisis de equidad demográfica y métricas de privacidad y consumo computacional, con el fin de comprobar la estabilidad de los resultados en escenarios reales.

CONFLICTO DE INTERÉS

El autor declara que no existen conflictos de interés de naturaleza personal, académica, institucional, laboral o financiera que hayan influido en el desarrollo, análisis, redacción o presentación de la presente investigación.

REFERENCIAS

- Abidi, S. M. H., Hassan, S. A., Raza, S. M., & Beliaty, 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>
- Amirgaliyev, B., Mussabek, M., Rakhimzhanova, T., et al. (2025). A review of machine learning and deep learning methods for person detection, tracking and identification,

- and face recognition with applications. *Sensors*, 25(5), 1410. <https://doi.org/10.3390/s25051410>
- Coe, J., & Atay, M. (2021). Evaluating impact of race in facial recognition across machine learning and deep learning algorithms. *Computers*, 10(9), 113. <https://doi.org/10.3390/computers10090113>
- El Fadel, N. (2025). Facial recognition algorithms: A systematic literature review. *Journal of Imaging*, 11(2), 58. <https://doi.org/10.3390/jimaging11020058>
- Eman, M., Mahmoud, T. M., Ibrahim, M. M., & Abd El-Hafeez, T. (2023). Innovative hybrid approach for masked face recognition using pretrained mask detection and segmentation, robust PCA, and KNN classifier. *Sensors*, 23(15), 6727. <https://doi.org/10.3390/s23156727>
- Es-Sobhahi, H., Radouane, M., & Nafil, K. (2025). Multimodal biometrics: A review of handcrafted and AI-based fusion approaches. *IET Biometrics*. <https://doi.org/10.1049/bme2/5055434>
- Kansal, I., Khuallar, V., Gupta, G., Gupta, D., et al. (2025). Deep learning-based privacy preserving multimodal biometrics recognition for cross-silo datasets. *Expert Systems*. <https://doi.org/10.1111/exsy.70053>
- Korchenko, O., Tereikovskiy, I., Ziubina, R., Tereikovska, L., et al. (2025). Modular neural network model for biometric authentication of personnel in critical infrastructure facilities based on facial images. *Applied Sciences*, 15(5), 2553. <https://doi.org/10.3390/app15052553>
- Muhammed, A., Marcos, J., & Gonçalves, N. (2026). Towards federated learning for face recognition: A comprehensive review of secure and privacy-preserving techniques and prospective research. *Pattern Analysis and Applications*. <https://doi.org/10.1007/s10044-026-01766-0>
- 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>
- Pann, V., & Lee, H. J. (2022). Effective attention-based mechanism for masked face recognition. *Applied Sciences*, 12(11), 5590. <https://doi.org/10.3390/app12115590>
- Qadir, A., Hassan, B. A., & Khalid, H. (2025). Large-scale deep learning based face recognition utilizing vector database technologies: Current trends, challenges, and solutions. *International Journal of Computers and Applications*. <https://doi.org/10.1080/1206212X.2025.2537892>
- Schlett, T., Rathgeb, C., Henniger, O., Galbally, J., Fierrez, J., & Busch, C. (2022). Face image quality assessment: A literature survey. *ACM Computing Surveys*, 54(10s), 1–49. <https://doi.org/10.1145/3507901>
- Sekhar, J. C., Josephson, P. J., Chinnasamy, A., et al. (2025). Automated face recognition using deep learning technique and center symmetric multivariant local binary pattern. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-024-10447-0>

- Siddiqi, M. H., Khan, K., Khan, R. U., & Alsirhani, A. (2022). Face image analysis using machine learning: A survey on recent trends and applications. *Electronics*, 11(8), 1210. <https://doi.org/10.3390/electronics11081210>
- Terhörst, P., Kolf, J. N., Damer, N., Kirchbuchner, F., & Kuijper, A. (2022). A comprehensive study on face recognition biases beyond demographics. *IEEE Transactions on Technology and Society*, 3(1), 16–30. <https://doi.org/10.1109/TTS.2021.3111823>
- Wang, M., & Deng, W. (2021). Deep face recognition: A survey. *Neurocomputing*, 429, 215–244. <https://doi.org/10.1016/j.neucom.2020.10.081>
- Yucer, S., Tektas, F., Al Moubayed, N., & Breckon, T. P. (2024). Racial bias within face recognition: A survey. *ACM Computing Surveys*. <https://doi.org/10.1145/3705295>
- 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>
- Zhao, R., Zhang, Y., Wang, T., Wen, W., Xiang, Y., et al. (2025). Visual content privacy protection: A survey. *ACM Computing Surveys*. <https://doi.org/10.1145/3708501>