



Sistema de Re-Identificación de personas a través de características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta usando modelos no holísticos a través de técnicas LBP y HOG de visión por computadora y los modelos SVM y CNN de Deep Learning

Jácome Bastidas, Bryan Steeven y Ruilova Rodríguez, Robinson Armando

Departamento de Ciencias de la Computación

Carrera de Ingeniería de Software

Trabajo de Unidad de Integración Curricular, previo a la obtención del Título de Ingeniero de Software

Ing. Jacho Guanoluisa, Nancy del Pilar, (MCL).

22 de agosto del 2023

Latacunga

Reporte de verificación de contenido



Plagiarism and AI Content Detection Report

Tesina_Final_Jacome_Ruilova.pdf

Scan details

Scan time:
August 23th, 2023 at 19:45 UTC

Total Pages:
79

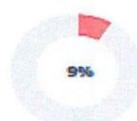
Total Words:
19585

Plagiarism Detection



Types of plagiarism	Words
Identical	0.6% 126
Minor Changes	0.1% 12
Paraphrased	4.6% 899
Omitted Words	15.1% 2951

AI Content Detection



Text coverage	Words
AI text	9% 26055
Human text	91% 62049

[Learn more](#)

i Alerts: (1)

Cross Language: Same Document Language

Submitted language and cross-language text are the same language. No credits were used.

2/5 Severity



🔍 Plagiarism Results: (28)

🌐 **Re-identificación de personas a través de sus caract...** 0.8%
https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=...
 Servicios Personalizados Revista SCIELO Analytics Google Scholar H5M5 ...

📄 **aartolamTFM0723.pdf** 0.8%
<https://openaccess.uoc.edu/bitstream/10609/148477/1/aart...>
 Mis 18 el 28
 Crimen financiero Detección de fraude en tarjetas de crédito aplicando aprendizaje automático Álvaro Artola Moreno Máster Universitario ...

Certified by
Copyleaks

About this report
help.copyleaks.com

copyleaks.com

Ing. Jacho Guanoluisa, Nancy Del Pilar

C. C. 0501963086



Departamento de Ciencias de la Computación

Carrera de Ingeniería de Software

Certificación

Certifico que el trabajo de integración curricular: **“Sistema de Re-Identificación de personas a través de características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta usando modelos no holísticos a través de técnicas LBP y HOG de visión por computadora y los modelos SVM y CNN de Deep Learning”** fue realizado por los señores **Ruilova Rodríguez, Robinson Armando y Jácome Bastidas, Bryan Steeven**, el mismo que cumple con los requisitos legales, teóricos, científicos, técnicos y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, además fue revisado y analizada en su totalidad por la herramienta de prevención y/o verificación de similitud de contenidos; razón por la cual me permito acreditar y autorizar para que se lo sustente públicamente.

Latacunga, 24 de agosto del 2023

Ing. **Jacho Guanoluisa, Nancy Del Pilar**

C. C. 0501963086



Departamento de Ciencias de la Computación

Carrera de Ingeniería de Software

Responsabilidad de Autoría

Nosotros, **Ruilova Rodríguez, Robinson Armando y Jácome Bastidas, Bryan Steeven**, con cédulas de ciudadanía n° 0604529610 y 0550083521, declaramos que el contenido, ideas y criterios del trabajo de integración curricular: **Sistema de Re-Identificación de personas a través de características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta usando modelos no holísticos a través de técnicas LBP y HOG de visión por computadora y los modelos SVM y CNN de Deep Learning** es de nuestra autoría y responsabilidad, cumpliendo con los requisitos legales, teóricos, científicos, técnicos, y metodológicos establecidos por la Universidad de las Fuerzas Armadas ESPE, respetando los derechos intelectuales de terceros y referenciando las citas bibliográficas.

Latacunga, 24 de agosto del 2023

Ruilova Rodríguez, Robinson
Armando
C.C.: 0604529610

Jácome Bastidas, Bryan Steeven
C.C.: 0550083521



Departamento de Ciencias de la Computación

Carrera de Ingeniería de Software

Autorización de Publicación

Nosotros, **Ruilova Rodríguez, Robinson Armando y Jácome Bastidas, Bryan Steeven**, con cédulas de ciudadanía n° 0604529610 y 0550083521, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de integración curricular: **Sistema de Re-Identificación de personas a través de características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta usando modelos no holísticos a través de técnicas LBP y HOG de visión por computadora y los modelos SVM y CNN de Deep Learning** en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra responsabilidad

Latacunga, 24 de agosto del 2023

**Ruilova Rodríguez, Robinson
Armando**
C.C.: 0604529610

Jácome Bastidas, Bryan Steeven
C.C.: 0550083521

Dedicatoria

Esa tesis está dedicada a cada persona que influyó, apoyo, creyó en mí, en especial para mi madre que siempre estuvo allí desde el día que me dieron la noticia que entre a esta universidad hasta el día de hoy que terminó una etapa de mi vida.

Mis hermanas y mi padre, quienes han estado en los buenos y en los malos momentos, brindándome su apoyo, cariño, algún consejo cuando más lo he necesitado.

A mis mascotas que fueron mis más fieles acompañantes en cada día que pase estudiando hasta el amanecer y me recibían en mi cuarto de foráneo o en mi casa. A cada uno de ellos, muchas gracias por acompañarme hasta lograr el éxito académico.

Ruilova Rodríguez, Robinson Armando

Dedicatoria

Con profunda gratitud y un sincero afecto, dedico este proyecto a todas las personas que me apoyaron en este camino, a mis padres cuyo amor y apoyo constante fueron mi mayor motivación para salir adelante y superar todos los desafíos, a mis queridos hermanos que siempre estuvieron dándome esperanza y ánimos, su aliento constante ha sido mi inspiración para perseguir este logro. Así mismo, mi dedicatoria se extiende a mis amigos que con su presencia y colaboración. Este proyecto es resultado de todo el esfuerzo, amor y apoyo incondicional de todas las personas que me apoyaron.

Jácome Bastidas, Bryan Steeven

Agradecimiento

Quiero expresar mi más profundo agradecimiento a cada persona que formó parte de esta etapa de mi vida y han sido parte del desarrollo de este proyecto.

En primer lugar, quiero agradecer a mi madre que me brindó inspiración, motivación y apoyo incondicional desde el primer día que inicie mis estudios universitarios. A mi padre que me supo dar consejos valiosos que me fortalecieron en días intranquilos.

Asimismo, quiero agradecer a mis hermanas, amigos y mi enamorada Nayeli, quienes me dieron su amor, apoyo, comprensión y conocimiento.

También quiero agradecer a mi compañero de tesis Brayan Jácome quien fue parte importante en la realización de este proyecto, brindándome su conocimiento para luego plasmarlo en cada sección de este.

Finalmente, agradezco a mi tutora de tesis, la Msc. Nancy Jacho, quien me supo guiar, aconsejar, brindar su conocimiento y asesoramiento para culminar de manera exitosa la realización de este proyecto.

Sin su apoyo nada de esto hubiera sido posible, solo me queda decir que este logro también es suyo.

Ruilova Rodríguez, Robinson Armando

Agradecimiento

Quiero expresar mi agradecimiento a Dios por haberme otorgado salud, fortaleza y sabiduría a lo largo de toda mi vida.

Asimismo, deseo expresar mi sincero agradecimiento a mis padres, cuyo apoyo inquebrantable y amor incondicional han sido mi fuente de inspiración constante para avanzar. Su guía y dedicación han impregnado en mí valores y principios que han moldeado mi carácter y me han permitido superar cualquier adversidad.

Finalmente, expreso mi agradecimiento a mis tutores de tesis Msc. Nancy Jacho, por todo su apoyo y orientación en el desarrollo de este proyecto, el aporte de sus conocimientos ha sido fundamentales para la mejora del proyecto y para mi formación personal y académica.

Jácome Bastidas, Bryan Steeven

ÍNDICE DE CONTENIDO

Carátula	1
Reporte de verificación de contenido.....	2
Certificado	3
Responsabilidad de Auditoria.....	4
Autorización de Publicación	5
Dedicatoria	6
Dedicatoria	7
Agradecimiento.....	8
Agradecimiento.....	9
Índice de contenido	10
Índice de tablas	13
Índice de figuras	15
Resumen.....	17
Abstract	18
Capítulo I: Introducción.....	19
Propósito y contextualización del tema.....	19
Justificación del interés de la investigación	20
Objetivos	21
<i>Objetivo General:</i>	21
<i>Objetivos Específicos:</i>	21
Metodología	22

Capítulo II: Marco teórico	24
Características Biométricas y Soft-Biométricas	24
<i>Características Biométricas</i>	25
<i>Características Soft-Biométricas</i>	26
Técnicas de Visión por Computadora.....	27
<i>Local Binary Pattern (LBP)</i>	29
<i>Histograma de Gradiente Ordenado (HOG)</i>	30
Técnicas de Machine Learning.....	31
<i>Convolutional Neural Network (CNN)</i>	32
<i>Support vector machine (SVM)</i>	33
Técnicas No Holísticas.....	35
Scrum	36
Yolo	37
Métricas de Evaluación	38
Capítulo III: Implementación del Sistema.....	41
Análisis y diseño del sistema	41
<i>Historias de Usuario</i>	42
<i>Product Backlog</i>	43
<i>Escenario para la implementación</i>	44
<i>Herramientas de software para el desarrollo</i>	45
<i>Componentes hardware para el desarrollo</i>	47
Definición e implementación de modelos de identificación facial, textura y color de la vestimenta	47

<i>Sprint 01: Dataset y algoritmo de identificación facial</i>	48
<i>Sprint 02: Desarrollo e implementación de modelos y/o algoritmos de identificación facial mediante técnicas de Visión por Computadora.....</i>	50
<i>Sprint 03: Creación de dataset y algoritmo de identificación de características Soft-biométricas.....</i>	57
<i>Sprint 04: Desarrollo e implementación de modelos y/o algoritmos de identificación de personas mediante características Soft-biométricas.....</i>	59
<i>Sprint 05: Desarrollo e implementación de un sistema de Re-ID de personas mediante sus características biométricas y Soft-biométricas...</i>	70
Capítulo IV: Definición y Aplicación de Métricas de Evaluación	76
Marco de Evaluación.....	76
Definición de Métricas de Evaluación.....	77
Aplicación de Métricas de Evaluación	77
Capitulo V: Conclusiones.....	98
Conclusiones	98
Bibliografía	99
Anexos.....	104

ÍNDICE DE TABLAS

Tabla 1 <i>Métricas de Evaluación</i>	39
Tabla 2 <i>Valores de la Matriz de Confusión</i>	39
Tabla 3 <i>Team Scrum</i>	42
Tabla 4 <i>Historias de Usuario</i>	42
Tabla 5 <i>Product Backlog</i>	44
Tabla 6 <i>Herramientas usadas para la creación del sistema</i>	45
Tabla 7 <i>Herramientas hardware usadas para la creación del sistema</i>	47
Tabla 8 <i>Historia de Usuario H.U.01</i>	48
Tabla 9 <i>Sprint Backlog 01</i>	49
Tabla 10 <i>Historia de Usuario H.U.02</i>	50
Tabla 11 <i>Sprint Backlog 02</i>	51
Tabla 12 <i>Algoritmo LBP para identificación facial</i>	52
Tabla 13 <i>Resultados de las métricas de evaluación</i>	56
Tabla 14 <i>Historia de Usuario H.U.03</i>	57
Tabla 15 <i>Sprint Backlog 03</i>	58
Tabla 16 <i>Historia de Usuario H.U.04</i>	59
Tabla 17 <i>Sprint Backlog 04</i>	60
Tabla 18 <i>Algoritmo LBP para identificación mediante la silueta corporal</i>	61
Tabla 19 <i>Algoritmo HOG para identificación de personas mediante la textura de la vestimenta</i>	64
Tabla 20 <i>Algoritmo HOG para identificación de personas mediante el color de la vestimenta</i>	65
Tabla 21 <i>Resultados de las métricas de evaluación</i>	69
Tabla 22 <i>Historia de Usuario H.U.05</i>	70
Tabla 23 <i>Sprint Backlog 05</i>	71
Tabla 24 <i>Algoritmo de identificación de personas</i>	72
Tabla 25 <i>Algoritmo de Re-ID de personas</i>	73

Tabla 26 <i>Resultados de la Métrica de Evaluación Accuracy</i>	81
Tabla 27 <i>Resultados al aplicar la Métricas de Evaluación al sistema de Re-ID facial</i>	81
Tabla 28 <i>Resultados obtenidos de las pruebas realizadas al sistema de Re-ID facial dando una predicción de Identificado en cada recorrido</i>	82
Tabla 29 <i>Resultados de la Métrica de Evaluación Accuracy</i>	85
Tabla 30 <i>Resultados al aplicar las Métricas de Evaluación el sistema de Re-ID mediante la silueta corporal</i>	85
Tabla 31 <i>Resultados obtenidos de las pruebas realizadas al sistema de Re-ID mediante la silueta corporal con una predicción de Identificado en cada recorrido</i>	86
Tabla 32 <i>Resultados de la Métrica de Evaluación Accuracy</i>	89
Tabla 33 <i>Resultados del sistema de Re-Identificación mediante la textura de la vestimenta</i>	90
Tabla 34 <i>Resultados obtenidos de las pruebas realizadas al sistema de Re-ID mediante la textura de la vestimenta con una predicción de Identificado en cada recorrido</i>	91
Tabla 35 <i>Resultados de la métrica de evaluación Accuracy</i>	93
Tabla 36 <i>Resultados al aplicar las métricas de evaluación al sistema de Re-Identificación mediante el color de la vestimenta</i>	94
Tabla 37 <i>Resultados obtenidos de las pruebas realizadas al sistema de Re-ID mediante el color de la vestimenta con una predicción de Identificado en cada recorrido</i>	95
Tabla 38 <i>Resultados obtenidos de las pruebas realizadas al sistema de Re-ID a través de la combinación de las características con una predicción de Identificado en cada recorrido</i>	96

ÍNDICE DE FIGURAS

Figura 1 <i>LBP (Local Binary Pattern)</i>	29
Figura 2 <i>HOG (Histograma de Gradiente Ordenado)</i>	31
Figura 3 <i>CNN (Convolution Neural Network)</i>	33
Figura 4 <i>SVM (Support Vector Machine)</i>	34
Figura 5 <i>Matriz de confusión</i>	40
Figura 6 <i>Ambiente controlado</i>	44
Figura 7 <i>Ubicación de las cámaras</i>	45
Figura 8 <i>Carpetas creadas para el almacenamiento del dataset de características faciales</i>	50
Figura 9 <i>Proceso de la captura de rostros</i>	53
Figura 10 <i>Identificación facial de la persona</i>	54
Figura 11 <i>Matriz de Confusión de la clase Ángel Video 1</i>	55
Figura 12 <i>Matriz de Confusión de la clase Ángel Video 2</i>	55
Figura 13 <i>Matriz de Confusión de la clase Ángel Video 3</i>	56
Figura 14 <i>Carpetas creadas para el almacenamiento del dataset de características Soft-biométricas</i>	59
Figura 15 <i>Proceso de captura de la silueta corporal</i>	66
Figura 16 <i>Proceso de captura de la textura de la vestimenta</i>	66
Figura 17 <i>Proceso de captura del color de la vestimenta</i>	67
Figura 18 <i>Identificación frontal de la persona mediante sus características Soft-biométricas</i>	67
Figura 19 <i>Matriz de Confusión de la clase Ángel en el primer recorrido</i>	68
Figura 20 <i>Matriz de Confusión de la clase Ángel en el segundo recorrido</i>	68
Figura 21 <i>Matriz de Confusión de la clase Ángel en el tercer recorrido</i>	69
Figura 22 <i>Re-ID de la persona mediante sus características Soft-biométrica</i>	75
Figura 23 <i>Multiprocesamiento</i>	78
Figura 24 <i>Re-Identificación facial con el modelo entrenado</i>	78

Figura 25 <i>Re-Identificación mediante las características Soft-biométricas con el modelo entrenado</i>	79
Figura 26 <i>Re-ID facial de la clase Alex.....</i>	79
Figura 27 <i>Matriz de Confusión de la Re-ID facial en el primer recorrido.....</i>	80
Figura 28 <i>Matriz de Confusión de la Re-ID facial en el segundo recorrido</i>	80
Figura 29 <i>Matriz de Confusión de la Re-ID facial en el tercer recorrido.....</i>	80
Figura 30 <i>Re-ID mediante la silueta corporal</i>	83
Figura 31 <i>Matriz de Confusión de la Re-ID mediante la silueta corporal.....</i>	84
Figura 32 <i>Matriz de Confusión de la Re-ID mediante la silueta corporal.....</i>	84
Figura 33 <i>Matriz de Confusión de la Re-ID mediante la silueta corporal.....</i>	85
Figura 34 <i>Re-Identificación mediante la textura de la vestimenta.....</i>	88
Figura 35 <i>Matriz de Confusión de la Re-ID mediante la textura de la vestimenta.....</i>	88
Figura 36 <i>Matriz de Confusión de la Re-ID mediante la textura de la vestimenta.....</i>	89
Figura 37 <i>Matriz de Confusión de la Re-ID mediante la textura de la vestimenta.....</i>	89
Figura 38 <i>Re-Identificación mediante el color de la vestimenta.....</i>	92
Figura 39 <i>Matriz de Confusión de la Re-Identificación mediante el color de la vestimenta .</i>	92
Figura 40 <i>Matriz de Confusión de la Re-Identificación mediante el color de la vestimenta .</i>	93
Figura 41 <i>Matriz de Confusión de la Re-Identificación mediante el color de la vestimenta .</i>	93

Resumen

La realización de este proyecto está enfocada en desarrollar un sistema de Re-Identificación de personas. El sistema se basa en el análisis de características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta. El sistema emplea un enfoque de análisis no holístico a través de técnicas de visión por computadora como LBP (Local Binary Patterns) y HOG (Histogram of Oriented Gradients), así como modelos de Deep Learning como SVM (Support Vector Machines) y CNN (Convolutional Neural Networks). Para llevar a cabo el reconocimiento facial y de la silueta corporal se aplicó una combinación de características LBP con el clasificador CNN, mientras que la detección de la textura y color de la vestimenta se la realizó mediante la combinación de características HOG con el clasificador SVM. Los datos se recogieron en los pasillos de la Universidad de las Fuerzas Armadas "ESPE" sede Latacunga, que ofrecen condiciones óptimas de iluminación, un mínimo de obstáculos y posiciones estáticas de cámara de alta resolución para minimizar cualquier tipo de ruido en las imágenes. Para que el sistema funcione en tiempo real, se utilizaron multiprocesadores. El primer procesador se utilizó para realizar la tarea de Re-Identificación por reconocimiento facial; del segundo al sexto realizaron la tarea de Re-Identificación de la persona basándose en características Soft-biométricas como la silueta corporal, la textura y color de la vestimenta, dando como resultado un porcentaje de predicción para el color de la ropa de un 84,86%, 33,55% para la silueta corporal, 89,76% para la textura y 92,96% para el modelo de reconocimiento facial.

Palabras clave: Re-Identificación de personas, características biométricas y Soft-biométricas, Machine Learning, Deep Learning, Visión por Computadora.

Abstract

The realization of this project is focused on developing a system of Re-Identification of people. The system is based on the analysis of biometric features: facial and Soft-biometric: body silhouette, texture and color of clothing. The system employs a non-holistic analysis approach through computer vision techniques such as LBP (Local Binary Patterns) and CNN (Convolutional Neural Networks), and HOG (Histogram of Oriented Gradients). The detection of garment texture and color was carried out by combining HOG features with the SVM classifier, while face and body silhouette recognition was accomplished by integrating LBP features with the CNN classifier. The University of the Armed Forces "ESPE" Latacunga branch's hallways, which provide ideal lighting conditions, few obstructions, and high-resolution static camera locations to reduce picture noise, were used to capture the data. Multiprocessors were employed to make the system run in real time. The first processor was used to carry out the task of re-identification using facial recognition; the second through the sixth carried out the task using soft-biometric features like body silhouette, texture, and clothing color. As a result, the prediction percentage for clothing color was 84.86%, 33.55% for body silhouette, 89.76% for texture, and 92.96% for the facial recognition model.

Key words: Person re-identification, biometric and soft-biometric features, Machine Learning, Deep Learning, Computer Vision.

Capítulo I

Introducción

Propósito y contextualización del tema

En la actualidad, la videovigilancia se ha generalizado tanto en el ámbito público como en el privado en diversos entornos, como universidades, bibliotecas, teatros, hospitales, centros comerciales y edificios residenciales (Armstrong & Norris, 2020). Para proteger la seguridad de las personas, la videovigilancia ha dejado de ser un lujo para convertirse en una necesidad.

Con el paso del tiempo, se ha observado que esta tecnología ha ayudado a prevenir catástrofes en diversas naciones, como atentados, secuestros o robos, gracias al análisis de las grabaciones que ha permitido detectar o prevenir dichos problemas en la sociedad contemporánea.

Muchos países cuentan con cámaras, y su presencia las ha convertido en un componente esencial de la infraestructura de seguridad (Armstrong & Norris, 2020).

Por ejemplo, en diciembre de 2017, China destacó por tener la red de videovigilancia más grande y sofisticada del mundo. Dado el número de transmisiones de vídeo que se producen, es necesario analizarlas en tiempo real para prevenir y mitigar riesgos como accidentes, delitos, terrorismo u otras cuestiones acuciantes para la sociedad contemporánea (Regazzoni et al., 2010).

La capacidad de caracterizar la actividad y el comportamiento de las personas en una escena específica a largo plazo es posible gracias al análisis de vídeo. Este análisis es esencial para llevar a cabo tareas que implican la videovigilancia inteligente, como el seguimiento de personas sospechosas o de sucesos sospechosos para avisar a tiempo al personal de seguridad y lograr una vigilancia más proactiva (Mantini & Shah, 2014).

La automatización del análisis facilita la identificación de objetos en movimiento y el seguimiento de su trayectoria, lo que constituye la base para extraer información crucial

sobre los objetos a partir de secuencias de imágenes en sistemas de vigilancia (Alejandra, 2016).

La Re-Identificación es una tarea clave de los sistemas de videovigilancia que implica reconocer con precisión una instancia específica de un objeto a lo largo del tiempo utilizando numerosas cámaras y puntos (Mantini & Shah, 2014).

Con el paso del tiempo, avanzamos hacia una sociedad en la que las cámaras son omnipresentes, impulsadas por su bajo coste de implantación y la enorme cantidad de información que pueden proporcionar.

La Re-Identificación de personas presenta retos que pueden superarse utilizando técnicas y modelos basados en la visión por ordenador, el aprendizaje automático y el aprendizaje profundo (Hermans et al., 2017).

Estas características pueden dividirse en dos grupos: características biométricas, como el tamaño de la cabeza, y características biométricas blandas, como la altura, el anclaje, la textura y el color de la ropa (estas últimas son características complementarias) (Jain et al., 2004).

Además, existen enfoques alternativos que pretenden mejorar la precisión y robustez de los sistemas Re-ID. Entre ellos se encuentran los modelos no holísticos, que consideran a una persona como un conjunto de partes. Según los requisitos únicos de cada aplicación, el número de partes puede cambiar (Hermans et al., 2017).

A la luz de lo anterior, el objetivo principal de este proyecto de investigación es desarrollar e implementar un sistema de Re-Identificación de individuos utilizando características biométricas blandas, como el tono de la piel, la textura de la ropa y los rasgos faciales, con el fin de aumentar la precisión de la identificación y la Re-Identificación en sistemas de cámaras de circuito cerrado.

Justificación del interés de la investigación

El mundo actual ha hecho que los sistemas de videovigilancia sean esenciales para la seguridad de las personas, y su principal objetivo es disminuir los riesgos asociados a aspectos como el control de acceso y la vigilancia local y corporativa (Alejandra, 2016).

Dentro de los sistemas inteligentes de videovigilancia, la Re-Identificación es un proceso crucial. Algunos sistemas de videovigilancia combinan características biométricas (como el rostro) y biométricas blandas (como el silencio corporal) para mejorar la identificación de personas, incluso en entornos difíciles (Chen et al., 2021).

El objetivo principal es seguir a las personas para saber por dónde llegan y de dónde parten. Cuando se puede ver el pecho de una persona, su identidad se determina por sus características faciales; si no, se determina por sus características biométricas blandas.

Este proyecto de investigación pretende desarrollar varios modelos de Re-ID de personas combinando descriptores y clasificadores como LBP, HOG y SVM, CNN con el fin de determinar cuál de estas combinaciones mejora la precisión de predicción en la identificación de personas.

El objetivo principal de este proyecto es desarrollar e implantar un sistema de Re-Identificación de personas por sus rasgos faciales, lenguaje corporal, textura y color de la ropa. Para lograr una mayor precisión en la predicción, se utilizarán modelos no históricos. Este sistema también servirá de guía para futuros proyectos orientados a la seguridad.

Objetivos

Objetivo General:

Desarrollar un sistema de Re-Identificación de personas a través de características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta usando modelos no holísticos, a través de técnicas LBP y HOG de Visión por Computadora y los modelos SVM y CNN en Deep Learning.

Objetivos Específicos:

- Conocer y estudiar sobre características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta, aplicando técnicas de Visión por Computadora como LBP y HOG y modelos y/o algoritmos de Machine Learning como SVM y CNN que son utilizadas en la Re-Identificación de personas.

- Implementar un sistema de Re-Identificación de personas a través de las características Soft-biométricas faciales y Soft-biométricas: la silueta, la textura y el color de la vestimenta, utilizando algoritmos LBP y HOG de Visión por Computadora y/o modelos SVM y CNN en Machine Learning.
- Validar los resultados, analizar errores y ajustar los modelos del sistema de videovigilancia.
- Documentar la tesina de grado para evidenciar el proceso realizado en el sistema de Re-Identificación de personas.

Metodología

Para alcanzar los objetivos propuestos en este proyecto, se desarrollará e implementará un sistema de Re-Identificación de personas a través de características biométricas y Soft-biométricas.

Primero se llevará a cabo una revisión de la literatura respectiva a la Re-Identificación de personas mediante características biométricas faciales y Soft-biométricas como la silueta corporal, textura y color de la vestimenta. Esta revisión se realizará de publicaciones científicas de las librerías digitales: Scopus, ISI Web e IEEE Xplore, con el objetivo de combinar conocimientos relacionados con la Re-ID de personas.

A continuación, se recopilan imágenes, vídeos y filmaciones de personas para crear un conjunto de datos. Estos datos se utilizan para extraer características biométricas como rasgos faciales y Soft-biométricas como siluetas corporales, textura y color de la vestimenta. Otro conjunto de datos se genera a partir de vídeos captados por cámaras de circuito cerrado no superpuestas.

Las características biométricas y Soft-biométricas se extraen de ambos conjuntos de datos y se utilizan para entrenar varios modelos y algoritmos de aprendizaje automático como SVM, LBP, HOG y CNN.

Una vez adquiridos estos conocimientos y el dataset necesario, se procederá a la implementación de modelos de Re-Identificación de personas. Para ello, se utiliza un

sistema de dos cámaras no superpuestas, la primera identificará a la persona mediante reconocimiento facial y generará modelos basados en características biométricas y/o Soft-biométricas en tiempo real.

Por otro lado, la segunda cámara se encargará de capturar la parte posterior de la persona y mediante el uso de modelos de Deep Learning previamente entrenados, se Re-Identificará a la persona.

La integración de características Soft-biométricas en los modelos implementados para la Re-Identificación de personas mejora la precisión, robustez y rendimiento de los sistemas de Re-Identificación en comparación con el uso de estas características por separado (Mantini & Shah, 2015).

Posteriormente, se evaluará al sistema de Re-Identificación aplicando métricas de evaluación. Además, se llevarán a cabo variaciones en los hiperparámetros de los modelos seleccionados con el fin de mejorar el proceso de aprendizaje. Estas variaciones se realizarán con el objetivo de comparar y analizar las predicciones obtenidas, buscando así optimizar el rendimiento de la Re-ID.

Los hiperparámetros se establecen antes del entrenamiento y afectan el comportamiento y el rendimiento del modelo. Controlan aspectos como la complejidad del modelo, la velocidad de aprendizaje, la regularización y la tolerancia al error (Heaton, 2018).

Además, se emplearán técnicas no holísticas que permiten dividir el cuerpo de la persona, generando una ventana global que contiene una serie de subventanas internas. Esta estrategia tiene como finalidad reducir el número de comparaciones necesarias y disminuir el tiempo requerido para realizar la Re-ID. De esta manera, se busca mejorar el rendimiento general de la Re-ID en la identificación de personas.

Capítulo II

Marco teórico

En esta sección se exponen los conceptos y definiciones relacionados con un sistema de Re-Identificación de personas.

La Re-Identificación de personas se basa en la extracción y comparación de características visuales de una persona, como la apariencia física, la textura de la ropa y los patrones de movimiento (M. Li et al., 2018). Este proceso utiliza técnicas de aprendizaje automático (como el aprendizaje profundo), para mejorar la precisión y robustez de los sistemas de Re-Identificación (Zheng et al., 2016).

Primero, se exponen las características biométricas y Soft-biométricas empleadas en el sistema propuesto de Re-Identificación de personas. Asimismo, exploraremos diferentes técnicas en Visión por Computadora junto con los modelos y algoritmos empleados en Machine Learning.

A continuación, se discuten los modelos no holísticos utilizados en los sistemas de Re-Identificación de personas. Por último, se presentan las métricas de evaluación que se utilizarán para valorar el rendimiento del sistema y la metodología empleada para su desarrollo.

Características Biométricas y Soft-Biométricas

Los identificadores biométricos son características únicas de una persona que pueden utilizarse para identificarla (Jain et al., 2004). Los ojos dactilares, el iris y la graja son las características biométricas más relevantes.

Las características biométricas blandas son rasgos que no son exclusivos de una persona pero que pueden utilizarse para identificarla con precisión (Jain et al., 2004). Ejemplos de biometría blanda son la altura, el peso, la vestimenta y el peinado.

Las características biométricas y blandas desempeñan un papel vital en los sistemas de Re-Identificación de personas (Jain et al., 2004). Estas características van desde los

rasgos físicos y puramente físicos hasta los rasgos de comportamiento que son esenciales para identificar y reconocer a las personas (Akagündüz, 2015).

Características Biométricas

Las características físicas que distinguen a cada ser humano, como la cresta dactilar, el iris, el rostro, el ADN, la voz, etc., se conocen como características biométricas. Estas características desempeñan un papel crucial en los sistemas de Re-Identificación de personas, ya que suelen ser estables y pueden utilizarse para identificar con precisión a los individuos (Jain et al., 2004).

La huella dactilar es una característica biométrica única de cada persona. Las huellas dactilares se desarrollan en el útero y permanecen inalteradas durante toda la vida. Las huellas dactilares pueden utilizarse para la identificación en diversos contextos, como la seguridad pública, las investigaciones criminales y el comercio centrado en las minorías (Jain et al., 2004).

Otra característica biométrica única es la imagen del iris. El iris es el disco de color que rodea la pupila del ojo. El iris tiene una serie de características únicas, como el patrón, la forma y el color de los anillos, que pueden utilizarse para identificar a un individuo (Jalilian et al., 2020).

La característica biométrica facial se utiliza ampliamente en los sistemas de Re-Identificación de personas porque permite reconocer y rastrear individuos en diversas cámaras y entornos (Zhao et al., 2003). Esta característica tiene muchas ventajas, entre ellas su naturaleza no intrusiva (porque puede extraerse a distancia utilizando una cámara) y su amplia disponibilidad en conjuntos de imágenes de vigilancia.

Es posible alcanzar niveles extremadamente altos de precisión y solidez en la Re-ID de personas en entornos reales de videovigilancia utilizando técnicas de extracción y comparación de rasgos faciales.

La característica biométrica facial se utiliza ampliamente en los sistemas de Re-Identificación de personas porque permite reconocer y rastrear individuos en diversas cámaras y entornos (Zhao et al., 2003). Esta característica tiene muchas ventajas, entre

ellas su naturaleza no intrusiva (porque puede extraerse a distancia utilizando una cámara) y su amplia disponibilidad en conjuntos de imágenes de vigilancia.

Es posible alcanzar niveles extremadamente altos de precisión y solidez en la Re-ID de personas en entornos reales de videovigilancia utilizando técnicas de extracción y comparación de rasgos faciales. Por ejemplo, un sistema de Re-ID que utilice la biometría puede reconocer con mayor precisión a una persona, aunque la imagen esté distorsionada o sea de mala calidad (Alejandra, 2016).

La biometría es una potente herramienta que puede utilizarse para mejorar el rendimiento de un sistema de Re-ID de personas. Sin embargo, no se han abordado cuestiones como la privacidad y la ética del uso de la biometría.

Características Soft-Biométricas

Las características Soft-Biométricas, también conocidas como características blandas, se han vuelto cada vez más importantes en la identificación de personas (Carrillo-Medina et al., 2022). Estas características no son exclusivamente físicas e incluyen información como el color de la vestimenta y la textura, el estilo de caminar, la relación de aspecto, la silueta, etc. Las características Soft-Biométricas pueden complementar los sistemas tradicionales de Re-ID de características biométricas en persona (Gavilanes et al., 2022).

Uno de los enfoques utilizados en la Re-ID consiste en el análisis de la silueta corporal, la silueta corporal se refiere al contorno límite de la forma de la persona, y es una representación fundamental de sus propiedades (Akagündüz, 2015).

Esta característica Soft-biométrica se puede extraer incluso si la persona esta parcialmente ocluida o si la calidad de imagen o video es baja. Esto lo convierte en una característica valiosa para Re-ID de personas en entornos difíciles (Masullo et al., 2020).

Otro enfoque utilizado en la Re-ID de personas es el análisis de la textura de la ropa. La textura de la ropa se refiere a los patrones repetitivos o estructuras visuales en una imagen que se pueden utilizar para extraer información y características sobre la persona que usa la ropa (Alejandra, 2016).

Existen diferentes métodos para extraer, analizar y describir la textura en una imagen, como la aplicación de histogramas de gradientes orientados (HOG), descriptores de patrones locales (LBP) o el uso de matrices de co-ocurrencia (Alejandra, 2016).

Los identificadores biométricos blandos son identificadores que no son únicos, pero permiten un alto grado de precisión. Los identificadores biométricos blandos más comunes son la altura, el peso, la ropa y el pelo (Alejandra, 2016).

La altura es una característica Soft-biométrica que puede utilizarse para identificar a las personas. La estatura de una persona es relativamente constante y no cambia mucho con el tiempo. La estatura puede utilizarse para identificar a individuos en diversas aplicaciones, como la seguridad pública, la investigación criminal y el comercio minorista (Schumann & Monari, 2014).

Otra característica que se aplica en Re-ID de personas es el color de la vestimenta. El color de la vestimenta proporciona característica visual que facilita la detección de una persona incluso si la persona cambia de apariencia física. Sin embargo, su uso debe considerarse en conjunto con otras características para lograr un sistema de identificación sólido y preciso (Schumann & Monari, 2014).

La combinación de silueta corporal, textura y color de la vestimenta puede proporcionar una representación más completa y discriminatoria de una persona que cualquiera de estas características por sí solas. Esto se debe a que cada característica proporciona información diferente sobre una persona, y al combinarlas, los sistemas Re-ID pueden crear una representación más robusta e informativa que es más probable que pueda distinguir entre dos personas diferentes, incluso en condiciones difíciles (Chen et al., 2021).

Técnicas de Visión por Computadora

La visión por computadora es un campo dentro de la inteligencia artificial que permite a los ordenadores ver, interpretar y comprender el mundo que les rodea (Szeliski, 2022). Lo hace analizando imágenes y vídeos, igual que hace el sistema visual humano.

El preprocesamiento de imágenes es un paso inicial en el análisis de visión por computadora, que implica la corrección de imperfecciones y la mejora de la calidad de las imágenes. Esto puede incluir operaciones como la reducción de ruido, la normalización de la iluminación, la corrección de distorsiones y la segmentación inicial (Gonzalez et al., 2009).

La segmentación de imágenes se utiliza para dividir una imagen en regiones significativas, permitiendo separar objetos del fondo y facilitar el análisis posterior. Se pueden aplicar técnicas como la segmentación basada en umbrales, la segmentación por regiones y la segmentación basada en bordes (Szeliski, 2022).

La detección y reconocimiento de objetos son técnicas que se centran en identificar y localizar objetos específicos dentro de las imágenes, se utilizan métodos como la detección de características, la clasificación mediante aprendizaje automático (por ejemplo, SVM) y el uso de redes neuronales convolucionales (CNN) (Girshick et al., 2014).

El seguimiento de objetos implica rastrear la posición y el movimiento de un objeto a través de una secuencia de imágenes o video (Schumann & Monari, 2014). Se pueden emplear técnicas como el filtrado de Kalman, el flujo óptico y los descriptores de características locales para mantener un seguimiento preciso (Szeliski, 2022).

El reconocimiento facial es una técnica dentro de la visión por computadora, que se enfoca en identificar y reconocer rostros humanos en imágenes o videos (S. Z. Li & Jain, 2011). Se utilizan algoritmos de detección de rostros, extracción de características faciales y clasificación para lograr un reconocimiento preciso (Turk & Pentland, 1991).

En el reconocimiento facial, se emplean descriptores de características de imágenes para detectar, identificar y reconocer rostros humanos (Turk & Pentland, 1991). Dos descriptores de características ampliamente utilizados en esta área son los Patrones Binarios Locales (LBP) y los Histogramas de Gradientes Orientados (HOG). Estos descriptores permiten capturar y representar de manera efectiva las características distintivas de los rostros (Pozuelo Fernández, 2016).

Local Binary Pattern (LBP)

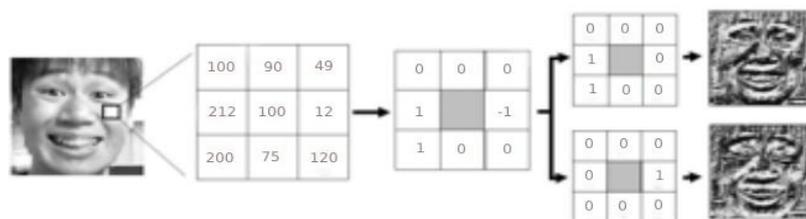
El descriptor Local Binary Patterns (LBP) ha demostrado ser una opción destacada para la caracterización de imágenes al analizar las texturas y reconocer patrones, su rendimiento y eficacia han sido ampliamente probados, lo que lo convierte en una elección destacada (Arboleda & Guerrero, 2015).

La aplicación del LBP ha supuesto avances significativos en el campo de la identificación facial, demostrando su eficacia en diversas aplicaciones como la Re-ID de personas. Estos resultados destacados confirman su valioso potencial en diversas áreas de Visión por Computadora (Ojala et al., 1996).

El método LBP se aplica a imágenes en escala de grises y opera mediante el cálculo de un valor binario para cada píxel de la imagen, basado en la comparación de las intensidades de los píxeles vecinos, si la intensidad del píxel vecino es mayor o igual que la intensidad del píxel central, se le asigna el valor de 1, caso contrario, se le asigna un valor de 0 (Arboleda & Guerrero, 2015).

Figura 1

LBP (Local Binary Pattern)



Nota. Ejemplo del cálculo de patrones binarios locales. Tomado de (Merchán et al., 2014).

El proceso de cálculo de LBP implica, además, la concatenación de los histogramas calculados de todas las celdas para generar un vector de características final que representa la textura de la imagen (Merchán et al., 2014). Este vector resultante es útil para entrenar modelos de aprendizaje automático, permitiendo la extracción y representación efectiva de la información textural de la imagen (Ojala et al., 1996).

LBP es un método altamente eficiente y de bajo costo computacional en términos de su cálculo. Su simplicidad no compromete su efectividad, ya que es robusto frente a

variaciones en la iluminación, lo que lo convierte en una opción adecuada para aplicaciones en entornos del mundo real (Arboleda & Guerrero, 2015).

Sin embargo, es importante tener en cuenta que LBP también tiene algunas limitaciones. Por ejemplo, puede ser sensible a cambios en la escala de la imagen y a ciertos tipos de ruido, lo que puede afectar su desempeño en ciertos escenarios específicos (Arboleda & Guerrero, 2015).

Histograma de Gradiente Ordenado (HOG)

El Histograma de Gradiente Orientado (HOG) es un descriptor de características ampliamente utilizado en Visión por Computadora y procesamiento de imágenes con el propósito de detectar objetos (Dalal & Triggs, 2005).

Se fundamenta en el cálculo y representación de gradientes locales en una imagen, capturando información sobre la dirección y magnitud de los cambios de intensidad en diferentes regiones.

El proceso de cálculo del Histograma de Gradiente Orientado (HOG) comienza dividiendo la imagen en celdas más pequeñas y calculando los gradientes de cada píxel en cada celda utilizando operadores como el operador de Sobel. Estos gradientes representan tanto la dirección como la magnitud de los cambios de intensidad presentes en la imagen (Zeng et al., 2010).

A continuación, se procede al cálculo del histograma de orientaciones de los gradientes dentro de cada celda, este histograma registra la frecuencia de aparición de diferentes direcciones de gradientes en la celda, capturando así información sobre la textura y los patrones presentes en esa región específica de la imagen (Chen et al., 2021).

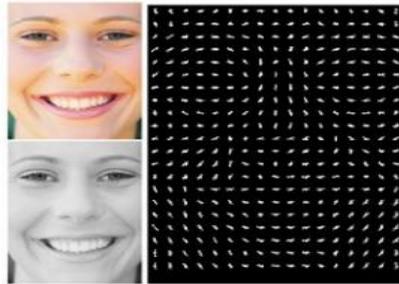
Para mejorar la representación y capturar de manera más efectiva las características locales, las celdas se agrupan en bloques. Dentro de cada bloque, se concatenan los histogramas de las celdas vecinas, generando un vector de características que captura información contextual más completa y robusta de la imagen (Chen et al., 2021).

Además, los histogramas de las celdas vecinas se agrupan en bloques y se normalizan para tener en cuenta las variaciones de iluminación y contraste. Por último, los

bloques normalizados se concatenan para formar el vector de características HOG, que representa la imagen original y encapsula las características distintivas de la misma (Chen et al., 2021).

Figura 2

HOG (Histograma de Gradiente Ordenado)



Nota. Ejemplo de cálculo de gradiente en esquema HOG. Tomado de (Merchán et al., 2014).

El descriptor HOG es ampliamente valorado en la Re-ID de personas debido a su capacidad para obtener características que son útiles para capturar información sobre la forma y textura de los objetos de una imagen (Chen et al., 2021).

Además, el descriptor HOG es ampliamente utilizado en sistemas de detección de objetos basados en aprendizaje profundo, lo que destaca su popularidad y versatilidad en múltiples aplicaciones (Zeng et al., 2010).

Técnicas de Machine Learning

El Machine Learning es un campo de estudio que se centra en construir algoritmos y modelos que permitan a los ordenadores extraer conocimientos y tomar decisiones fundamentadas en datos. Estos algoritmos y modelos se basan en técnicas estadísticas y de análisis de datos para identificar patrones y realizar predicciones o clasificaciones (Hastie et al., 2001).

Las técnicas de Machine Learning son ampliamente empleadas en una variedad de campos con el objetivo de incrementar la precisión y la robustez de los sistemas. Estas técnicas posibilitan que los sistemas aprendan de forma automática a partir de los datos,

mejorando su rendimiento a medida que se les suministra más información, esto les brinda la capacidad de adaptarse y evolucionar (Dalal & Triggs, 2005).

El Machine Learning se utiliza en muchos campos, como la visión por ordenador, el procesamiento del lenguaje natural, la medicina, la economía y la Re-ID humana (Mitchell, 1997).

Convolutional Neural Network (CNN)

Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son una técnica de aprendizaje profundo que se ha utilizado para extraer información de varios conjuntos de datos de diferentes dimensiones (Vaz & Balaji, 2021).

Una CNN funciona mediante la aplicación de filtros convolucionales a la entrada de datos para extraer características relevantes y luego realizar operaciones de agrupación para reducir la dimensionalidad (LeCun et al., 2015).

El proceso de convolución implica deslizar un filtro sobre la imagen de entrada y calcular la suma ponderada de los píxeles cubiertos por el filtro en cada posición (Vaz & Balaji, 2021). Esto permite detectar características locales, como bordes, texturas y patrones en la imagen. Los filtros convolucionales se aprenden durante el entrenamiento de la red neuronal y se utilizan para extraer características específicas de la imagen (Vaz & Balaji, 2021).

Después de la convolución, se aplica una función de activación no lineal, como la función ReLU, para introducir la no linealidad en la red y permitir la representación de características más complejas.

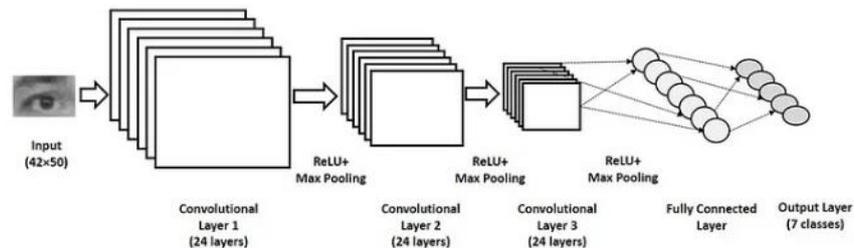
Luego, se realiza la operación de agrupación, también conocida como submuestreo o pooling, que reduce la dimensionalidad de las características extraídas al seleccionar el valor máximo o promedio de un vecindario de píxeles. Esto ayuda a reducir el costo computacional y la cantidad de parámetros en la red.

Después de varias capas de convolución y agrupación, se utilizan capas completamente conectadas para realizar la clasificación final, estas capas toman las

características extraídas y las transforman en una salida que representa la clase o categoría a la que pertenece la imagen (LeCun et al., 2015).

Figura 3

CNN (Convolution Neural Network)



Nota. Ejemplo de cálculo. Tomado de (Jeong, 2019).

En la Re-ID de personas, las CNN se utilizan para extraer características discriminatorias de las imágenes de las personas. Estas características capturan aspectos clave como la apariencia, la forma o la silueta de la persona. Al entrenar una CNN con un gran conjunto de datos de personas, la red puede aprender a reconocer, discriminar y dar seguimiento (Vaz & Balaji, 2021).

Support vector machine (SVM)

Las máquinas de soporte vectorial (SVM) son algoritmos de aprendizaje automático que han demostrado un exitoso rendimiento en la Re-ID de personas, las SVM pueden determinar los límites entre dos conjuntos de datos, lo que las convierte en una alternativa muy potente para la clasificación (Cortes & Vapnik, 1995).

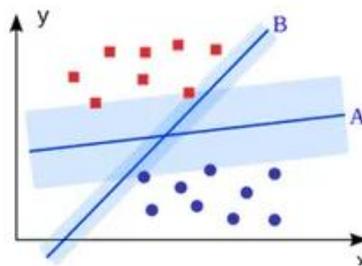
La máquina de vectores soporte (SVM) es un modelo de aprendizaje supervisado con algoritmos de aprendizaje asociados que analizan datos para realizar análisis de clasificación y regresión (Zhili & Guiyan, 2008).

Las SVM se diseñaron para inducir un modelo basado en el error global. Sin embargo, cuando aprenden a partir de conjuntos de datos desequilibrados, las SVM pueden mostrar un rendimiento deficiente en la clase minoritaria (Cortes & Vapnik, 1995).

Su funcionamiento se basa en encontrar un hiperplano óptimo, también conocido como vectores de soporte, que permita separar de manera óptima las diferentes clases en un conjunto de datos. Estos vectores de soporte desempeñan un papel fundamental al establecer la frontera de decisión. El algoritmo SVM utiliza una función de kernel para mapear los datos de entrada a un espacio de mayor dimensionalidad, lo que permite encontrar una frontera de decisión no lineal en el espacio transformado (Cortes & Vapnik, 1995).

Figura 4

SVM (Support Vector Machine)



Nota. Ejemplo de discriminación. Tomado de (Patel, 2017).

En este caso, la SVM se utiliza para clasificar puntos de datos en dos clases, representadas por los puntos rojo y azul. La SVM encuentra un hiperplano que separa las dos clases lo mejor posible (Patel, 2017). Este hiperplano es la línea que la SVM ha trazado en la imagen. Los puntos de datos más cercanos al hiperplano se denominan vectores soporte.

Para aplicar la SVM a la Re-ID, es necesario extraer características de la imagen de una persona. Estas características pueden extraerse manualmente o mediante técnicas de aprendizaje automático. Una vez extraídas las características, pueden utilizarse para entrenar un modelo SVM (Patel, 2017).

Los modelos SVM se entrenan utilizando un conjunto de imágenes de caras. El conjunto de datos debe estar etiquetado. Esto significa que cada imagen debe tener una etiqueta que indique a quién pertenece; el modelo SVM aprende a dividir las imágenes en diferentes rostros basándose en las características extraídas.

Tras el entrenamiento, el modelo SVM se utiliza para predecir la afiliación de nuevas imágenes. La nueva imagen se introduce en el modelo y éste produce predicciones. Las predicciones son etiquetas para las caras de la imagen.

SVM es una poderosa herramienta que se puede utilizar para mejorar el rendimiento de los sistemas de Re-ID. Sin embargo, aún quedan algunos problemas por resolver, como la falta de datos de entrenamiento y la distorsión de las imágenes. A medida que la tecnología de aprendizaje automático siga mejorando, se espera que la identificación automática se convierta en una herramienta aún más potente para diversas aplicaciones (Cortes & Vapnik, 1995).

Técnicas No Holísticas

Los sistemas actuales de Re-ID de personas utilizan técnicas no holísticas para mejorar la precisión en la discriminación de individuos, las técnicas no holísticas se centran en la extracción y comparación de características locales específicas en lugar de considerar la imagen completa. Esta técnica se fundamenta en la idea de que ciertas áreas del cuerpo, como el rostro, las manos o la vestimenta, albergan datos distintivos que pueden ser utilizados para identificar personas de manera precisa.

Dentro del ámbito del reconocimiento facial, el enfoque no holístico se fundamenta en la extracción de características locales del rostro, tales como la distancia entre los ojos, la forma de la nariz y los labios, así como los pómulos (Zheng et al., 2016). Estas características se emplean para lograr una representación más precisa de los rasgos faciales relevantes en la identificación de personas (Zheng et al., 2016).

Un ejemplo habitual de modelo no holístico es el enfoque basado en reglas, que utiliza reglas específicas para tomar decisiones en función de características o atributos concretos de los datos. Estos modelos son más sencillos y fáciles de aplicar, pero pueden no ser tan precisos o eficaces como los enfoques más complejos que tienen en cuenta más información.

características o atributos concretos de los datos. Estos modelos son más sencillos y fáciles de aplicar, pero pueden no ser tan precisos o eficaces como los enfoques más complejos que tienen en cuenta más información.

Es importante señalar que los modelos no holísticos pueden ser apropiados en determinados contextos, como cuando se dispone de datos limitados o cuando la complejidad computacional es una consideración importante (Fan et al., 2019).

Scrum

La metodología Scrum es un enfoque ágil de la gestión y el desarrollo de proyectos, se enfoca en la colaboración, cooperación, flexibilidad, adaptabilidad y la entrega constante de valor al cliente. Scrum se centra en crear productos cada vez más funcionales en plazos fijos denominados Sprint (Mundra et al., 2013).

Los Sprints son iteraciones de trabajo que generalmente duran de una a cuatro semanas, durante las cuales se planifica, se desarrolla y se entrega un conjunto de funcionalidades (Mundra et al., 2013).

Scrum se caracteriza por tener roles definidos, como el Product Owner, el Scrum Máster y el Equipo de Desarrollo, y por utilizar artefactos como el Product Backlog y el Sprint Backlog para gestionar el trabajo (Rising & Janoff, 2000).

El Product Owner es el propietario del proyecto, es responsable de maximizar el valor de los productos que su equipo desarrolla en nombre de los usuarios finales, trabaja en estrecha colaboración con el equipo de desarrollo y tiene la autoridad para tomar decisiones sobre las funcionalidades y prioridades del producto (Rising & Janoff, 2000).

El Scrum Master es responsable de asegurar que el equipo de desarrollo siga las prácticas y principios de Scrum, y de facilitar el proceso de desarrollo del proyecto, el Scrum Master actúa como un coach o facilitador para el equipo, ayudándoles a entender y adoptar Scrum de manera efectiva (Rising & Janoff, 2000).

El equipo de desarrollo está compuesto por profesionales que son responsables de desarrollar y entregar el producto o incremento de producto en cada sprint, el equipo de

desarrollo es autónomo y autoorganizado, lo que significa que tiene la capacidad de tomar decisiones y gestionar su propio trabajo (Rising & Janoff, 2000).

El Product Backlog es una lista priorizada de requisitos o elementos de trabajo que deben ser completados para el desarrollo de un producto (Rising & Janoff, 2000). Estos elementos pueden ser funcionalidades, mejoras, correcciones de errores, entre otros (Mundra et al., 2013).

Un Sprint Backlog es una colección de elementos seleccionados del Product Backlog que el equipo de desarrollo se compromete a completar durante un sprint (Rising & Janoff, 2000). Es una lista detallada de tareas y actividades que el equipo de desarrollo necesita realizar para entregar los incrementos de producto planificados para el sprint (Mundra et al., 2013).

Yolo

YOLO (You Only Look Once) es un popular algoritmo de detección de objetos en imágenes y videos (Terven & Cordova-Esparza, 2023). A diferencia de los enfoques tradicionales que dividen la detección en múltiples etapas, YOLO realiza la detección de objetos en una sola pasada, lo que lo hace muy eficiente en términos de velocidad de procesamiento en tiempo real.

El algoritmo YOLO divide la imagen de entrada en una cuadrícula y predice las cajas delimitadoras y las probabilidades de las clases de objetos en cada celda de la cuadrícula. A medida que se realiza la inferencia, YOLO aplica una única red neuronal convolucional para realizar la detección y clasificación de objetos simultáneamente (Redmon et al., 2016). Esto permite una detección rápida y precisa de múltiples objetos en una sola imagen o fotograma de video.

Para entrenar modelos YOLO, se requiere un conjunto de datos anotados que contenga imágenes o videos con objetos de interés y sus correspondientes cajas delimitadoras y etiquetas de clase. A partir de este conjunto de datos, se entrena el modelo YOLO utilizando técnicas de aprendizaje profundo y optimización, ajustando los pesos y

parámetros de la red neuronal convolucional para realizar la detección precisa de objetos en nuevas imágenes o videos (Redmon et al., 2016).

Sin embargo, YOLO tiene algunas limitaciones. Al tratarse de un método de detección basado en cuadrículas, puede tener dificultades para detectar objetos pequeños o poco espaciados. También puede tener problemas con la precisión del cuadro delimitador (ROI), lo que puede afectar a la precisión de la detección (Redmon et al., 2016).

En general, YOLO ha demostrado ser una técnica eficaz y eficiente para la detección de objetos en imágenes y vídeos y se utiliza ampliamente en aplicaciones de Visión por Computadora.

Métricas de Evaluación

Las métricas de evaluación son utilizadas para medir el rendimiento y la calidad de los modelos de Machine Learning. Estas métricas permiten cuantificar el desempeño de un modelo en función de su capacidad de predecir correctamente las etiquetas o clasificar los datos (Sokolova & Lapalme, 2009).

A continuación, se presentan algunas de las métricas de evaluación más comunes:

- **Accuracy:** Esta métrica muestra el porcentaje de predicciones correctas realizadas por el modelo sobre el número total de predicciones.
- **Precisión:** Esta métrica mide la proporción de verdaderos positivos correctamente clasificados sobre el número total de muestras clasificadas como positivas.
- **Recall:** Esta métrica evalúa la proporción de verdaderos positivos en relación con el total de instancias positivas en el conjunto de datos.
- **F1-Score:** Es una medida que combina la precisión y el recall, ofreciendo una medida equilibrada del rendimiento del modelo.
- **Matriz de confusión:** Es una tabla que presenta el número de predicciones correctas e incorrectas de un modelo, clasificadas en verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos.

Estas métricas son utilizadas para evaluar diferentes aspectos del rendimiento del modelo, como la capacidad de clasificación, la detección de falsos positivos o negativos, el equilibrio entre precisión y recall (Sokolova & Lapalme, 2009).

En la tabla 1 se muestran cada una de las fórmulas de las métricas de evaluación mencionadas.

Tabla 1

Métricas de Evaluación

Métricas de Evaluación	Fórmula
Accuracy	$\frac{VP + VN}{VP + VN + FP + FN}$
Precisión	$\frac{VP}{VP + FP}$
Recall	$\frac{VP}{VP + FN}$
F1-Score	$2 * \frac{precision * recall}{precision + recall}$

Nota. Esta tabla muestra los nombres de las métricas de evaluación en la parte izquierda y en la parte derecha se muestran sus respectivas formulas.

Tabla 2

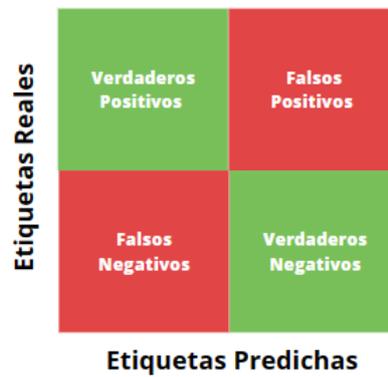
Valores de la Matriz de Confusión

	Clasificación	
	Positivo	Negativo
Clase real		
Positivos	VP	FN
Negativos	FP	VN

Nota. Las siglas (VP) hacen referencia a los verdaderos positivos, (FN) falsos negativos, (FP) falsos positivos y (VN) verdaderos negativos.

Figura 5

Matriz de confusión



Nota. Representación gráfica de una matriz de confusión. Imagen de autoría propia.

Es importante seleccionar las métricas de evaluación adecuadas según el problema y los objetivos específicos del modelo. Además, es recomendable utilizar múltiples métricas para obtener una visión más completa del rendimiento del modelo.

Capítulo III

Implementación del Sistema

En este capítulo se describe el proceso llevado a cabo durante el desarrollo del sistema propuesto, un sistema de Re-DI de personas a través de características biométricas: facial y Soft-biométricas: silueta corporal, textura y color de la vestimenta usando modelos no holísticos, a través de técnicas LBP y HOG de Visión por Computadora y los modelos SVM y CNN en Deep Learning, el cual será desarrollado con el lenguaje de programación Python (versión 3.10.11) e implementado en un circuito cerrado de cámaras en la Universidad de las Fuerzas Armadas "ESPE" sede Latacunga campus Belisario Quevedo.

SCRUM es la metodología utilizada para el desarrollo de este proyecto, debido a su adaptabilidad a cambios de requisitos, ciclo de vida flexible, colaboración entre miembros y la capacidad de entregar productos software funcionales de alta calidad de manera iterativa e incremental (Rising & Janoff, 2000).

Todos los proyectos de desarrollo de software necesitan seguir y medir su progreso. Este capítulo se centrará en el uso de métricas de evaluación en la fase de pruebas del ciclo de vida del desarrollo de software. Estas métricas son esenciales para el equipo de desarrollo porque proporcionan datos objetivos sobre el progreso del proyecto. Estos datos pueden utilizarse para identificar problemas, definir mejoras y medir la calidad del software.

Análisis y diseño del sistema

De acuerdo con las normas de la metodología de desarrollo ágil Scrum, se obtienen las Historias de Usuario (HU) para especificar los requerimientos del sistema (Rising & Janoff, 2000).

En la tabla 3 se muestra los miembros del equipo SCRUM, se especifica a la persona con su rol y se determina su función.

Tabla 3*Team Scrum*

N°.	Rol	Integrante	Funciones
1	Product Owner	Dr. José Luis Carrillo Medina	Determinar los requisitos del sistema y tiempos de entrega
2	Scrum Master	Msc. Nancy del Pilar Jacho Guanoluisa Bryan Steeven Jácome	Líder del equipo Scrum
3	Development Team	Bastidas Robinson Armando Ruilova Rodríguez	Desarrollo e implementación del sistema de Re-ID

Historias de Usuario

En la tabla 4 se muestran todas las Historias de Usuario, donde se indica un identificador único (ID), el nombre de la Historia de Usuario, el rol, la funcionalidad y el resultado esperado al implementar en el sistema.

Tabla 4*Historias de Usuario*

ID	Nombre	Rol	Funcionalidad	Resultado
1	H.U.01	Como usuario	Quiero obtener un dataset que contenga la característica biométrica del rostro	Para entrenar un modelo de Deep Learning de identificación de rostros
2	H.U.02	Como usuario	Quiero un modelo y/o algoritmo que permita la identificación de rostros mediante técnicas de visión por Computadora	Para identificar a personas mediante la característica biométrica del rostro

ID	Nombre	Rol	Funcionalidad	Resultado
3	H.U.03	Como usuario	Quiero obtener un dataset que contenga características Soft-biométricas como la silueta corporal, la textura y color de la vestimenta	Para entrenar un modelo de Deep Learning para identificación de personas
4	H.U.04	Como usuario	Quiero un modelo y/o algoritmo que permita la identificación de personas a través de las características Soft-biométricas (silueta corporal, textura y color de la vestimenta)	Para mejorar la precisión y robustez en el proceso de Re-ID de personas
5	H.U.05	Como usuario	Quiero que el sistema detecte a personas mediante su vista frontal y la Re-ID mediante su vista posterior utilizando características biométricas (rostro) y Soft-biométricas (silueta corporal, textura y color de la vestimenta)	Para detectar y Re-ID a las personas en un circuito cerrado de cámaras

Product Backlog

El Product Backlog es una lista de los requisitos del sistema ya planteados (Historias de Usuario), esta lista permite tener una comprensión clara de las tareas pendientes y su prioridad, lo que ayuda a planificar y organizar el proyecto de manera eficiente (Mundra et al., 2013).

Tabla 5*Product Backlog*

Historia de usuario	Nombre	Estimación (días)	Fecha de inicio	Fecha de fin	N° de Sprint
1	H.U.01	6	4/5/2023	11/5/2023	1
2	H.U.02	20	12/5/2023	8/6/2023	2
3	H.U.03	5	9/6/2023	15/6/2023	3
4	H.U.04	20	16/6/2023	13/7/2023	4
5	H.U.05	21	14/7/2023	11/8/2023	5

Escenario para la implementación

La implementación del sistema de Re-ID de personas se lleva a cabo en un ambiente controlado situado en la Universidad de las Fuerzas Armadas ESPE sede Latacunga.

Entre todos los ambientes que ofrece las instalaciones del campus universitario, se escogió los pasillos ubicados en el segundo piso del edificio central, que proporcionan acceso al departamento de Ciencias de la Computación.

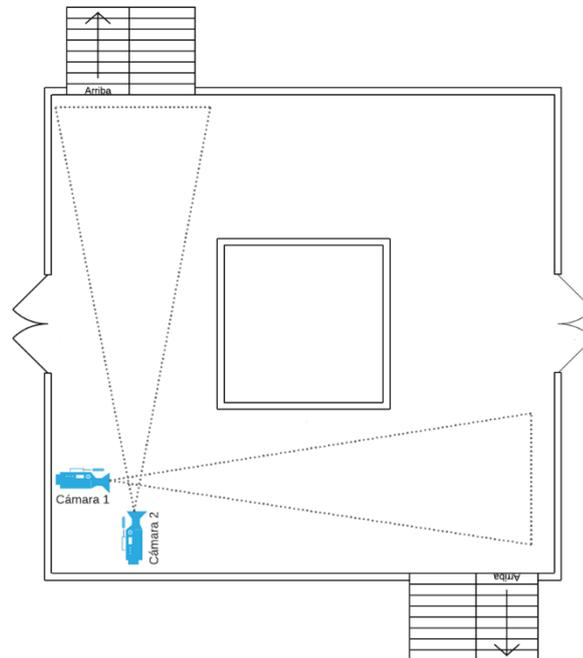
Figura 6*Ambiente controlado*

Nota. Pasillos de la Universidad de las Fuerzas Armadas ESPE sede Latacunga.

Las cámaras están ubicadas en la esquina adyacente al departamento de Ciencias de la Computación, esta ubicación es ideal debido a su cobertura completa permitiendo que las cámaras tengan un ángulo de visión adecuado para la captura de imágenes claras.

Figura 7

Ubicación de las cámaras



Nota. Las cámaras están ubicadas de forma que sus áreas de cobertura no están solapadas.

Herramientas de software para el desarrollo

En la tabla 6 presenta todas las herramientas utilizadas en el desarrollo del sistema de Re-ID de personas, junto con sus descripciones y versiones.

Tabla 6

Herramientas usadas para la creación del sistema

Herramienta	Descripción
Sistema Operativo	Windows 11
Entorno de desarrollo integrado (IDE)	Para el desarrollo del sistema de Re-ID de personas se utilizó el editor Visual Studio Code versión 1.80.1

Herramienta	Descripción
Lenguaje de programación	Para la programación del sistema se utilizó el lenguaje Python en su versión 3.10.11
Bases de datos de personas	Para el entrenamiento de los modelos, se generó un dataset propio, donde se puedan extraer todas las características que se necesitan.
Bibliotecas de Visión por Computadora	Se utilizo Open Source Computer Vision Library (OpenCV) para el preprocesamiento y procesamiento de imágenes.
Bibliotecas de Deep Learning	Para el entrenamiento de modelos de Re-ID de personas se utilizó Frameworks como TensorFlow y PyTorch
Herramientas de detección de objetos	Para la detección y extracción de la región de interés (ROI) se utilizó You Only Look Once (YOLO) en su versión 8
Técnicas de extracción de características	Para la extracción de características se utilizó los descriptores Histogramas de Gradientes Orientados (HOG) y los Patrones Binarios Locales (LBP)
Algoritmos de clasificación	Para la clasificación de entidades detectadas se utilizaron los clasificadores de Maquinas de Soporte

Herramienta	Descripción
	Vectorial (SVM) y las Redes Neuronales Convolucionales (CNN)

Componentes hardware para el desarrollo

En la tabla 7 presenta todas las herramientas hardware utilizadas en el desarrollo del sistema de Re-ID de personas, junto con sus descripciones y características.

Tabla 7

Herramientas hardware usadas para la creación del sistema

Componentes	Descripción
Procesador	Intel Core i7-13700K, 3.4GHZ de 16 CORE
Memoria RAM	Memoria RAM DDR4 de 32 GB
Tarjeta de Video	MSI GEFORCE RTX 3060 12GB
Almacenamiento	SSD de 1000GB Kingston

Definición e implementación de modelos de identificación facial, textura y color de la vestimenta

Una vez elaborado el Product Backlog se procede a generar cada uno de los Sprint Backlog, el Product Owner es el responsable de crear el Sprint Backlog, que consiste en ordenar las tareas y actividades de cada Sprint en función de su prioridad.

Después de haber creado el Sprint Backlog, el Product Owner, el Scrum Master y el Equipo de Desarrollo se reúnen para planificar el Sprint, las reuniones se realizaron de manera remota través de la plataforma Google Meet, pero cuando se creía necesario, se llevaron a cabo de forma presencial en las instalaciones de la Universidad de las Fuerzas Armadas ESPE sede Latacunga.

Sprint 01: Dataset y algoritmo de identificación facial

La Historia de Usuario 01 indica que se debe crear un dataset que contenga características biométricas del rostro, la Historia de Usuario 01 se tomó en cuenta para el desarrollo del Sprint 01.

Historia de Usuario Detallada

Tabla 8

Historia de Usuario H.U.01

Historia de Usuario	
Número: H.U.01	Usuario: Usuario
Nombre historia: Creación de dataset para identificación facial	Número de Sprint: 1
Prioridad: Alta	Riesgo de desarrollo: Media
Puntos estimados (días): 5	Interacción asignada: 1
Desarrolladores responsables: Bryan Jácome, Robinson Ruilova	
Descripción: Como usuario quiero obtener un dataset que contenga la característica biométrica del rostro.	
Validación:	
<ul style="list-style-type: none"> • Generar videos en ambientes controlados del campus de la universidad. • Extraer imágenes de los rostros obtenidos de cada frame de los videos generados. • Almacenar las imágenes de los rostros en carpetas individuales para cada persona. 	

Sprint Backlog

Para el desarrollo del Sprint 01 se consideraron tres tareas, los responsables de cumplir con estas tareas son los integrantes del Development Team, Bryan Jácome y Robinson Ruilova. El estado de cada una de las tareas es finalizado.

En la tabla 9 se detalla las tareas realizadas en el Sprint 01, el tiempo asignado a cada tarea y también se muestra la jornada de trabajo en horas.

Tabla 9

Sprint Backlog 01

Sprint 01				
Fecha Inicio: 04/05/2023		Fecha Fin: 11/05/2023		Jornada: 8 horas
H.U.	Tareas	Horas	Fecha Inicio	Fecha Fin
01	Grabación de videos de personas en diferentes entornos controlados	16	04/05/2023	05/05/2023
01	Desarrollo de algoritmo para captura de rasgos faciales	28	08/05/2023	11/05/2023
01	Creación de carpetas independientes por personas y almacenamiento del dataset	4	11/05/2023	11/05/2023

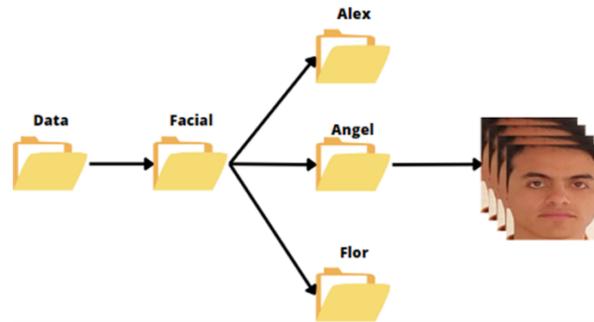
Resultados del Sprint 01

Se creo un total de 14 videos en diferentes entornos controlados, generando un dataset de 1200 imágenes que contienen características faciales listas para el entrenamiento de modelos de detección facial.

En la figura 8 se puede observar un diagrama de la distribución del almacenamiento del dataset generado por el algoritmo de detección facial y una representación gráfica de su contenido.

Figura 8

Carpetas creadas para el almacenamiento del dataset de características faciales



Sprint 02: Desarrollo e implementación de modelos y/o algoritmos de identificación facial mediante técnicas de Visión por Computadora

Para el desarrollo del Sprint 02 se tomó en cuenta la Historia de Usuario 02, la Historia de Usuario 02 indica que se debe desarrollar un modelo y/o algoritmo que permita la identificación facial utilizando técnicas de Visión por Computadora.

Historia de Usuario Detallada

Tabla 10

Historia de Usuario H.U.02

Historia de Usuario	
Número: H.U.02	Usuario: Usuario
Nombre historia: Desarrollo de un modelo y/o algoritmo de identificación facial	Número de Sprint: 2
Prioridad: Alta	Riesgo de desarrollo: Alta
Puntos estimados (días): 20	Interacción asignada: 1
Desarrolladores responsables: Bryan Jácome, Robinson Ruilova	
Descripción: Como usuario quiero un modelo y/o algoritmo que permita la identificación de rostros mediante técnicas de visión por Computadora.	
Validación:	

Historia de Usuario

- Implementar técnicas de Visión por Computadora como LBP para el reconocimiento de características faciales.
 - Desarrollar y entrenar un modelo capaz de identificar a personas mediante su rostro.
 - Realizar pruebas del modelo desarrollado con el dataset creado en el Sprint 01.
-

Sprint Backlog

Para el desarrollo del Sprint 02 se consideraron cuatro tareas, los responsables de cumplir con estas tareas son los integrantes del Development Team, Bryan Jácome y Robinson Ruilova. El estado de cada una de las tareas al terminar el Sprint 02 es finalizado.

En la tabla 11 se detalla las tareas realizadas en el Sprint 02, el tiempo asignado y también se muestra la jornada de trabajo en horas.

Tabla 11

Sprint Backlog 02

Sprint 02				
Fecha Inicio: 12/05/2023		Fecha Fin: 08/06/2023		Jornada: 8 horas
H.U.	Tareas	Horas	Fecha Inicio	Fecha Fin
02	Desarrollo del algoritmo de entrenamiento del modelo	48	12/05/2023	19/05/2023
02	Desarrollo del algoritmo de identificación de personas mediante su rostro	32	22/05/2023	26/05/2023
02	Optimizar código y realizar pruebas de confianza	4	29/05/2023	01/06/2023

Sprint 02

02	Aplicar métricas de evaluación y rendimiento	40	02/06/2023	08/06/2023
----	--	----	------------	------------

Resultados del Sprint 02

Se desarrollo un modelo capaz de identificar a las personas conocidas (personas que se encuentran en el dataset) mediante su rostro, utilizando técnicas de Visión por Computadora como el descriptor LBP (Local Binary Pattern) y el clasificador CNN (Convolutional Neural Network).

En la tabla 12 se muestra el pseudocódigo desarrollado para la identificación facial de personas.

Tabla 12

Algoritmo LBP para identificación facial

Algoritmo 1: Identificación facial mediante descriptor LBP

```

# Lectura del modelo entrenado
modelFace = crear_modelo_LBPHFaceRecognizer()
modelFace.leer('Models/CNN-LBP-face.xml')
# Lectura del modelo para extraer el ROI
modelPerson = crear_modelo_YOLO('Models/yolov8n-face.pt')
# Captura del video
cap = abrir_video('Videos/Angel2_Cam1.mp4')
mientras verdadero:
    ret, frame = leer_frame(cap)
    si no ret:
        romper
    auxFrame = copiar_frame(frame)
    resultados = modelPerson(frame)
    para cada resultado en resultados:
        para cada caja en resultado.cajas:
            si caja.confianza > 0.35:
                # Obtener las coordenadas de la región de interés ROI
                x1, y1, x2, y2 = caja.coord_xyxy[0]
                x1, y1, x2, y2 = convertir_a_entero(x1), convertir_a_entero(y1),
convertir_a_entero(x2), convertir_a_entero(y2)
                # Extraer la región de interés ROI (cara)
                cara = auxFrame[y1:y2, x1:x2]
                # Redimensionar la imagen obtenida de la cara
                cara = redimensionar(cara, (200, 200))
                cara = convertir_a_escalade_grises(cara)
                resultadoLBP = modelFace.predecir(cara)
                si (100-resultadoLBP[1]) > 60:

```

Algoritmo 1: Identificación facial mediante descriptor LBP

```

# Calcular el tamaño del rectángulo del texto
tamano_texto, _ = obtener_tamano_texto(
    '{}'.format(listaPersonas[resultadoLBP[0]]) + " {:.2f}".format(
        (100-resultadoLBP[1])/100), 1, 7, 8)
ancho_texto, alto_texto = tamano_texto
# Rectángulo del texto
dibujar_rectangulo(frame, (x1, y1 - alto_texto - 25), (x1 +
ancho_texto,
                                y1 - 26), (0, 255, 0), -1)

# Texto del resultado
dibujar_texto(frame, '{}'.format(listaPersonas[resultadoLBP[0]]) +
" {:.2f}".format(
    (100-resultadoLBP[1])/100), (x1, y1-24), 1, 7, (255, 255,
255), 8, LINEA_AA)
# Rectángulo de la cara
dibujar_rectangulo(frame, (x1, y1),
    (x2, y2), (0, 255, 0), 10)
sino:
    frame = resultado.graficar()

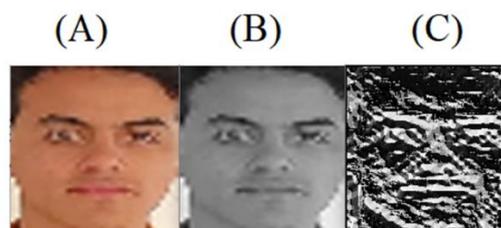
# Redimensionar la imagen obtenida de frame
frame = redimensionar_imagen(frame, ancho=1000)
# Visualizar el resultado
mostrar_imagen("CNN-LBP Face", frame)
si esperar_tecla(1) & 0xFF == tecla('q'):
    romper
cerrar_video(cap)
cerrar_ventanas()

```

La figura 9 se puede observar el proceso de tratamiento de la imagen del rostro para obtener sus características LBP. La imagen (A) corresponde a la imagen original obtenida del dataset, la imagen (B) es la misma imagen transformada a escala de grises y la imagen (C) es la representación de características LBP.

Figura 9

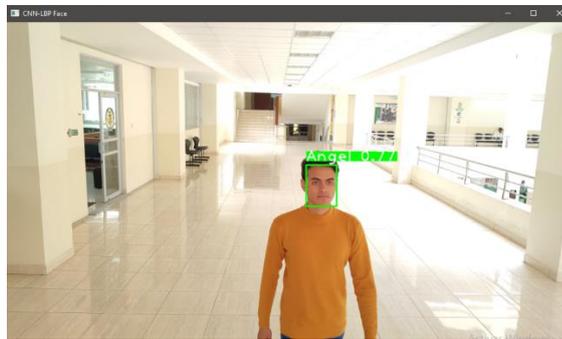
Proceso de la captura de rostros



La figura 10 muestra el proceso de identificación facial de una persona a partir de la imagen captada de la cámara 1, que enfoca la parte frontal de la persona. El sistema localiza el rostro de la persona y lo encierra en un recuadro, en la parte superior del recuadro se muestra la etiqueta, correspondiente al nombre de la persona, junto a la etiqueta se encuentra el porcentaje de predicción, representado en escala de 0 a 1 (siendo 1 el 100% de predicción).

Figura 10

Identificación facial de la persona

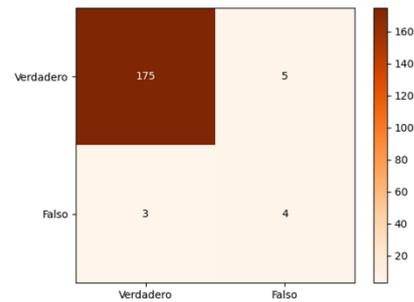


La identificación facial se la realiza en tres videos de la misma persona, pero con diferentes recorridos, en el primer recorrido, la persona camina en la parte izquierda del pasillo, en el segundo recorrido, la persona camina en el centro del pasillo y en el último recorrido, la persona camina en la parte derecha del pasillo.

Las figuras 11, 12, 13 ilustran la matriz de confusión aplicada al proceso de identificación facial en los tres recorridos, la matriz de confusión permite identificar cuantas veces el sistema reconoció a la persona, cuantas veces no la reconoció y cuantas veces realizo un reconocimiento falso.

Figura 11

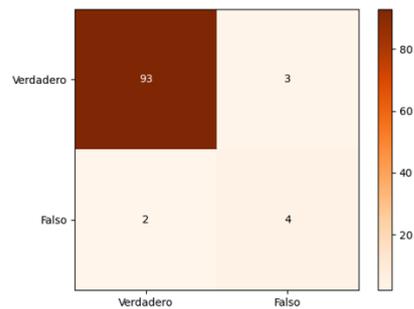
Matriz de Confusión de la clase Ángel Video 1



Nota. La matriz de confusión demuestra que el modelo acertó al predecir 175 imágenes de la clase Ángel, sin embargo, en 5 imágenes de la clase Ángel predijo como otra clase, en 3 imágenes donde aparece la clase Ángel no logro realizar la detección y predijo que en 4 imágenes no aparece la clase Ángel.

Figura 12

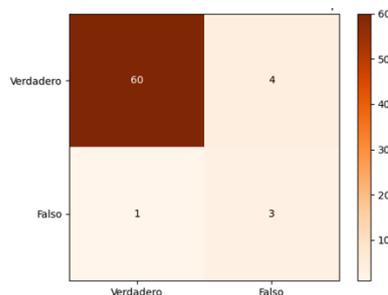
Matriz de Confusión de la clase Ángel Video 2



Nota. La matriz de confusión revela que el modelo acertó al predecir 93 imágenes de la clase Ángel, sin embargo, en 3 imágenes de la clase Ángel predijo como otra clase, en 2 imágenes donde aparece la clase Ángel no logro realizar la detección y predijo que en 4 imágenes no aparece la clase Ángel.

Figura 13

Matriz de Confusión de la clase Ángel Video 3



Nota. La matriz de confusión muestra que el modelo acertó al predecir 60 imágenes de la clase Ángel, a pesar de eso, en 4 imágenes de la clase Ángel predijo como otra clase, en 1 imagen donde aparece la clase Ángel no logro realizar la detección y predijo que en 3 imágenes no aparece la clase Ángel.

En la tabla 13 se presenta los resultados de las métricas de evaluación aplicadas al sistema de identificación facial, las métricas se aplican por separado a cada recorrido realizado por la persona y se calcula el promedio de los tres recorridos.

Tabla 13

Resultados de las métricas de evaluación

Clasificador	Métricas	Primer	Segundo	Tercer	Promedio
		recorrido	recorrido	recorrido	
CNN	Accuracy	0.9572	0.9510	0.9265	0.9449±0.0142
	Recall	0.9831	0.9789	0.9836	0.9819±0.0033
	Precision	0.9722	0.9688	0.9375	0.9595±0.0176

Los resultados de las métricas varían en cada recorrido, debido a los cambios de iluminación de la escena y el ruido que existe en cada toma.

Al concluir el Sprint 02, no se encontraron mayores inconvenientes en el transcurso del desarrollo del sistema de identificación facial, se logró cumplir con todas las tareas planteadas en el Sprint Backlog, dando como resultado un modelo y algoritmo capaz de

identificar a personas mediante su rostro. Los resultados obtenidos al aplicar las métricas de evaluación son satisfactorios, tanto en las pruebas realizadas como en el dataset.

Sprint 03: Creación de dataset y algoritmo de identificación de características Soft-biométricas

En el Sprint 03 se tomó en cuenta la Historia de Usuario 03, que indica que se debe crear un dataset que contenga características Soft-biométricas como la silueta de la persona y la textura y el color de su vestimenta.

Historia de Usuario Detallada

Tabla 14

Historia de Usuario H.U.03

Historia de Usuario	
Número: H.U.03	Usuario: Usuario
Nombre historia: Creación de dataset para identificación mediante características Soft-biométricas	
	Número de Sprint: 1
Prioridad: Alta	Riesgo de desarrollo: Media
Puntos estimados (días): 5	Interacción asignada: 1
Desarrolladores responsables: Bryan Jácome, Robinson Ruilova	
Descripción: Como usuario quiero obtener un dataset que contenga características Soft-biométricas como la silueta corporal, la textura y color de la vestimenta	
Validación:	
<ul style="list-style-type: none"> • Generar videos en ambientes controlados del campus de la universidad. • Extraer imágenes y datos de la silueta de la persona, textura y color de la vestimenta. • Almacenar las imágenes y datos de las características Soft-biométricas en carpetas individuales para cada persona. 	

Sprint Backlog

Para el desarrollo del Sprint 03 se consideraron tres tareas, los responsables de cumplir con estas tareas son los integrantes del Development Team, Bryan Jácome y Robinson Ruilova. El estado de cada una de las tareas al término del Sprint 03 es finalizado.

En la tabla 15 se detalla las tareas realizadas en el Sprint 03, el tiempo asignado y también se muestra la jornada de trabajo en horas.

Tabla 15

Sprint Backlog 03

Sprint 03				
Fecha Inicio: 09/06/2023		Fecha Fin: 15/06/2023		Jornada: 8 horas
H.U.	Tareas	Horas	Fecha Inicio	Fecha Fin
03	Grabación de videos de personas en diferentes entornos controlados	16	09/06/2023	12/06/2023
03	Desarrollo de algoritmo para captura de rasgos Soft-biométricos	20	13/06/2023	15/06/2023
03	Creación de carpetas independientes por personas y almacenamiento del dataset	4	15/06/2023	15/06/2023

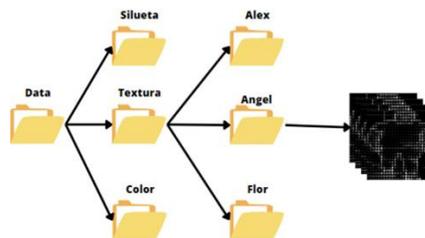
Resultados del Sprint 03

Se creó un total de 14 videos en diferentes entornos controlados, generando un dataset de 1200 imágenes diferenciadas por el cambio de iluminación, enfoque y ruido que aparece en cada una, las imágenes obtenidas contienen características Soft-biométricas listas para el entrenamiento de modelos de detección de personas.

La figura 14 presenta un diagrama de la estructura del dataset almacenado, resultado del algoritmo de detección de características Soft-biométricas. Se muestra la distribución de las carpetas y una representación de su contenido.

Figura 14

Carpetas creadas para el almacenamiento del dataset de características Soft-biométricas



Sprint 04: Desarrollo e implementación de modelos y/o algoritmos de identificación de personas mediante características Soft-biométricas

Para el desarrollo del Sprint 04, se implementó la Historia de Usuario 04, la cual especifica que se debe desarrollar un modelo y/o algoritmo que permita la identificación de personas a través de características Soft-biométricas como la silueta corporal, textura y color de la vestimenta.

Historia de Usuario Detallada

Tabla 16

Historia de Usuario H.U.04

Historia de Usuario	
Número: H.U.04	Usuario: Usuario
Nombre historia: Desarrollo de un modelo y/o algoritmo de identificación de personas mediante características Soft-biométricas	Número de Sprint: 4
Prioridad: Alta	Riesgo de desarrollo: Alta
Puntos estimados (días): 20	Interacción asignada: 1
Desarrolladores responsables: Bryan Jácome, Robinson Ruilova	

Historia de Usuario

Descripción: Como usuario quiero un modelo y/o algoritmo que permita la identificación de personas a través de las características Soft-biométricas (silueta corporal, textura y color de la vestimenta)

Validación:

- Implementar técnicas de Visión por Computadora como LBP y HOG para el reconocimiento de características Soft-biométricas.
 - Desarrollar y entrenar un modelo capaz de identificar a personas mediante su silueta corporal, textura y color de la vestimenta.
 - Realizar pruebas al modelo desarrollado con el dataset creado en el Sprint 03.
-

Sprint Backlog

Para el desarrollo del Sprint 04 se consideraron cuatro tareas, los responsables de cumplir con estas tareas son los integrantes del Development Team, Bryan Jácome y Robinson Ruilova. El estado de cada una de las tareas al término del Sprint 04 es finalizado.

La tabla 17 presenta todas las tareas realizadas en el Sprint 04, el tiempo asignado y también se muestra la jornada de trabajo en horas.

Tabla 17

Sprint Backlog 04

Sprint 04				
Fecha Inicio: 16/06/2023		Fecha Fin: 13/07/2023		Jornada: 8 horas
H.U.	Tareas	Horas	Fecha Inicio	Fecha Fin
04	Desarrollar un algoritmo para el entrenamiento del algoritmo	48	16/06/2023	23/06/2023

Sprint 04				
04	Desarrollar un algoritmo de identificación de personas mediante su silueta corporal	40	26/06/2023	30/06/2023
04	Desarrollar un algoritmo de identificación de personas mediante la textura y color de la vestimenta	40	03/07/2023	07/07/2023
04	Aplicar métricas de evaluación y rendimiento	32	10/07/2023	13/07/2023

Resultados del Sprint 04

Se desarrollo un modelo capaz de identificar a personas conocidas (personas que se encuentran en el dataset) mediante su silueta corporal, la textura y color de su vestimenta. Para la identificación se utilizó técnicas de Visión por Computadora como los descriptores LBP (Local Binary Pattern) para obtener las características de la silueta corporal y HOG (Histograma de Gradientes Ordenados) para extraer las características de la textura y color de la vestimenta y los clasificadores CNN (Convolutional Neural Network) y SVM (Support Vector Machine) que analizan las características obtenidas y predicen a que clase pertenecen.

Las tablas 18, 19 y 20 exponen el pseudocódigo desarrollado para lograr la identificación de personas mediante su silueta, textura y color de la vestimenta respectivamente.

Tabla 18

Algoritmo LBP para identificación mediante la silueta corporal

Algoritmo 1: identificación por silueta corporal mediante descriptor LBP

```
# Crear el modelo LBP
modelLBP = crear_modelo_LBPHFaceRecognizer()
# Lectura del modelo de personas
modelPerson = crear_modelo_YOLO('Models/yolov8n.pt')
```

Algoritmo 1: identificación por silueta corporal mediante descriptor LBP

```

# Lectura del modelo CNN
modelCNN = crear_modelo_YOLO('Models/CNN-silhouette.pt')
# Lectura del modelo LBP
modelLBP.leer('Models/LBP-silhouette.xml')
# Capturar el video
cap = abrir_video('Videos/Angel2_Cam1.mp4')
funcion rec_LBP(x1, y1, x2, y2):
    # Extraer la región de interés ROI (silueta)
    silueta = copiar_frame(auxFrame[y1:y2, x1:x2])
    # Redimensionar la silueta
    silueta = redimensionar_imagen(silueta, (150, 150),
interpolacion=INTER_CUBIC)
    # Clasificador de reconocimiento de silueta
    resultado = modelLBP.predecir(silueta)
    # Condición del valor de confianza
    si resultado[1] > 50:
        # Calcular el tamaño del rectángulo del texto
        tamaño_texto, _ = obtener_tamaño_texto(
            '{}'.format(personsPath[resultado[0]]) + " {:.2f}".format(
                resultado[1]/100), 1, 7, 8)
        ancho_texto, alto_texto = tamaño_texto
        # Rectángulo del texto
        dibujar_rectangulo(frame, (x1, y1 - alto_texto - 25), (x1 + ancho_texto,
            y1 - 26), (0, 255, 0), -1)

        # Texto del resultado
        dibujar_texto(frame, '{}'.format(personsPath[resultado[0]]) + "
{:.2f}".format(
            resultado[1]/100), (x1, y1-24), 1, 7, (255, 255, 255), 8,
LINEA_AA)
        # Rectángulo de la cara
        dibujar_rectangulo(frame, (x1, y1),
            (x2, y2), (0, 255, 0), 10)
mientras verdadero:
    ret, frame = leer_frame(cap)
    si no ret:
        romper
    # Transformación a escala de grises
    auxFrame = convertir_a_escala_de_grises(frame)
    # Predicción con el modelo de personas
    resultadosPerson = modelPerson(frame)
    # Predicción con el modelo CNN
    resultados = modelCNN(frame)
    para cada resultado en resultados:
        # Si detecta un rostro
        si longitud(resultado.cajas) != 0:
            para cada caja en resultado.cajas:
                # Obtener las coordenadas de la región de interés ROI
                x1, y1, x2, y2 = caja.coord_xyxy[0]
                x1, y1, x2, y2 = convertir_a_entero(x1), convertir_a_entero(y1),
convertir_a_entero(x2), convertir_a_entero(y2)
                # Condición del valor de confianza
                si caja.conf[0] > 0.2:
                    frame = resultado[0].graficar()

```

Algoritmo 1: identificación por silueta corporal mediante descriptor LBP

```

    sino:
        rec_LBP(x1, y1, x2, y2)
sino:
    para cada r en resultadosPerson:
        para cada caja en r.cajas:
            # 0 = Person, son los id de las clases
            si entero(caja.cls[0]) == 0:
                continuar
            # Obtener las coordenadas de la región de interés ROI
            x1, y1, x2, y2 = caja.coord_xyxy[0]
            x1, y1, x2, y2 = convertir_a_entero(x1), convertir_a_entero(y1),
convertir_a_entero(x2), convertir_a_entero(y2)
            si caja.conf[0] < 0.35:
                frame = r[0].graficar()
                sino:
                    rec_LBP(x1, y1, x2, y2)
            # Redimensionar la imagen obtenida de frame
            frame = redimensionar_imagen(frame, ancho=1000)
            # Visualizar el resultado
            mostrar_imagen("Silueta CNN LBP", frame)
            # Para salir presionando q
            si esperar_tecla(1) & 0xFF == tecla('q'):
                romper
    cerrar_video(cap)
    cerrar_ventanas()

```

Tabla 19

Algoritmo HOG para identificación de personas mediante la textura de la vestimenta

Algoritmo 2: identificación por la textura de la vestimenta mediante descriptor HOG

```

# Lectura del modelo entrenado
clf = cargar_modelo('Models/SVM-HOG-texture.pkl')
# Lectura del modelo para extraer el ROI
modelPerson = crear_modelo_YOLO('Models\yolov8n.pt')
# Capturar el video
cap = abrir_video('Videos\Angel2_Cam1.mp4')
mientras verdadero:
    ret, frame = leer_frame(cap)
    si no ret:
        romper
    # Predicción con el modelo YOLO para obtener personas
    results = predecir_con_modelo(modelPerson, frame)
    # Transformación a escala de grises
    gray = convertir_a_escala_de_grises(frame)
    auxFrame = copiar_imagen(gray)
    para cada result en results:
        para cada box en result.bboxes:
            # 0 = Person, son los id de las clases
            si entero(box.cls[0]) == 0 y box.conf[0] > 0.60:
                # Obtener las coordenadas del ROI

```

Algoritmo 2: identificación por la textura de la vestimenta mediante descriptor HOG

```

x1, y1, x2, y2 = obtener_coordenadas(box.xyxy[0])
# Extraer la región de interés ROI (textura)
texture = copiar_imagen(auxFrame[y1:y2, x1:x2])
# Redimensionar la textura
texture = redimensionar_imagen(texture, (200, 200),
interpolacion=INTER_CUBIC)
# Calcular el descriptor HOG para la textura
hog_features = calcular_hog(texture, orientations=9,
pixels_per_cell=(8, 8), cells_per_block=(2, 2), block_norm='L2-Hys')
# Agregar la textura al descriptor HOG
texture = remodelar(hog_features, (1, -1))
texture = convertir_a_arreglo(texture, tipo=np.float32)
# Clasificador SVM
predicted_label = predecir_con_SVM(clf, texture)[0]
# Calcular el tamaño del rectángulo del texto
tamano_texto, _ =
obtener_tamano_texto('{}'.format(peopleList[predicted_label]), 1, 7, 8)
ancho_texto, alto_texto = tamano_texto
# Rectángulo del texto
dibujar_rectangulo(frame, (x1, y1 - alto_texto - 25), (x1 +
ancho_texto, y1 - 26), (0, 255, 0), -1)
# Texto del Resultado
dibujar_texto(frame, '{}'.format(peopleList[predicted_label]), (x1, y1-
24), 1, 7, (255, 255, 255), 8, LINEA_AA)
# Rectángulo de la textura
dibujar_rectangulo(frame, (x1, y1), (x2, y2), (0, 255, 0), 10)
# Redimensionar la imagen obtenida de frame
frame = redimensionar_imagen(frame, ancho=1000)
# Visualizar el resultado
mostrar_imagen("SVM HOG Textura", frame)
si esperar_tecla(1) & 0xFF == tecla('q'):
    romper
cerrar_video(cap)
cerrar_ventanas()

```

Tabla 20*Algoritmo HOG para identificación de personas mediante el color de la vestimenta***Algoritmo 3:** identificación por medio del color de la vestimenta mediante descriptor

HOG

```

# Lectura del modelo entrenado
clf = cargar_modelo('Models/SVM-HOG-color.pkl')
# Lectura del modelo para extraer el ROI
modelPerson = crear_modelo_YOLO('Models/yolov8n.pt')
# Capturar el video
cap = abrir_video('Videos\Angel2_Cam1.mp4')
mientras verdadero:
    ret, frame = leer_frame(cap)
    si no ret:

```

Algoritmo 3: identificación por medio del color de la vestimenta mediante descriptor

HOG

```

romper
# Predicción con el modelo YOLO para obtener personas
results = predecir_con_modelo(modelPerson, frame)
# Transformación a escala de grises
gray = convertir_a_escala_de_grises(frame)
auxFrame = copiar_imagen(gray)
para cada result en results:
    para cada box en result.bboxes:
        # 0 = Person, son los id de las clases
        si entero(box.cls[0]) == 0 y box.conf[0] > 0.60:
            # Obtener las coordenadas del ROI
            x1, y1, x2, y2 = obtener_coordenadas(box.xyxy[0])
            # Extraer la región de interés ROI (textura)
            texture = copiar_imagen(auxFrame[y1:y2, x1:x2])
            # Redimensionar la textura
            texture = redimensionar_imagen(texture, (200, 200),
interpolacion=INTER_CUBIC)
            # Calcular el descriptor HOG para la textura
            hog_features = calcular_hog(texture, orientations=9,
pixels_per_cell=(8, 8), cells_per_block=(2, 2), block_norm='L2-Hys')
            # Agregar la textura al descriptor HOG
            texture = remodelar(hog_features, (1, -1))
            texture = convertir_a_arreglo(texture, tipo=np.float32)
            # Clasificador SVM
            predicted_label = predecir_con_SVM(clf, texture)[0]
            imprimir('Precisión: ', predecir_con_SVM(clf, texture)[0])
            # Calcular el tamaño del rectángulo del texto
            tamaño_texto, _ =
obtener_tamaño_texto('{}'.format(peopleList[predicted_label]), 1, 7, 8)
            ancho_texto, alto_texto = tamaño_texto
            # Rectángulo del texto
            dibujar_rectangulo(frame, (x1, y1 - alto_texto - 25), (x1 +
ancho_texto, y1 - 26), (0, 255, 0), -1)
            # Texto del Resultado
            dibujar_texto(frame, '{}'.format(peopleList[predicted_label]), (x1, y1-
24), 1, 7, (255, 255, 255), 8, LINEA_AA)
            # Rectángulo de la textura
            dibujar_rectangulo(frame, (x1, y1), (x2, y2), (0, 255, 0), 10)
            # Redimensionar la imagen obtenida de frame
            frame = redimensionar_imagen(frame, ancho=1000)
            # Visualizar el resultado
            mostrar_imagen("SVM HOG Color", frame)
            si esperar_tecla(1) & 0xFF == tecla('q'):
                romper
cerrar_video(cap)
cerrar_ventanas()

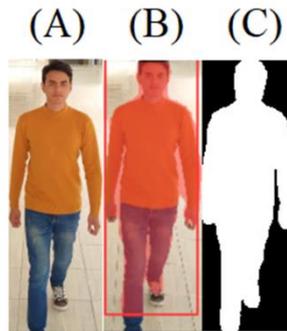
```

En la figura 15 presenta el proceso de tratamiento de la imagen para la obtención de la silueta corporal mediante características LBP. La imagen (A) corresponde a la imagen

original de la persona obtenida del dataset, la imagen (B) representa la obtención de la silueta corporal y la imagen (C) representa la transformación de la silueta corporal a una escala binaria de blanco y negro.

Figura 15

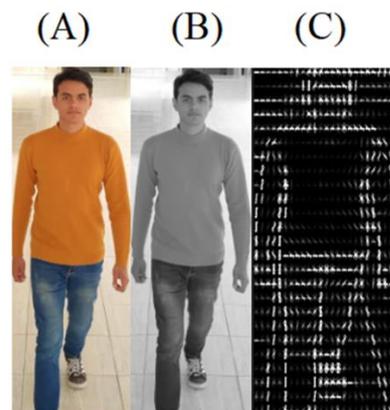
Proceso de captura de la silueta corporal



La figura 16 muestra el proceso que se realiza para la extracción de la textura de la vestimenta mediante el descriptor HOG. La imagen (A) es la imagen original obtenida del dataset, La imagen (B) es la misma imagen obtenida del dataset transformada a escala de grises y la imagen (C) es la representación de las características HOG.

Figura 16

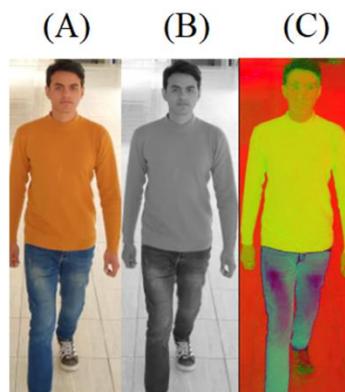
Proceso de captura de la textura de la vestimenta



La figura 17 representa el proceso realizado para la extracción del color de la vestimenta mediante el descriptor HOG. La imagen (A) es la imagen original obtenida del dataset, La imagen (B) es la misma imagen obtenida del dataset transformada a escala de grises y la imagen (C) es la representación de las características de color de la vestimenta.

Figura 17

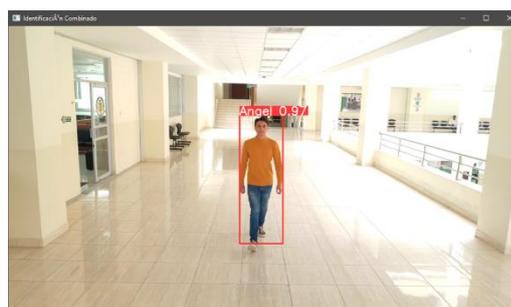
Proceso de captura del color de la vestimenta



En la figura 18 se representa el proceso de identificación de una persona mediante la combinación de sus características Soft-biométricas silueta corporal, textura y color de la vestimenta, extraídas de la parte frontal de la persona. El sistema localiza las características distintivas de la persona y la encierra en un recuadro, en la parte superior del recuadro se muestra la etiqueta, correspondiente al nombre de la persona, junto a la etiqueta se encuentra el porcentaje de predicción, representado en escala de 0 a 1 (siendo 1 el 100% de predicción).

Figura 18

Identificación frontal de la persona mediante sus características Soft-biométricas

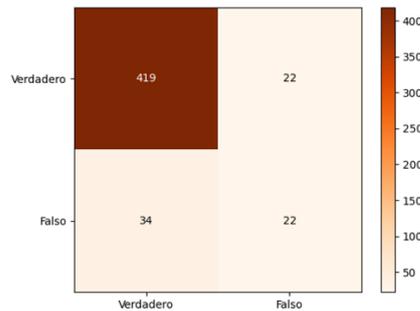


La identificación de la persona se realiza en tres recorridos diferentes, el primer recorrido, la persona camina en la parte izquierda del pasillo, en el segundo recorrido, la persona camina en el centro del pasillo y en el último recorrido, la persona camina en la parte derecha del pasillo.

En las figuras 19, 20 y 21 se puede observar la matriz de confusión aplicada al proceso de identificación de la persona en los tres recorridos, la matriz de confusión permite identificar cuantas veces el sistema reconoció a la persona, cuantas veces no la reconoció y cuantas veces realizo un reconocimiento falso.

Figura 19

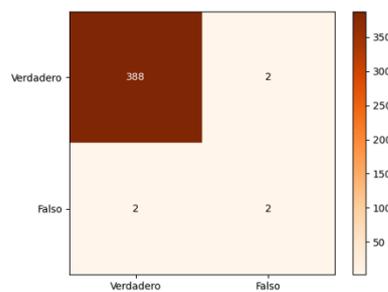
Matriz de Confusión de la clase Ángel en el primer recorrido



Nota. La matriz de confusión muestra que el modelo acertó al predecir 419 imágenes de la clase Ángel, pero, en 22 imágenes de la clase Ángel se equivocó y predijo como otra clase, en 34 imagen donde aparece la clase Ángel no logro realizar la detección y predijo que en 22 imágenes no aparece la clase Ángel.

Figura 20

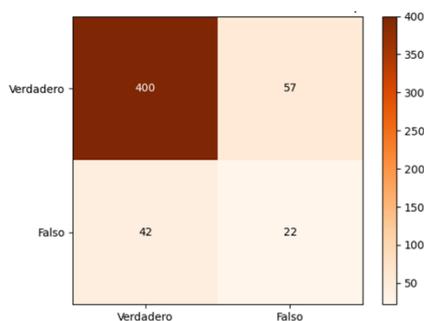
Matriz de Confusión de la clase Ángel en el segundo recorrido



Nota. La matriz de confusión expone que el modelo entrenado acertó al predecir 388 imágenes de la clase Ángel, así mismo, en 2 imágenes de la clase Ángel se equivocó y las predijo como otra clase, en 2 imagen donde aparece la clase Ángel no logro realizar la detección y predijo que en 2 imágenes no aparece la clase Ángel.

Figura 21

Matriz de Confusión de la clase Ángel en el tercer recorrido



Nota. La matriz de confusión muestra que el modelo entrenado acertó al predecir 400 imágenes de la clase Ángel, así mismo, en 57 imágenes de la clase Ángel se equivocó y las predijo como otra clase, en 42 imagen donde aparece la clase Ángel no logro realizar la detección y predijo que en 22 imágenes no aparece la clase Ángel.

La tabla 21 expone los resultados de las métricas de evaluación aplicadas al sistema de identificación mediante características Soft-biométricas, las métricas se aplican por separado a cada recorrido realizado por la persona y se calcula el promedio de los tres recorridos.

Tabla 21

Resultados de las métricas de evaluación

Clasificador	Métricas	Primer	Segundo	Tercer	Promedio
		recorrido	recorrido	recorrido	
CNN, SVM	Accuracy	0.8873	0.9898	0.8100	0.8957±0.0867
	Recall	0.9249	0.9949	0.9050	0.9416±0.0453
	Precision	0.9501	0.9949	0.8753	0.9401±0.0575

Los resultados de las métricas varían en cada recorrido, en el tercer recorrido existe una diferencia considerable en relación con el primer y segundo recorrido debido al cambio drástico de iluminación y el reflejo del suelo.

En el desarrollo del Sprint 04, no se encontraron mayores inconvenientes en el transcurso del desarrollo del sistema, se logró cumplir con todas las tareas planteadas en el

Sprint Backlog, dando como resultado tres modelos que combinados son capaces de detectar con mayor precisión a una persona mediante sus características Soft-biométricas. Los resultados obtenidos al aplicar las métricas de evaluación cumplen con las expectativas previstas.

Sprint 05: Desarrollo e implementación de un sistema de Re-ID de personas mediante sus características biométricas y Soft-biométricas

Para el desarrollo e implementación del Sprint 05 se consideró la Historia de Usuario 05, la Historia de Usuario indica que se debe desarrollar e implementar un modelo y/o algoritmo que identifique a personas mediante su vista frontal y Re-Identificarla mediante su vista posterior.

Historia de Usuario Detallada

Tabla 22

Historia de Usuario H.U.05

Historia de Usuario	
Número: H.U.05	Usuario: Usuario
Nombre historia: Desarrollo e implementación de modelo y/o algoritmo de Re-ID de personas	Número de Sprint: 5
Prioridad: Alta	Riesgo de desarrollo: Alta
Puntos estimados (días): 21	Interacción asignada: 1
Desarrolladores responsables: Bryan Jácome, Robinson Ruilova	
Descripción: Como usuario quiero que el sistema detecte a personas mediante su vista frontal y la Re-ID mediante su vista posterior utilizando características biométricas (rostro) y Soft-biométricas (silueta corporal, textura y color de la vestimenta)	
Validación:	

Historia de Usuario

- Implementar técnicas de Visión por Computadora LBP y HOG para el reconocimiento de características biométricas y Soft-biométricas.
 - Desarrollar y entrenar modelos capaces de Re-ID a personas mediante sus características Soft-biométricas.
 - Realizar pruebas a los modelos desarrollados con los dataset creados en el Sprint 01 y 03.
-

Sprint Backlog

Para el desarrollo del Sprint 05 se consideraron cuatro tareas, los responsables de cumplir con estas tareas son los integrantes del Development Team, Bryan Jácome y Robinson Ruilova. El estado de cada una de las tareas al término del Sprint 05 es finalizado.

En la tabla 23 se puede observar las tareas realizadas en el desarrollo del Sprint 05, el tiempo asignado y también se muestra la jornada de trabajo en horas.

Tabla 23

Sprint Backlog 05

Sprint 05				
Fecha Inicio: 13/07/2023		Fecha Fin: 11/08/2023		Jornada: 8 horas
H.U.	Tareas	Horas	Fecha Inicio	Fecha Fin
05	Desarrollar un algoritmo para el entrenamiento de los modelos	40	13/07/2023	19/07/2023
05	Desarrollar un algoritmo de identificación facial y extracción de características Soft-biométricas	56	20/07/2023	28/07/2023

Sprint 05

05	Desarrollar un algoritmo de Re-Identificación de personas mediante características Soft-biométricas	56	31/07/2023	08/08/2023
05	Aplicar métricas de evaluación y rendimiento	24	09/08/2023	11/08/2023

Resultados del Sprint 05

Se desarrollo un modelo capaz de identificar a personas conocidas (personas que se encuentran en el dataset) mediante su rostro y Re-Identificarlas mediante características Soft-biométricas, utilizando técnicas de Visión por Computadora como los descriptores LBP y HOG, y algoritmos de Machine Learning como CNN y SVM.

Las tablas 24 y 25 expone el pseudocódigo desarrollado para lograr la Re-ID de personas.

Tabla 24

Algoritmo de identificación de personas

Algoritmo 1: Identificación facial

```

dataPath = 'Data/Face'
peopleList = obtener_lista_personas_en_directorio(dataPath)
modelLBP = crear_modelo_LBP()
modelLBP.cargar_desde_archivo('Models/CNN-LBP-face.xml')
modelPerson = cargar_modelo_YOLO('Models/yolov8n-face.pt')

mientras Verdadero:
    ret, frame = leer_siguiente_frame_de_capV1()

    si no ret:
        romper

    resultados = modelPerson.detectar_objetos(frame)

    por cada resultado en resultados:
        por cada caja en resultado.cajas:
            si caja.confianza > 0.30:
                x1, y1, x2, y2 = caja.obtener_coordenadas()

```

Algoritmo 1: Identificación facial

```

        x1, y1, x2, y2 = convertir_a_entero(x1), convertir_a_entero(y1),
convertir_a_entero(x2), convertir_a_entero(y2)
        cara = recortar_region_de_interes(frame, y1, y2, x1, x2)
        cara = redimensionar_imagen(cara, 200, 200)
        cara = convertir_a_escalade_grises(cara)
        resultadoLBP = modelLBP.predecir(cara)
        si (100-resultadoLBP[1]) > 60:
            tamaño_texto, _ = obtener_tamaño_texto('{}
{}'.format(peopleList[resultadoLBP[0]], "{:.2f}".format((100-resultadoLBP[1])/100)), 1,
6, 8)

            ancho_texto, alto_texto = tamaño_texto
            dibujar_rectangulo_texto(frame, x1, y1 - alto_texto - 25, x1 +
ancho_texto, y1 - 26, (0, 255, 0), -1)
            dibujar_texto(frame, '{} {}'.format(peopleList[resultadoLBP[0]], "
{:.2f}".format((100-resultadoLBP[1])/100)), x1, y1-24, 1, 5, (255, 255, 255), 8,
CV2.LINE_AA)

            dibujar_rectangulo(frame, x1, y1, x2, y2, (0, 255, 0), 10)

        frame = redimensionar_imagen(frame, ancho=1000)
        mostrar_imagen("CNN-LBP Face", frame)
        si presionar_tecla(1) y tecla == 'q':
            romper

    liberar_capV1()
    cerrar_ventana()

```

Tabla 25*Algoritmo de Re-ID de personas*

Algoritmo 2: Re-ID de personas

```

    éxito, img = capturar_siguiente_frame(cap)
    # img = aplicar_filtro_mediana(img, 9)
    resultados = detectar_objetos_con_modelo(model, img, True, iou_thres)
    predict = predecir_con_modelo(model, img)
    salida =
convertir_mascara_a_imagen_binaria(predict[0].masks.masks[0].numpy() * 255)
    contornos, jerarquia = encontrar_contornos(salida, cv2.RETR_TREE,
cv2.CHAIN_APPROX_SIMPLE)
    gray = convertir_a_escalade_grises(img)
    auxFrame_textura = copiar_imagen(gray)
    img_color = convertir_a_hsv(img)
    gray_color = convertir_a_escalade_grises(img_color)
    auxFrame_color = copiar_imagen(gray_color)
    auxFrame_color1 = copiar_imagen(img_color)

    para cada r en resultados:
        cajas = r.boxes
        para cada caja en cajas:
            cls = obtener_clase_de_caja(caja)
            si classNames[cls] != "persona":

```

Algoritmo 2: Re-ID de personas

```

continuar
x1, y1, x2, y2 = obtener_coordenadas_de_caja(caja)
x1, y1, x2, y2 = convertir_a_entero(x1), convertir_a_entero(y1),
convertir_a_entero(x2), convertir_a_entero(y2)
dibujar_rectangulo(img, (x1, y1), (x2, y2), (255, 255, 255), 3)
x, y, ancho, alto = obtener_rectangulo_delimitador(contornos[0])
textura = recortar_region_de_interes(auxFrame_textura, y1, y2, x1, x2)
color = recortar_region_de_interes(auxFrame_color, y1, y2, x1, x2)
color1 = recortar_region_de_interes(auxFrame_color1, y1, y2, x1, x2)
roi = recortar_region_de_interes(salida, y, y + alto, x, x + ancho)
_, silueta = aplicar_umbral(roi, 1, 255, cv2.THRESH_BINARY)
silueta = redimensionar_imagen(silueta, x2 - x1, y2 - y1)
mostrar_imagen("binario", silueta)
mostrar_imagen("color", color1)
resultado_silueta = predecir_con_reconocedor_de_caras(silueta)
resultado_textura = predecir_con_reconocedor_de_caras(textura)
resultado_color = predecir_con_reconocedor_de_caras(color)
conf_silueta = 1 - obtener_confianza_normalizada(resultado_silueta[1])
conf_textura = 1 - obtener_confianza_normalizada(resultado_textura[1])
conf_color = 1 - obtener_confianza_normalizada(resultado_color[1])
min_conf = obtener_minima_confianza(conf_silueta, conf_textura,
conf_color)
si min_conf == conf_silueta:
    index = obtener_indice(resultado_silueta[0])
sino si min_conf == conf_textura:
    index = obtener_indice(resultado_textura[0])
sino:
    index = obtener_indice(resultado_color[0])
etiqueta = obtener_etiqueta_de_imagen(imagePaths[index])
mostrar_resultados(resultado_silueta, resultado_textura,
resultado_color)
resultados_ordenados = ordenar_resultados(resultado_silueta,
resultado_textura, resultado_color)

marco = redimensionar_imagen(img, ancho=1000)
mostrar_imagen('Re-ID de personas', marco)

```

La figura 19 muestra la Re-ID de una persona mediante la combinación de sus características Soft-biométricas silueta corporal, textura y color de la vestimenta. El sistema identifica las características distintivas de la persona y la encierra en un recuadro, en la parte superior se muestra la etiqueta, correspondiente al nombre de la persona y el porcentaje de predicción, representado en la escala de 0 a 1 (siendo 1 el 100% de predicción).

Figura 22

Re-ID de la persona mediante sus características Soft-biométrica



Capítulo IV

Definición y Aplicación de Métricas de Evaluación

Este capítulo ofrece una descripción detallada de los experimentos realizados. Incluye una descripción exhaustiva del sistema de evaluación utilizado, un análisis minucioso de los parámetros de evaluación empleados y una presentación visual de los resultados obtenidos, que luego se comentan en detalle.

Marco de Evaluación

Se realizó cuatro diferentes pruebas al sistema de Re-Identificación de personas: la primera se identificó a la persona mediante sus características faciales, utilizando la cámara uno; en la segunda, se Re-Identificó a la misma persona mediante sus características del color de la vestimenta, utilizando la cámara dos. En el tercer escenario, las personas se identificaron basándose en características de textura (utilizando la cámara 1). Por último, en el cuarto escenario, identificamos a las personas basándonos en su silueta (utilizando la cámara 2).

El sistema se basa en seis procesadores que se sincronizan con las necesidades cambiantes en tiempo real, lo que lo hace versátil. El primer procesador se centra en el reconocimiento facial. El segundo procesador utiliza un enfoque experimental basado en la textura y la silueta corporal, ampliando el alcance de la información que puede captarse.

El tercer procesador desempeña un papel clave en la creación de un conjunto de datos que documenta los cambios de ropa y postura. La posterior extracción de descriptores de color de la ropa constituye la base de un modelo de color altamente adaptable que puede reflejar con precisión la cambiante diversidad cromática.

En el cuarto proceso, se realiza un salto cualitativo utilizando el modelo de color previamente creado. En este paso, los descriptores de color se combinan con los datos adicionales obtenidos en los pasos anteriores para identificar y Re-Identificar con precisión los rostros objetivo. El resultado es un sistema completo y fiable que identifica a las personas de forma impecable, incluso en condiciones visuales difíciles.

La incorporación de un quinto procesador enriquece aún más el proceso y mejora el rendimiento en todas las etapas, desde el reconocimiento facial hasta la fase final de Re-Identificación. La variedad de fuentes visuales, que son vídeos de distintas personas en diferentes escenarios, proporciona una gran cantidad de datos que mejoran la capacidad del sistema para realizar un reconocimiento y una Re-Identificación cada vez más eficaces en diferentes contextos y a lo largo del tiempo.

Por último, el sexto procesador simboliza la cúspide de la operación, optimizando aún más cada etapa del procedimiento. Esta ampliación de los recursos garantiza una eficacia en el reconocimiento de personas y aumenta la robustez y precisión del sistema. Cada uno de estos procesadores trabaja en armonía para crear un sistema no holístico que responde a los retos de la Re-Identificación en escenarios diversos y cambiantes.

Definición de Métricas de Evaluación

Para evaluar el rendimiento del sistema del modelo de aprendizaje automático, se utilizarán las métricas de evaluación más convencionales mencionadas anteriormente. Estas métricas, junto con sus respectivas fórmulas, se detallan en el capítulo 2, en el apartado "Métricas de Evaluación". Entre las métricas a utilizar se encuentran: accuracy, precisión, recall (o sensibilidad), F1 score y la matriz de confusión.

Aplicación de Métricas de Evaluación

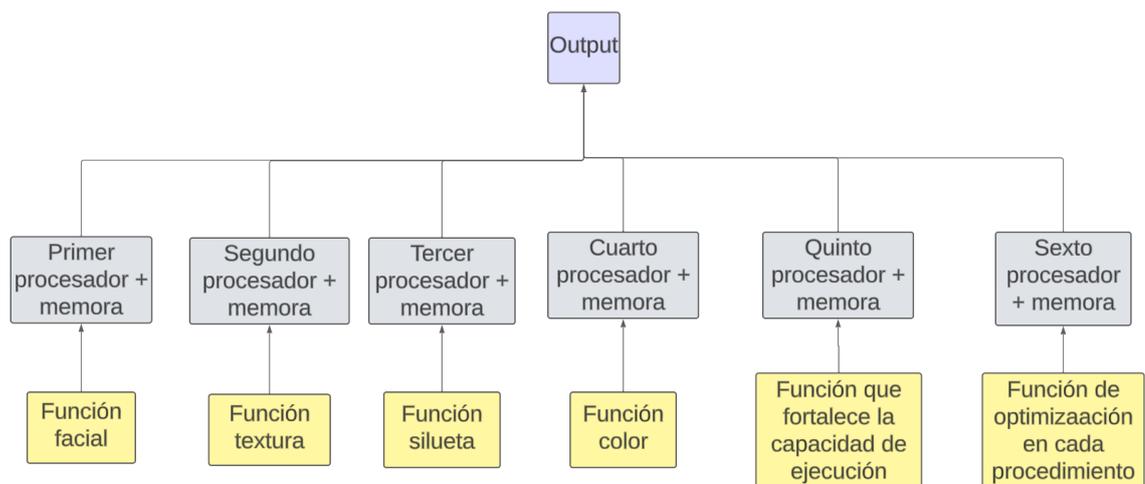
El proceso para aplicar estas métricas al sistema propuesto y comprobar que son correctas, se probó cada algoritmo por separado. Esto incluye el algoritmo de Re-Identificación facial, silueta corporal, color y textura de la vestimenta. Una vez realizadas estas evaluaciones individuales, se integran todos los algoritmos en su conjunto.

Esta integración mide el tiempo que se tarda en ejecutar todo el sistema. Así se obtiene una visión general del rendimiento de cada componente individual y de la interacción entre ellos. Esta evaluación no holística es crucial para determinar el rendimiento global del sistema y proporciona información valiosa para futuras optimizaciones y adaptaciones.

A continuación, presentamos pruebas con cinco personas para evaluar la eficacia del modelo de reconocimiento facial previamente entrenado. Estas pruebas se diseñaron para obtener los resultados verdadero positivo, verdadero negativo, falso positivo y falso negativo comentados en el segundo capítulo.

Figura 23

Multiprocesamiento



Nota. Para realizar las pruebas se utilizan seis procesadores, cada uno de ellos dividido en distintos sectores de memoria para realizar diferentes tareas. Estos procesadores realizan estas tareas en paralelo. El primer procesador se utiliza para Re-Identificar al individuo mediante biometría facial. Los procesadores segundos a sexto, por su parte, se centran en Re-Identificar a los individuos basándose en características Soft biométricas como la silueta corporal, la textura y color de la vestimenta.

Figura 24

Re-Identificación facial con el modelo entrenado



Figura 25

Re-Identificación mediante las características Soft-biométricas con el modelo entrenado



Nota. Se muestra la Re-ID de los individuos con los que se realizaron las pruebas Re-Identificando sus características Soft-biométricas en su primer recorrido, en la etiqueta se observa el nombre de la clase junto con el porcentaje de precisión.

Pruebas al sistema de Re-ID facial

Para realizar las pruebas al sistema de Re-ID facial utilizando un dataset que contiene videos de 5 personas (3 videos por persona), a continuación, se aplica las métricas de evaluación para medir el rendimiento y robustez del sistema de identificación facial.

Se creará una tabla donde se presentará los resultados obtenidos de las pruebas realizadas al sistema de identificación facial.

Figura 26

Re-ID facial de la clase Alex

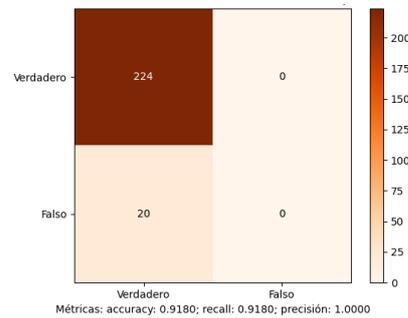


Nota. Se muestra la exitosa Re-ID de la clase Alex en su primer recorrido, en la etiqueta se observa el nombre de la clase junto con el porcentaje de precisión.

En las figuras 27, 28 y 29 se muestran los resultados obtenidos de la aplicación de la matriz de confusión y de las métricas de evaluación en la clase Alex en sus tres recorridos.

Figura 27

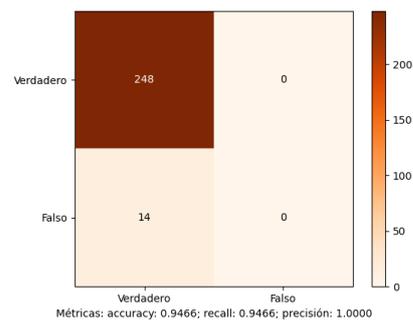
Matriz de Confusión de la Re-ID facial en el primer recorrido



Nota. Se expone la matriz de confusión aplicada al primer recorrido de Alex, los resultados obtenidos son: VP = 224, FP = 0, FN = 20, VN = 0. Estos resultados demuestran que el sistema tiene un alto porcentaje de predicción.

Figura 28

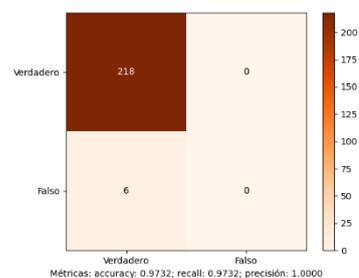
Matriz de Confusión de la Re-ID facial en el segundo recorrido



Nota. Se expone la matriz de confusión aplicada al segundo recorrido de Alex, los resultados obtenidos son: VP = 248, FP = 0, FN = 14, VN = 0. Estos resultados demuestran que el sistema tiene un alto porcentaje de predicción y robustez.

Figura 29

Matriz de Confusión de la Re-ID facial en el tercer recorrido



Nota. Se expone la matriz de confusión aplicada al tercer recorrido de Alex, los resultados obtenidos son: VP = 218, FP = 0, FN = 6, VN = 0. Estos resultados demuestran que el sistema tiene un alto porcentaje de predicción y robustes.

Tabla 26

Resultados de la Métrica de Evaluación Accuracy

Recorrido	Clasificador	Métricas	Valor
#1	CNN	Accuracy	0.9180
#2	CNN	Accuracy	0.9466
#3	CNN	Accuracy	0.9732

Tabla 27

Resultados al aplicar la Métricas de Evaluación al sistema de Re-ID facial

Persona	Recorrido	Clasificador	Accuracy	Precisión	Recall
Alex	#1	CNN	0.8927	0.9655	0.9180
	#2		0.9075	0.9538	0.9466
	#3		0.9522	0.9776	0.9732
Ángel	#1	CNN	0.9180	1.000	0.9180
	#2		0.9466	1.000	0.9466
	#3		0.9732	1.000	0.9732
Diego	#1	CNN	0.9221	0.9498	0.9693
	#2		0.9410	0.9558	0.9825
	#3		0.8982	0.9531	0.9385
Flor	#1	CNN	0.9032	0.9459	0.9496
	#2		0.9109	0.9615	0.9414
	#3		0.9197	0.9528	0.9610
Jhon	#1	CNN	0.9251	0.9818	0.9373
	#2		0.9262	0.9493	0.9740
	#3		0.9300	0.9485	0.9751

Nota. Se presenta los resultados de las métricas de evaluación aplicadas al sistema de Re-Identificación facial, los resultados obtenidos son satisfactorios.

Los resultados son obtenidos al realizar tres recorridos utilizando la característica biométrica facial con el escenario de una cámara, utilizando la cámara uno.

Tabla 28

Resultados obtenidos de las pruebas realizadas al sistema de Re-ID facial dando una predicción de Identificado en cada recorrido

Clase	Recorrido	Resultado esperado	Resultado Obtenido	Porcentaje de predicción
Alex	#1	Alex	Alex	90,12%%
	#2	Alex	Alex	91,75%
	#3	Alex	Alex	89,63%
Ángel	#1	Ángel	Ángel	93,72%
	#2	Ángel	Ángel	95,28%
	#3	Ángel	Ángel	92,85%
Diego	#1	Diego	Diego	91,57%
	#2	Diego	Diego	93,11%
	#3	Diego	Diego	90,94%
Flor	#1	Flor	Flor	95,92%
	#2	Flor	Flor	96,83%
	#3	Flor	Flor	94,76%
Jhon	#1	Jhon	Jhon	92,47%
	#2	Jhon	Jhon	94,39%
	#3	Jhon	Jhon	91,82%
	Promedio			92,96%
	Desviación estándar			±1,85

Nota. La tabla expone el porcentaje de predicción de todas las personas en sus tres recorridos, dando un promedio de 92,96% una vez ejecutado el sistema de Re-ID facial. El

primer identificado del primer recorrido fue Alex, luego Ángel, Diego, Flor y Jhon, así mismo fueron para los otros dos recorridos. El porcentaje de predicción representa que tan seguro está el modelo de su propia predicción.

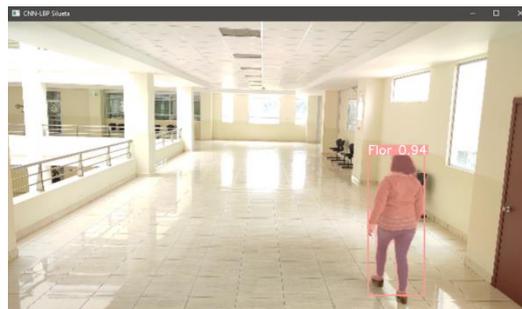
Pruebas al sistema de Re-ID mediante la silueta corporal

Para realizar esta prueba se utilizó un conjunto de datos (dataset) que contenía vídeos de cinco individuos únicos, cada uno con tres vídeos diferentes, para probar el sistema Re-ID utilizando información de textura. A continuación, se utilizaron métricas de evaluación para cuantificar el rendimiento y la solidez del sistema Re-ID.

Se creará una tabla donde se presentará los resultados obtenidos de las pruebas realizadas al sistema de Re-ID mediante la silueta corporal.

Figura 30

Re-ID mediante la silueta corporal

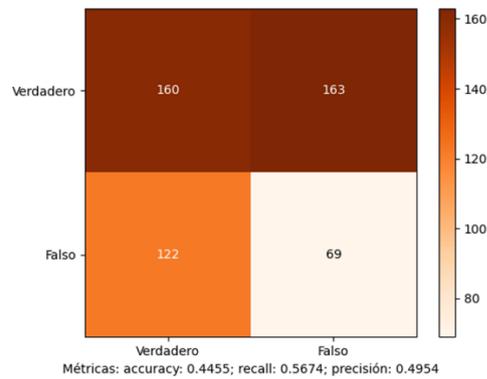


Nota. Se muestra la Re-ID de la clase Flor mediante su característica Soft-biométrica de la silueta corporal.

En las figuras 31, 32 y 33 se muestran los resultados obtenidos de la aplicación de la matriz de confusión y de las métricas de evaluación en la clase Flor en sus tres recorridos.

Figura 31

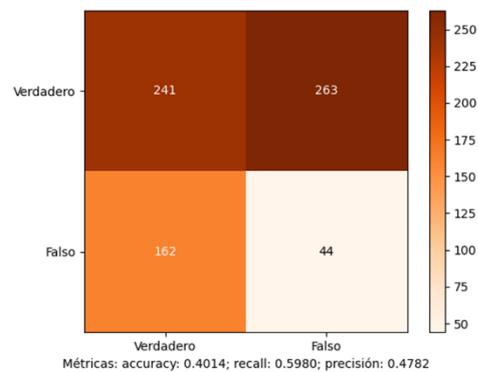
Matriz de Confusión de la Re-ID mediante la silueta corporal



Nota. Se expone la matriz de confusión aplicada al primer recorrido de Flor, los resultados obtenidos son: VP = 160, FP = 163, FN = 122, VN = 69. La cantidad de falsos negativos se debe a que al usar un análisis no holístico no identifica al comenzar el video y este tarda pocos segundos hasta identificar de manera correcta al individuo.

Figura 32

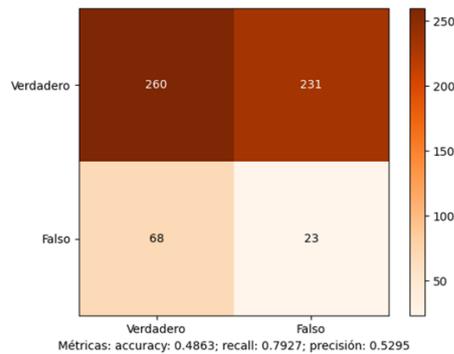
Matriz de Confusión de la Re-ID mediante la silueta corporal



Nota. Se expone la matriz de confusión aplicada al segundo recorrido de Flor, los resultados obtenidos son: VP = 241, FP = 263, FN = 162, VN = 44.

Figura 33

Matriz de Confusión de la Re-ID mediante la silueta corporal



Nota. Se expone la matriz de confusión aplicada al tercer recorrido de Flor, los resultados obtenidos son: VP = 260, FP = 231, FN = 68, VN = 23.

Tabla 29

Resultados de la Métrica de Evaluación Accuracy

Recorrido	Clasificador	Métricas	Valor
#1	CNN	Accuracy	0.4455
#2	CNN	Accuracy	0.4014
#3	CNN	Accuracy	0.4863

Tabla 30

Resultados al aplicar las Métricas de Evaluación el sistema de Re-ID mediante la silueta corporal

Persona	Recorrido	Clasificador	Accuracy	Precisión	Recall
Alex	#1	CNN	0.4214	0.4823	0.6516
	#2		0.4121	0.4556	0.5631
	#3		0.4444	0.4837	0.6693
Ángel	#1	CNN	0.3976	0.4398	0.5263
	#2		0.4411	0.4890	0.5894
	#3		0.4164	0.4770	0.6035
Diego	#1	CNN	0.4653	0.4873	0.6694

Persona	Recorrido	Clasificador	Accuracy	Precisión	Recall
Flor	#2	CNN	0.4465	0.4487	0.7420
	#3		0.3951	0.3974	0.6221
	#1		0.4455	0.4954	0.5674
	#2		0.4014	0.4782	0.5980
	#3		0.4863	0.5295	0.7927
	#1		0.3829	0.4001	0.6105
Jhon	#2	CNN	0.4127	0.4912	0.6580
	#3		0.4054	0.4825	0.6463
	#1		0.3829	0.4001	0.6105

Nota. Se muestra los resultados obtenidos al aplicar las métricas de evaluación en el sistema de Re-ID mediante la silueta corporal, las métricas se aplicaron a los tres recorridos de las cinco personas del dataset, en donde los resultados obtenidos aplicando el clasificar CNN nos brinda presiones exactas de los individuos con los cuales se probó el sistema.

Los resultados son obtenidos al realizar tres recorridos utilizando la característica Soft-biométrica silueta corporal con el escenario de una cámara, utilizando la cámara dos.

Tabla 31

Resultados obtenidos de las pruebas realizadas al sistema de Re-ID mediante la silueta corporal con una predicción de Identificado en cada recorrido.

Clase	Recorrido	Resultado esperado	Resultado Obtenido	Porcentaje de predicción
Alex	#1	Alex	Alex	38,15%
	#2	Alex	Alex	37,72%
	#3	Alex	Alex	32,51%
Ángel	#1	Ángel	Ángel	35,89%
	#2	Ángel	Ángel	31,94%
	#3	Ángel	Ángel	30,48%

Clase	Recorrido	Resultado esperado	Resultado Obtenido	Porcentaje de predicción
Diego	#1	Diego	Diego	34,12%
	#2	Diego	Diego	36,25%
	#3	Diego	Diego	30,85%
Flor	#1	Flor	Flor	31,67%
	#2	Flor	Flor	33,28%
	#3	Flor	Flor	30,12%
Jhon	#1	Jhon	Jhon	37,43%
	#2	Jhon	Jhon	38,97%
	#3	Jhon	Jhon	31,56%
Promedio				33,55%
Desviación estándar				$\pm 0,0257$

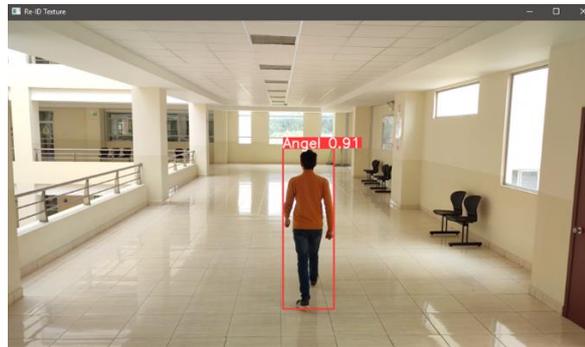
Nota. La tabla expone el porcentaje de predicción de todas las personas en sus tres recorridos, dando un promedio de 33,55% una vez ejecutado el sistema de Re-ID mediante la silueta corporal. El porcentaje de predicción representa que tan seguro está el modelo de su propia predicción.

Pruebas al algoritmo de Re-Identificación mediante la textura de la vestimenta

Para realizar esta prueba se utilizó un conjunto de datos (dataset) que contenía vídeos de cinco individuos únicos, cada uno con tres vídeos diferentes, para probar el sistema Re-ID utilizando información de textura. A continuación, se utilizaron métricas de evaluación para cuantificar el rendimiento y la solidez del sistema Re-ID.

Figura 34

Re-Identificación mediante la textura de la vestimenta

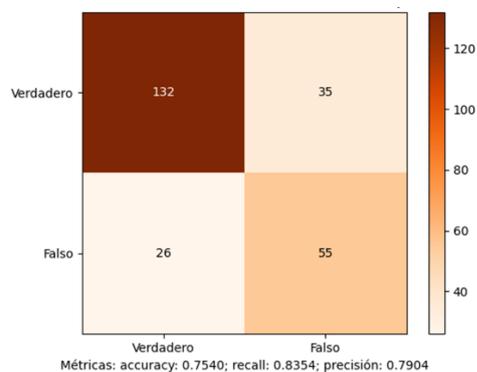


Nota. Se muestra la Re-ID de la clase Ángel en el segundo recorrido mediante la característica Soft-biométrica de la textura de la vestimenta.

En las figuras 35, 36 y 37 se muestran los resultados obtenidos de la aplicación de la matriz de confusión y de las métricas de evaluación en la clase Ángel en sus tres recorridos.

Figura 35

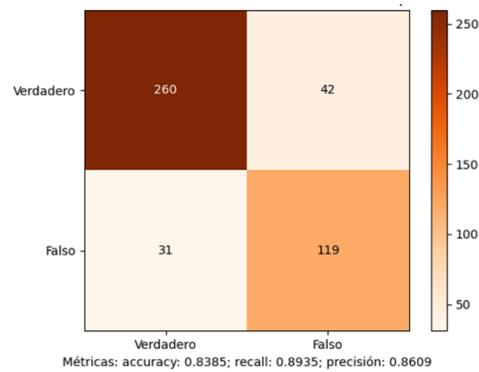
Matriz de Confusión de la Re-ID mediante la textura de la vestimenta



Nota. Se expone la matriz de confusión aplicada al primer recorrido de Ángel, los resultados obtenidos son: VP = 132, FP = 35, FN = 26, VN = 55.

Figura 36

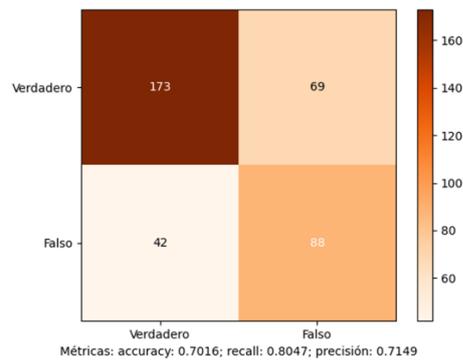
Matriz de Confusión de la Re-ID mediante la textura de la vestimenta



Nota. Se expone la matriz de confusión aplicada al segundo recorrido de Ángel, los resultados obtenidos son: VP = 260, FP = 42, FN = 31, VN = 119.

Figura 37

Matriz de Confusión de la Re-ID mediante la textura de la vestimenta



Nota. Se expone la matriz de confusión aplicada al tercer recorrido de Ángel, los resultados obtenidos son: VP = 173, FP = 69, FN = 42, VN = 88.

Tabla 32

Resultados de la Métrica de Evaluación Accuracy

Recorrido	Clasificador	Métricas	Valor
#1	SVM	Accuracy	0.7540
#2	SVM	Accuracy	0.8385
#3	SVM	Accuracy	0.7016

Tabla 33*Resultados del sistema de Re-Identificación mediante la textura de la vestimenta*

Persona	Recorrido	Clasificador	Accuracy	Precisión	Recall
Alex	#1	SVM	0.7373	0.7617	0.8750
	#2		0.8485	0.9590	0.8673
	#3		0.7556	0.7452	0.9281
Ángel	#1	SVM	0.7540	0.7904	0.8354
	#2		0.8385	0.8609	0.8935
	#3		0.7016	0.7149	0.8047
Diego	#1	SVM	0.7810	0.8293	0.8981
	#2		0.8217	0.8225	0.9633
	#3		0.7264	0.7670	0.8935
Flor	#1	SVM	0.7190	0.7562	0.8097
	#2		0.8046	0.8338	0.8793
	#3		0.7235	0.7589	0.8610
Jhon	#1	SVM	0.7810	0.8851	0.7859
	#2		0.7578	0.7555	0.8873
	#3		0.7083	0.7256	0.8238

Nota. Se muestra los resultados obtenidos al aplicar las métricas de evaluación en el sistema de Re-ID mediante la textura de la vestimenta, las métricas se aplicaron a los tres recorridos de las cinco personas del dataset.

Los resultados son obtenidos al realizar tres recorridos utilizando la característica Soft-biométrica textura de la vestimenta con el escenario de una cámara, utilizando la cámara dos.

Tabla 34

Resultados obtenidos de las pruebas realizadas al sistema de Re-ID mediante la textura de la vestimenta con una predicción de Identificado en cada recorrido.

Clase	Recorrido	Resultado esperado	Resultado Obtenido	Porcentaje de predicción
Alex	#1	Alex	Alex	92,17%
	#2	Alex	Alex	94,23%
	#3	Alex	Alex	85,64%
Ángel	#1	Ángel	Ángel	91,36%
	#2	Ángel	Ángel	89,91%
	#3	Ángel	Ángel	86,78%
Diego	#1	Diego	Diego	88,73%
	#2	Diego	Diego	91,22%
	#3	Diego	Diego	87,53%
Flor	#1	Flor	Flor	95,40%
	#2	Flor	Flor	89,97%
	#3	Flor	Flor	86,22%
Jhon	#1	Jhon	Jhon	93,12%
	#2	Jhon	Jhon	92,40%
	#3	Jhon	Jhon	87,94%
Promedio				89,76%
Desviación estándar				±0,0297

Nota. La tabla expone el porcentaje de predicción de todas las personas en sus tres recorridos, dando un promedio de 89,76% una vez ejecutado el sistema de Re-ID mediante la textura de la vestimenta. El primer identificado del primer recorrido fue Alex, luego Ángel, Diego, Flor y Jhon, así mismo fueron para los otros dos recorridos. El porcentaje de predicción representa que tan seguro está el modelo de su propia predicción.

Pruebas al algoritmo de Re-Identificación de color de la vestimenta

Para realizar las pruebas al sistema de Re-ID mediante el color de la vestimenta, se utilizó un dataset que contiene videos de 5 personas (3 videos por persona), a continuación, se aplica las métricas de evaluación para medir el rendimiento y robustes del sistema de Re-ID mediante la textura de la vestimenta.

Figura 38

Re-Identificación mediante el color de la vestimenta

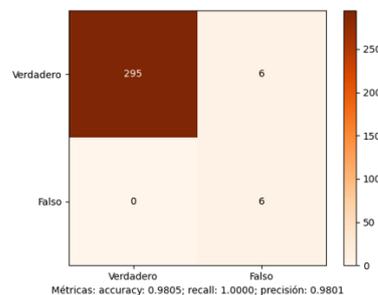


Nota. Se muestra la Re-Identificación de la clase Ángel en el segundo recorrido mediante la característica Soft-biométrica del color de la vestimenta, la Re-Identificación se realiza en la cámara dos.

En las figuras 39, 40 y 41 se muestran los resultados obtenidos de la aplicación de la matriz de confusión y de las métricas de evaluación en la clase Ángel en sus tres recorridos.

Figura 39

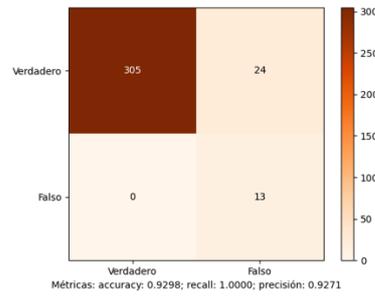
Matriz de Confusión de la Re-Identificación mediante el color de la vestimenta



Nota. Se expone la matriz de confusión aplicada al primer recorrido de Ángel, los resultados obtenidos son: VP = 295, FP = 6, FN = 0, VN = 6.

Figura 40

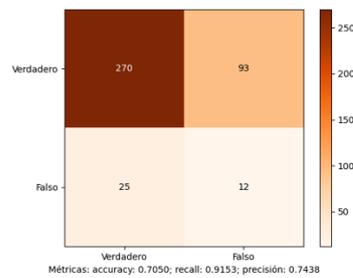
Matriz de Confusión de la Re-Identificación mediante el color de la vestimenta



Nota. Se expone la matriz de confusión aplicada al segundo recorrido de Ángel, los resultados obtenidos son: VP = 305, FP = 24, FN = 0, VN = 13.

Figura 41

Matriz de Confusión de la Re-Identificación mediante el color de la vestimenta



Nota. Se expone la matriz de confusión aplicada al segundo recorrido de Ángel, los resultados obtenidos son: VP = 207, FP = 93, FN = 25, VN = 12.

Tabla 35

Resultados de la métrica de evaluación Accuracy

Recorrido	Clasificador	Métricas	Valor
#1	SVM	Accuracy	0.9805
#2	SVM	Accuracy	0.9298
#3	SVM	Accuracy	0.7050

Tabla 36

Resultados al aplicar las métricas de evaluación al sistema de Re-Identificación mediante el color de la vestimenta

Persona	Recorrido	Clasificador	Accuracy	Precisión	Recall
Alex	#1	SVM	0.9002	0.9373	0.9281
	#2		0.9173	0.9544	0.9486
	#3		0.7944	0.8404	0.9186
Ángel	#1	SVM	0.9805	0.9801	10.000
	#2		0.9298	0.9271	10.000
	#3		0.7050	0.7438	0.9153
Diego	#1	SVM	0.9085	0.9280	0.9667
	#2		0.9256	0.9326	0.9815
	#3		0.8255	0.8673	0.9213
Flor	#1	SVM	0.9106	0.9465	0.9525
	#2		0.9157	0.9346	0.9662
	#3		0.8380	0.8851	0.9164
Jhon	#1	SVM	0.9207	0.9484	0.9622
	#2		0.9125	0.9360	0.9624
	#3		0.7907	0.8295	0.9267

Nota. Se presenta los resultados de la aplicación de las métricas de evaluación en el Sistema de Re-Identificación mediante el color de la vestimenta.

Los resultados son obtenidos al realizar tres recorridos utilizando la característica Soft-biométrica color de la vestimenta con el escenario de una cámara, utilizando la cámara dos.

Tabla 37

Resultados obtenidos de las pruebas realizadas al sistema de Re-ID mediante el color de la vestimenta con una predicción de Identificado en cada recorrido.

Clase	Recorrido	Resultado esperado	Resultado Obtenido	Porcentaje de predicción
Alex	#1	Alex	Alex	88,24%
	#2	Alex	Alex	82,57%
	#3	Alex	Alex	80,14%
Ángel	#1	Ángel	Ángel	80,63%
	#2	Ángel	Ángel	85,37%
	#3	Ángel	Ángel	81,49%
Diego	#1	Diego	Diego	84,32%
	#2	Diego	Diego	81,97%
	#3	Diego	Diego	80,42%
Flor	#1	Flor	Flor	91,48%
	#2	Flor	Flor	88,62%
	#3	Flor	Flor	82,76%
Jhon	#1	Jhon	Jhon	87,09%
	#2	Jhon	Jhon	83,71%
	#3	Jhon	Jhon	80,92%
Promedio				84,86%
Desviación estándar				±0,0318

Nota. La tabla expone el porcentaje de predicción de todas las personas en sus tres recorridos, dando un promedio de 84,86% una vez ejecutado el sistema de Re-ID mediante el color de la vestimenta. El primer identificado del primer recorrido fue Alex, luego Ángel, Diego, Flor y Jhon, así mismo fueron para los otros dos recorridos. El porcentaje de predicción representa que tan seguro está el modelo de su propia predicción.

Los resultados son obtenidos al realizar tres recorridos utilizando las características Soft-biométricas silueta corporal, textura y color de la vestimenta con el escenario de una cámara, utilizando la cámara dos.

Tabla 38

Resultados obtenidos de las pruebas realizadas al sistema de Re-ID a través de la combinación de las características con una predicción de Identificado en cada recorrido

Clase	Recorrido	Resultado esperado	Resultado Obtenido	Porcentaje de predicción
Alex	#1	Alex	Alex	82,45%
	#2	Alex	Alex	83,12%
	#3	Alex	Alex	80,34%
Ángel	#1	Ángel	Ángel	85,72%
	#2	Ángel	Ángel	85,16%
	#3	Ángel	Ángel	81,95%
Diego	#1	Diego	Diego	88,03%
	#2	Diego	Diego	89,47%
	#3	Diego	Diego	81,79%
Flor	#1	Flor	Flor	83,94%
	#2	Flor	Flor	86,27%
	#3	Flor	Flor	81,02%
Jhon	#1	Jhon	Jhon	87,12%
	#2	Jhon	Jhon	83,91%
	#3	Jhon	Jhon	80,57%
Promedio				84,05%
Desviación estándar				±0,0235

Nota. La tabla expone el porcentaje de predicción de todas las personas en sus tres recorridos, dando un promedio de 84,05% una vez ejecutado el sistema de Re-ID mediante

la combinación de las características Soft-biométricas silueta corporal, textura y color de la vestimenta. El porcentaje de predicción representa que tan seguro está el modelo de su propia predicción.

Capítulo V

Conclusiones

Conclusiones

Un análisis del estado del arte muestra que existe poca documentación sobre el reconocimiento del color, la textura y la silueta de las personas, en comparación con la amplia y suficiente base documental para el reconocimiento facial; por lo tanto, se espera que este trabajo de investigación tenga mayor importancia en el futuro y sirva de base fundamental para futuras investigaciones.

Se desarrolló un sistema de Re-Identificación de personas mediante el uso de algoritmos de visión por computadora y Machine Learning; la invención se llevó a cabo en un entorno controlado en la ESPE sede Latacunga campus Belisario Quevedo; el sistema se basa en características biométricas como rasgos faciales y características Soft-biométricas como silueta corporal, textura y color de la ropa; se realizó una evaluación para validar los resultados y analizar los posibles errores; los resultados mostraron que para el color de la ropa es de un 84,86%, 33,55% para la silueta corporal, 89,76% para la textura y 92,96% para el modelo de reconocimiento facial.

Se realizaron evaluaciones utilizando matrices de confusión para identificar los verdaderos positivos, los verdaderos negativos, los falsos positivos y los falsos negativos; los resultados se utilizaron para validar los datos a través del reconocimiento del color de la ropa, la textura y la silueta, así como de los rasgos faciales; los resultados mostraron un error mínimo en los estudios y confirmaron la fiabilidad de los métodos utilizados.

El desarrollo de la tesina nos brindó un amplio conocimiento en el área de Re-Identificación de personas utilizando características biométricas como el rostro y Soft-biométricas como la silueta corporal, textura y color de la vestimenta.

Bibliografía

- Akagündüz, E. (2015). Shape recognition using orientational and morphological scale-spaces of curvatures. *IET Computer Vision*, 9(5), 750-757. <https://doi.org/10.1049/iet-cvi.2015.0012>
- Alejandra, M.-O. D. (2016). Re-identificación de personas a través de sus características soft-biométricas en un entorno multi-cámara de video-vigilancia. *Ingeniería, Investigación y Tecnología*, 17(2), 257-271. <https://doi.org/10.1016/j.riit.2016.06.010>
- Arboleda, C. T., & Guerrero, M. I. (2015). Detección de poses de las manos usando descriptores LBP. *Revista de Investigaciones Universidad del Quindío*, 27(2), Article 2. <https://doi.org/10.33975/riuq.vol27n2.50>
- Armstrong, G., & Norris, C. (2020). *The Maximum Surveillance Society: The Rise of CCTV*. Routledge.
- Carrillo-Medina, J., Chango-Caisabanda, D., Cuyo-Chiluisa, V., & Galarza-Medina, E. (2022). Person Re-identification using soft-biometric features: Body silhouette and clothing texture in a multi-camera video surveillance environment. *2022 Third International Conference on Information Systems and Software Technologies (ICI2ST)*, 1-8. <https://doi.org/10.1109/ICI2ST57350.2022.00013>
- Chen, J., Jiang, X., Wang, F., Zhang, J., Zheng, F., Sun, X., & Zheng, W.-S. (2021). Learning 3D Shape Feature for Texture-insensitive Person Re-identification. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 8142-8151. <https://doi.org/10.1109/CVPR46437.2021.00805>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Dalal, N., & Triggs, B. (2005). Histograms of oriented gradients for human detection. *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 1, 886-893 vol. 1. <https://doi.org/10.1109/CVPR.2005.177>
- Fan, X., Luo, H., Zhang, X., He, L., Zhang, C., & Jiang, W. (2019). SCPNet: Spatial-Channel Parallelism Network for Joint Holistic and Partial Person Re-identification. En C. V.

Jawahar, H. Li, G. Mori, & K. Schindler (Eds.), *Computer Vision – ACCV 2018* (pp. 19-34). Springer International Publishing. https://doi.org/10.1007/978-3-030-20890-5_2

Gavilanes, P., Carrillo, J., & Galarza, E. (2022). Person Re-identification System in a Controlled Environment Based on Soft Biometric Features: Clothing Color and Body Silhouette Collected on Short Video Sequences Using Computer Vision and Machine Learning Algorithms. *2022 Third International Conference on Information Systems and Software Technologies (ICI2ST)*, 14-20.
<https://doi.org/10.1109/ICI2ST57350.2022.00010>

Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 580-587.
<https://doi.org/10.1109/CVPR.2014.81>

Gonzalez, R. C., Woods, R. E., & Masters, B. R. (2009). Digital Image Processing, Third Edition. *Journal of Biomedical Optics*, 14(2), 029901.
<https://doi.org/10.1117/1.3115362>

Hastie, T., Friedman, J., & Tibshirani, R. (2001). *The Elements of Statistical Learning*. Springer. <https://doi.org/10.1007/978-0-387-21606-5>

Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning. *Genetic Programming and Evolvable Machines*, 19(1), 305-307.
<https://doi.org/10.1007/s10710-017-9314-z>

Hermans, A., Beyer, L., & Leibe, B. (2017). *In Defense of the Triplet Loss for Person Re-Identification* (arXiv:1703.07737). arXiv. <https://doi.org/10.48550/arXiv.1703.07737>

Jain, A. K., Ross, A., & Prabhakar, S. (2004). An introduction to biometric recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1), 4-20.
<https://doi.org/10.1109/TCSVT.2003.818349>

- Jalilian, E., Karakaya, M., & Uhl, A. (2020). End-to-end Off-angle Iris Recognition Using CNN Based Iris Segmentation. *2020 International Conference of the Biometrics Special Interest Group (BIOSIG)*, 1-7.
- Jeong, J. (2019, julio 17). *The Most Intuitive and Easiest Guide for CNN*. Medium.
<https://towardsdatascience.com/the-most-intuitive-and-easiest-guide-for-convolutional-neural-network-3607be47480>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), Article 7553.
<https://doi.org/10.1038/nature14539>
- Li, M., Zhu, X., & Gong, S. (2018). Unsupervised Person Re-identification by Deep Learning Tracklet Association. En V. Ferrari, M. Hebert, C. Sminchisescu, & Y. Weiss (Eds.), *Computer Vision – ECCV 2018* (Vol. 11208, pp. 772-788). Springer International Publishing. https://doi.org/10.1007/978-3-030-01225-0_45
- Li, S. Z., & Jain, A. K. (Eds.). (2011). *Handbook of Face Recognition*. Springer.
<https://doi.org/10.1007/978-0-85729-932-1>
- Mantini, P., & Shah, S. K. (2014). Human Trajectory Forecasting In Indoor Environments Using Geometric Context. *Proceedings of the 2014 Indian Conference on Computer Vision Graphics and Image Processing*, 1-8.
<https://doi.org/10.1145/2683483.2683547>
- Mantini, P., & Shah, S. K. (2015). Person re-identification using geometry constrained human trajectory modeling. *2015 IEEE International Symposium on Technologies for Homeland Security (HST)*, 1-6. <https://doi.org/10.1109/THS.2015.7225275>
- Masullo, A., Burghardt, T., Damen, D., Perrett, T., & Mirmehdi, M. (2020). Person Re-ID by Fusion of Video Silhouettes and Wearable Signals for Home Monitoring Applications. *Sensors*, 20(9), 2576. <https://doi.org/10.3390/s20092576>
- Merchán, F., Galeano, S., & Poveda, H. (2014). Mejoras en el Entrenamiento de Esquemas de Detección de Sonrisas Basados en AdaBoost. *I+D Tecnológico*, 10(2), Article 2.
- Mitchell, T. M. (1997). Does Machine Learning Really Work? *AI Magazine*, 18(3), Article 3.
<https://doi.org/10.1609/aimag.v18i3.1303>

- Mundra, A., Misra, S., & Dhawale, C. A. (2013). Practical Scrum-Scrum Team: Way to Produce Successful and Quality Software. *2013 13th International Conference on Computational Science and Its Applications*, 119-123.
<https://doi.org/10.1109/ICCSA.2013.25>
- Ojala, T., Pietikäinen, M., & Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1), 51-59.
[https://doi.org/10.1016/0031-3203\(95\)00067-4](https://doi.org/10.1016/0031-3203(95)00067-4)
- Patel, S. (2017, mayo 4). Chapter 2: SVM (Support Vector Machine) — Theory. *Machine Learning 101*. <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>
- Pozuelo Fernández, J. (2016, abril 8). *Sistema colaborativo de detección y seguimiento de anomalías mediante visión por computador* [Info:eu-repo/semantics/bachelorThesis]. E.T.S.I y Sistemas de Telecomunicación (UPM). <https://oa.upm.es/41486/>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- Regazzoni, C. S., Cavallaro, A., Wu, Y., Konrad, J., & Hampapur, A. (2010). Video Analytics for Surveillance: Theory and Practice [From the Guest Editors]. *IEEE Signal Processing Magazine*, 27(5), 16-17. <https://doi.org/10.1109/MSP.2010.937451>
- Rising, L., & Janoff, N. S. (2000). The Scrum software development process for small teams. *IEEE Software*, 17(4), 26-32. <https://doi.org/10.1109/52.854065>
- Schumann, A., & Monari, E. (2014). A soft-biometrics dataset for person tracking and re-identification. *2014 11th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, 193-198.
<https://doi.org/10.1109/AVSS.2014.6918667>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437.
<https://doi.org/10.1016/j.ipm.2009.03.002>

- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications*. Springer Nature.
- Terven, J., & Cordova-Esparza, D. (2023). *A Comprehensive Review of YOLO: From YOLOv1 and Beyond* (arXiv:2304.00501). arXiv.
<https://doi.org/10.48550/arXiv.2304.00501>
- Turk, M., & Pentland, A. (1991). Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*, 3(1), 71-86. <https://doi.org/10.1162/jocn.1991.3.1.71>
- Vaz, J. M., & Balaji, S. (2021). Convolutional neural networks (CNNs): Concepts and applications in pharmacogenomics. *Molecular Diversity*, 25(3), 1569-1584.
<https://doi.org/10.1007/s11030-021-10225-3>
- Zeng, C., Ma, H., & Ming, A. (2010). Fast human detection using mi-SVM and a cascade of HOG-LBP features. *2010 IEEE International Conference on Image Processing*, 3845-3848. <https://doi.org/10.1109/ICIP.2010.5654100>
- Zhao, W., Chellappa, R., Phillips, P. J., & Rosenfeld, A. (2003). Face recognition: A literature survey. *ACM Computing Surveys*, 35(4), 399-458.
<https://doi.org/10.1145/954339.954342>
- Zheng, L., Yang, Y., & Hauptmann, A. G. (2016, octubre 10). *Person Re-identification: Past, Present and Future*. ArXiv.Org. <https://arxiv.org/abs/1610.02984v1>
- Zhili, C., & Guiyan, J. (2008). Application of multiple SVM classifier fusion technique in freeway automatic incident detection. *2008 27th Chinese Control Conference*, 581-585. <https://doi.org/10.1109/CHICC.2008.4605683>

Anexos

