



Estudio comparativo sobre el uso de técnicas, modelos y/o algoritmos, basados en características biométricas y soft-biométricas para la Re-Identificación de personas, mediante arquitecturas de altas prestaciones, CPUs y GPUs

Lema Velásquez, Steven Alexander y Robayo Bastidas, Alex Xavier

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

Dr. Carrillo Medina, José Luis, (mCL).

25 de agosto del 2023

Latacunga



Plagiarism report

Tesina_Lema_Robayo_COMPLETO-25-...

Scan details

Scan time:
August 25th, 2023 at 14:32 UTC

Total Pages:
123

Total Words:
30504

Plagiarism Detection



6.8%

Types of plagiarism		Words
Identical	0.2%	75
Minor Changes	0.1%	19
Paraphrased	5.5%	1690
Omitted Words	13.4%	4099

AI Content Detection

N/A

Text coverage

- AI text
- Human text

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: (31)

T-EPEL-SOF-0081.pdf

2.3%

<https://repositorio.espe.edu.ec/bitstream/21000/35752/1/t-e...>

DAVID ALEJANDRO PEREZ VILLAGOMEZ

1 Carátula Sistema de re-identificación de personas a través de las características faciales y soft-biométricas la silueta corporal, ut...

v17n2-10.pdf

0.5%

<https://www.revistaingenieria.unam.mx/numeros/2016/v17n...>

Ingeniería Investigación y Tecnología, volumen XVII (número 2), abril-junio 2016: 257-271 ISSN 2594-0732 FI-UNAM (artículo arbitrado) DOI...

Dr. Carrillo Medina, José Luis, (mCL).

C. C. 0501553788



Departamento de Ciencias de la Computación

Carrera de Ingeniería de Software

Certificación

Certifico que el trabajo de integración curricular: **"Estudio comparativo sobre el uso de técnicas, modelos y/o algoritmos, basados en características biométricas y soft-biométricas para la Re-Identificación de personas, mediante arquitecturas de altas prestaciones, CPUs y GPUs"** fue realizado por los señores **Lema Velásquez, Steven Alexander y Robayo Bastidas, Alex Xavier**, 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, 25 de agosto del 2023

Dr. Carrillo Medina, José Luis, (mCL).

C. C. 0501553788



Departamento de Ciencias de la Computación

Carrera de Ingeniería de Software

Responsabilidad de Autoría

Nosotros, **Lema Velásquez, Steven Alexander y Robayo Bastidas, Alex Xavier**, con cédulas de ciudadanía n° 0550243737 y 0550036529, declaramos que el contenido, ideas y criterios del trabajo de integración curricular: **Estudio comparativo sobre el uso de técnicas, modelos y/o algoritmos, basados en características biométricas y soft-biométricas para la Re-Identificación de personas, mediante arquitecturas de altas prestaciones, CPUs y GPUs** 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, 25 de agosto del 2023

Lema Velásquez, Steven Alexander

C.C.: 0550243737

Robayo Bastidas, Alex Xavier

C.C.: 0550036529



Departamento de Ciencias de la Computación

Carrera de Ingeniería de Software

Autorización de Publicación

Nosotros, **Lema Velásquez, Steven Alexander y Robayo Bastidas, Alex Xavier**, con cédulas de ciudadanía n° 0550243737 y 0550036529, autorizamos a la Universidad de las Fuerzas Armadas ESPE publicar el trabajo de integración curricular: **Estudio comparativo sobre el uso de técnicas, modelos y/o algoritmos, basados en características biométricas y soft-biométricas para la Re-Identificación de personas, mediante arquitecturas de altas prestaciones, CPUs y GPUs en el Repositorio Institucional, cuyo contenido, ideas y criterios son de nuestra responsabilidad**

Latacunga, 25 de agosto del 2023

.....
Lema Velásquez, Steven Alexander

C.C.: 0550243737

.....
Robayo Bastidas, Alex Xavier

C.C.: 0550036

Dedicatoria

Con profundo afecto y gratitud, dedico esta tesis a mis queridos abuelos, testigos de mi crecimiento desde mis primeros pasos, cuyo amor y apoyo han sido mi guía constante. A mi madre, ejemplo de sacrificio incansable, cuyo amor incondicional ha sido mi motor para llegar hasta aquí. También dedico este logro a mis queridos hermano y hermana, cuya compañía ha llenado mi vida de alegría y sentido, disipando cualquier sensación de soledad.

Esta tesis es el resultado del inquebrantable amor y apoyo que he recibido de vosotros. Gracias por ser mi inspiración constante.

Lema Velásquez, Steven Alexander

Dedicatoria

Este trabajo va dedicado a Dios, por iluminar mi camino en esta travesía académica y brindarme la fortaleza necesaria para superar los desafíos.

A mis queridos padres, cuyo amor incondicional y sacrificio han sido la base de mi educación, les dedico este logro. Su constante apoyo y aliento han sido mi motor para alcanzar mis metas.

A mi amado hermano, compañero de risas y adversidades, agradezco tu inspiración, apoyo y camaradería en cada paso del camino.

A toda mi familia, pilares de amor y estabilidad, les agradezco por creer en mí y por ser mi refugio en los momentos de duda.

A todos mis amigos del club de software quienes compartieron conmigo momentos de aprendizaje, distracción, creatividad y perseverancia. Su amistad y colaboración han enriquecido mi experiencia académica y personal.

Cada palabra escrita en estas páginas lleva un rastro de gratitud hacia ustedes. Sin su amor, apoyo y orientación, este logro no habría sido posible. Que este trabajo sea un tributo a nuestra unión y a la confianza que depositaron en mí. Con amor y gratitud infinitos.

Robayo Bastidas, Alex Xavier

Agradecimiento

En este momento de logro, deseo expresar mi profunda gratitud a Dios, fuente de fuerza y guía en cada paso de mi viaje. A mi querida familia y amigos, vuestro apoyo incondicional ha sido mi motor y consuelo a lo largo de este viaje.

A la Universidad de las Fuerzas Armadas, gracias por darme la oportunidad de adquirir conocimientos y crecer como persona. A mi tutor, el Dr. Carrillo Medina, José Luis, le reconozco no sólo por su sabiduría y experiencia compartidas, sino también por su generosidad al invertir tiempo y energía en mi desarrollo académico.

Cada uno de ustedes ha dejado una huella indeleble en este logro, y su contribución no pasará desapercibida. Gracias por ser una parte fundamental de este capítulo de mi vida.

Lema Velásquez, Steven Lema

Agradecimiento

En la culminación de este arduo viaje académico, deseo expresar mi más sincero agradecimiento a aquellos cuya influencia y apoyo han sido esenciales para alcanzar esta meta.

En primer lugar, agradezco de todo corazón a Dios, cuya guía y sabiduría han iluminado mi camino en cada fase de esta travesía.

A mis queridos padres, cuyo amor incondicional y sacrificio han cimentado los cimientos de mi educación, les dedico este logro. Su respaldo constante y fe en mí han sido una fuente constante de inspiración.

A mi entrañable familia, por ser mi red de seguridad emocional y mi puerto en las tormentas. Su amor incondicional me ha impulsado a superar obstáculos y a realizar mis aspiraciones.

A mis amigos del club de software, con quienes he compartido desafíos y sobre todo alegrías. Su amistad y colaboración han aportado un matiz valioso a esta travesía.

A mi apreciado tutor de tesis, el Dr. Jose Luis Carrillo, cuya orientación experta, paciencia y dedicación me han guiado a lo largo de este proceso. Su sabiduría y consejo han sido un faro en mi camino académico.

Cada página de esta tesis lleva impresa la huella de mi gratitud hacia todos ustedes. Sin su aliento constante, dirección y presencia en mi vida, este sendero habría sido mucho más empinado. Que este trabajo sea un testimonio de mi aprecio y de la confianza que depositaron en mí. Con humildad y un agradecimiento profundo.

Robayo Bastidas, Alex Xavier

ÍNDICE DE CONTENIDOS

Carátula.....	1
Reporte de verificación de contenido.....	2
Certificación	3
Responsabilidad de Autoría	4
Autorización de Publicación.....	5
Dedicatoria	6
Dedicatoria	7
Agradecimiento.....	8
Agradecimiento.....	9
Índice de Contenidos.....	10
Índice de Tablas	14
Índice de Figuras	17
Resumen.....	19
Abstract	20
Capítulo I: Introducción.....	21
Propósito y contextualización del tema.....	21
Justificación del interés de la investigación	22
Objetivos Generales y Específicos.....	23
<i>Objetivo General</i>	24
<i>Objetivo Específicos</i>	24
Metodología	24
Capítulo II: Marco teórico.....	28
Características Biométricas y Soft-biométricas.....	28
<i>Características Biométricas</i>	29
<i>Características Soft-biométricas</i>	29

Visión por computador	30
<i>Local Binary Pattern (LBP)</i>	31
<i>Histogram of Orient Gradient (HoG)</i>	32
Machine Learning (Aprendizaje automático).....	35
<i>Support Vector Machine (SVM)</i>	37
<i>Convolutional Neural Network (CNN)</i>	39
<i>Deep Neural Network (DNN)</i>	39
You Only Look Once (YOLO)	41
Comparación de descriptores y clasificadores en la Re-Identificación de personas	42
Arquitecturas de altas prestaciones (GPU y CPU).....	46
Metodología SCRUM	47
Capítulo III: Implementación del sistema	50
Análisis y Diseño del Sistema.....	58
<i>Análisis del Sistema</i>	58
<i>Product Backlog del Proyecto</i>	59
<i>Escenario para el sistema de Re-Identificación de personas</i>	60
<i>Herramientas de Software para el Desarrollo del Sistema de Re-Identificación de Personas</i>	63
<i>Herramientas de Hardware para el Desarrollo del Sistema de Re-Identificación de Personas</i>	63
<i>Implementación de técnicas de Visión por Computadora y algoritmos de Machine Learning para la identificación facial, silueta corporal, textura y color de la ropa</i>	64
Sprint 01: Generación de dataset de rostros y algoritmo de identificación facial.....	64
<i>H.U.01: Obtención de dataset de rostros</i>	64

<i>H.U.02: Desarrollo e implementación de modelos y/o algoritmos de identificación facial mediante técnicas de Visión por Computadora</i>	<i>72</i>
Sprint 02: Obtención de dataset de silueta corporal, textura y color de la ropa e implementación de algoritmos para el Re-Identificación de personas utilizando características soft-biométricas (silueta corporal, la textura y el color de la ropa).	81
<i>H.U.03: Creación de datasets de silueta corporal, textura y color de la ropa</i>	<i>81</i>
<i>H.U.04: Implementación de modelos capaces de Re-identificar personas al combinar características soft-biométricas: silueta corporal, textura y color de la ropa.....</i>	<i>85</i>
Sprint 03: Comparación del procesamiento de CPU y GPU, en el modelo combinado de características soft-biométricas (silueta corporal, textura y color de la ropa) con sus distintos clasificadores.....	95
<i>H.U.05: Comparación de rendimientos del sistema de Re-Identificación de personas mediante el uso de arquitecturas de altas prestaciones</i>	<i>96</i>
Capítulo IV: Validación del Sistema	106
Aplicación de las métricas de evaluación	107
Pruebas del algoritmo de identificación facial y Re-Identificación de la silueta corporal, textura y color de la ropa.	107
<i>Resultados de las Pruebas</i>	<i>109</i>
Validación de la eficiencia del sistema de Re-Identificación	115
Validación de los tiempos de entrenamiento de los modelos de identificación del rostro y de Re-Identificación de personas.....	118
<i>Tiempo empleado en el modelo para Re-ID de personas utilizando las características soft-biométricas: Silueta corporal (LBP), Textura (HoG) y Color (HoG) de la ropa.</i>	<i>119</i>
Capítulo V: Conclusiones	121

Bibliografia	123
Anexos	130

ÍNDICE DE TABLAS

Tabla 1 <i>Resume las principales ventajas y desventajas de utilizar YOLO</i>	42
Tabla 2 <i>Resumen de la característica biométrica, descriptores, clasificadores y porcentajes de precisión reportados en la literatura</i>	43
Tabla 3 <i>Resumen de las características Soft-biométricas, descriptores, clasificadores y porcentajes de precisión reportados en la literatura</i>	44
Tabla 4 <i>Ventajas y desventajas de las arquitecturas de altas prestaciones</i>	47
Tabla 5 <i>Roles principales en SCRUM</i>	52
Tabla 6 <i>Valores de la matriz de confusión</i>	55
Tabla 7 <i>Team Scrum / Equipo Scrum</i>	58
Tabla 8 <i>Historias de Usuario</i>	59
Tabla 9 <i>Product Backlog</i>	60
Tabla 10 <i>Herramientas de software para el desarrollo del sistema de Re-Identificación de personas</i>	63
Tabla 11 <i>Herramientas de Hardware para el desarrollo</i>	64
Tabla 12 <i>Historia de usuario H.U.01</i>	65
Tabla 13 <i>Sprint Backlog 01</i>	66
Tabla 14 <i>Algoritmo para la captura de imágenes y etiquetas para el dataset de rostros</i>	67
Tabla 15 <i>Historia de usuario H.U.02</i>	72
Tabla 16 <i>Sprint Backlog 02</i>	73
Tabla 17 <i>Pseudocódigo del algoritmo de entrenamiento del modelo de identificación de personas por su rostro</i>	74
Tabla 18 <i>Pseudocódigo del algoritmo para la identificación de personas por su rostro</i>	75
Tabla 19 <i>Matriz de confusión de la Identificación facial de la Clase 1: Alex</i>	80
Tabla 20 <i>Aplicación de métricas a los resultados obtenidos de la combinación de LBP y HoG con los clasificadores SVM, DNN y CNN</i>	81

Tabla 21 <i>Historia de usuario H.U.03</i>	82
Tabla 22 <i>Sprint Backlog 03</i>	82
Tabla 23 <i>Pseudocódigo del algoritmo para la extracción de características soft-biométricas</i> ...	83
Tabla 24 <i>Historia de usuario H.U.04</i>	86
Tabla 25 <i>Sprint Backlog 04</i>	87
Tabla 26 <i>Pseudocódigo para el entrenamiento del modelo de Re-Identificación de personas</i>	88
Tabla 27 <i>Pseudocódigo del algoritmo para la Re-Identificación de personas</i>	90
Tabla 28 <i>Datos de las matrices de confusión de la Re-Identificación de la Clase 1 mediante la silueta corporal, textura y color de la ropa</i>	93
Tabla 29 <i>Aplicación de métricas a los resultados obtenidos de la combinación de LBP y HoG</i>	94
Tabla 30 <i>Re-Identificación de la Clase 1: Alex a través de la combinación de su silueta corporal, textura y color de la ropa</i>	95
Tabla 31 <i>Historia de Usuario H.U.05</i>	96
Tabla 32 <i>Sprint Backlog 05</i>	97
Tabla 33 <i>Comparación del tiempo empleado en el entrenamiento del modelo de reconocimiento facial</i>	98
Tabla 34 <i>Comparación del tiempo empleado en el entrenamiento del modelo de Re-Identificación de personas con el uso de GPU y CPU</i>	99
Tabla 35 <i>Comparación del porcentaje de utilización de la CPU y GPU para el entrenamiento de modelo para la identificación del rostro</i>	100
Tabla 36 <i>Comparación del porcentaje de utilización de la CPU y GPU para el entrenamiento del modelo de Re-Identificación de personas</i>	101
Tabla 37 <i>Comparación del porcentaje de utilización de la CPU y GPU según el tipo de uso dentro del sistema de Re-Identificación de personas</i>	102

Tabla 38 <i>Variables de las métricas de evaluación de rendimiento de GPU y CPU</i>	103
Tabla 39 <i>Comparación usando las métricas para evaluar el rendimiento de GPU y CPU.....</i>	104
Tabla 40 <i>Resultados de la matriz de confusión de las nuevas clases, aplicando el modelo de rostros para la Identificación de personas.....</i>	110
Tabla 41 <i>Resultados de las pruebas realizadas con las nuevas clases, aplicando las métricas de evaluación</i>	111
Tabla 42 <i>Resultados de la matriz de confusión de las nuevas clases al aplicar los distintos modelos de Re-Identificación de personas.....</i>	113
Tabla 43 <i>Resultados de las pruebas realizadas con las nuevas clases, aplicando las métricas de evaluación precisión</i>	114
Tabla 44 <i>Resultados de las pruebas realizadas con las nuevas clases, aplicando la métrica de evaluación precisión.....</i>	115
Tabla 45 <i>Comparación del uso de la CPU y GPU, en el modelo de identifican facial.....</i>	116
Tabla 46 <i>Comparación de la precisión en la Re-Identificación de personas con el uso de CPU y GPU.....</i>	117
Tabla 47 <i>Comparación del tiempo empleados en el entrenamiento del modelo de reconocimiento facial con el uso de GPU y CPU de las clases Alex, Ángel, Diego, Flor y Jhon.....</i>	118
Tabla 48 <i>Comparación del tiempo empleado en el entrenamiento del modelo de Re-Identificación de personas combinando las características</i>	119

ÍNDICE DE FIGURAS

Figura 1 <i>El operador LBP básico</i>	31
Figura 2 <i>Pasos de HoG para la Re-Identificación mediante la textura de la ropa</i>	34
Figura 3 <i>Máquina de vectores soporte</i>	38
Figura 4 <i>Marco de trabajo de SCRUM</i>	48
Figura 5 <i>Funcionamiento de un sistema de RE-ID de personas</i>	51
Figura 6 <i>Marco de trabajo de SCRUM</i>	53
Figura 7 <i>Matriz de confusión</i>	55
Figura 8 <i>Pasillo de la ESPE campus Belisario Quevedo</i>	61
Figura 9 <i>Esquema de la disposición de las cámaras y su funcionalidad</i>	62
Figura 10 <i>Dataset con las imágenes de la Clase 1: Alex para el entrenamiento del modelo de identificación facial</i>	69
Figura 11 <i>Carpeta con las etiquetas correspondientes a las imágenes de la Clase 1</i>	70
Figura 12 <i>Formato de etiquetado en YOLO</i>	71
Figura 13 <i>Distribución de almacenamiento del dataset de rostros</i>	71
Figura 14 <i>Entrenamiento del modelo de detección facial</i>	75
Figura 15 <i>Persona identificada por el rostro, con su nombre correspondiente</i>	78
Figura 16 <i>Matriz de confusión generada al entrenar el modelo de reconocimiento facial con la arquitectura YOLO</i>	79
Figura 17 <i>Dataset con las imágenes de silueta, textura y color de la Clase 1: Alex</i>	85
Figura 18 <i>Persona Re-Identificada por las características soft-biométricas con su respectivo nombre de la clase</i>	92
Figura 19 <i>Representación de ejecución del sistema en multiprocesamiento</i>	108
Figura 20 <i>Descripción de cómo trabajan la CPU y GPU en el sistema de Re-Identificación de personas</i>	108

Figura 21 <i>Al dataset se añade de 4 nuevas Clases para llevar a cabo la Re-ID mediante el modelo de rostro.....</i>	109
Figura 22 <i>Resultados de las pruebas realizadas con las nuevas clases, aplicando la combinación de características</i>	112

Resumen

Este estudio compara distintos métodos de Re-Identificación de personas a partir de datos biométricos (rostro) y soft-biométricos (silueta corporal, textura y color de la ropa). El objetivo es identificar personas en condiciones controladas utilizando distintos enfoques, modelos y algoritmos de los campos de la Visión por Computadora y el aprendizaje automático. Todo esto se lleva a cabo aprovechando el poder de arquitecturas de alto rendimiento, lo que impulsa la capacidad de procesamiento y análisis de datos a niveles que antes eran inalcanzables. En este estudio se investiga diversas técnicas, modelos y algoritmos basados en características biométricas y soft-biométricas, estableciendo un enfoque integral que combina múltiples aspectos de la identificación individual. Además del reconocimiento facial, se está investigando la detección y Re-Identificación de personas a partir de la silueta corporal, la textura y el color de la ropa para mejorar la precisión y la velocidad en una variedad de situaciones y condiciones. Esto abre la puerta a aplicaciones más versátiles, desde la seguridad en espacios públicos hasta la autenticación en plataformas digitales. También, se analiza distintos métodos de aprendizaje, incluidos los enfoques holísticos que consideran la totalidad de la información disponible y los enfoques específicos que se centran en atributos individuales. Mediante el uso de técnicas avanzadas de aprendizaje automático y arquitecturas de alto rendimiento, como CPUs y GPUs, se busca mejorar la precisión y eficacia de los sistemas de Re-ID para determinar la solución más adecuada a esta investigación. Este estudio busca sentar las bases para futuros avances en la Re-Identificación, contribuyendo al progreso tecnológico y a la seguridad en una sociedad cada vez más digitalizada.

Palabras clave: Re-Identificación de personas, características biométricas, características soft-biométricas, Técnicas de Visión por Computadora, Machine Learning.

Abstract

This study compares different methods of Re-Identification of persons from biometric (face) and soft-biometric (body silhouette, texture and color of clothing) data. The objective is to identify people under controlled conditions using different approaches, models and algorithms from the fields of Computer Vision and Machine Learning. All this is accomplished by harnessing the power of high-performance architectures, which boosts data processing and analysis capabilities to levels that were previously unattainable. This study investigates various techniques, models and algorithms based on biometric and soft-biometric features, establishing a comprehensive approach that combines multiple aspects of individual identification. In addition to facial recognition, detection and Re-Identification of individuals from body silhouette, texture and clothing color is being investigated to improve accuracy and speed in a variety of situations and conditions. This opens the door to more versatile applications, from security in public spaces to authentication on digital platforms. Also, different learning methods are discussed, including holistic approaches that consider the totality of available information and specific approaches that focus on individual attributes. By using advanced machine learning techniques and high-performance architectures, such as CPUs and GPUs, we seek to improve the accuracy and efficiency of Re-ID systems to determine the most appropriate solution for this research. This study seeks to lay the groundwork for future advances in Re-ID, contributing to technological progress and security in an increasingly digitized society.

Key words: Person re-identification, biometric features, softbiometric features, Computer Vision Techniques, Machine Learning.

Capítulo I

Introducción

Propósito y contextualización del tema

En la actualidad, la seguridad es una preocupación primordial en la sociedad moderna. La vigilancia es fundamental para fortalecer la seguridad y la prevención de delitos. Los sistemas de videovigilancia ofrecen a las instituciones, empresas e industrias públicas y/o privadas supervisar y controlar actividades e identificar a quienes muestran actitudes sospechosas. Estos sistemas capturan y graban diversas imágenes y secuencias, que luego se analizan para detectar comportamientos inusuales o amenazas potenciales. Un ejemplo relevante es detectar objetos (personas, animales, cosas en general) obtenidos mediante el tratamiento de imágenes de cámaras de videovigilancia instaladas en lugares donde se han cometido delitos (Marín Reyes, 2021).

Actualmente, existen dos tipos de sistemas de videovigilancia, los tradicionales y los inteligentes. Los primeros se basan en cámaras de seguridad convencionales que capturan simplemente imágenes y videos para su posterior revisión por un agente de seguridad. Por otro lado, los segundos emplean tecnologías avanzadas, las cuales permiten analizar y procesar las imágenes en tiempo real. Estos sistemas pueden detectar y alertar sobre situaciones anómalas, reconocer objetos y personas en situaciones de vigilancia, utilizando diversas cámaras y lugares de observación (Moctezuma-Ochoa, 2016). Estos últimos están revolucionando la seguridad y la gestión de situaciones en diversas áreas, desde la seguridad pública hasta la optimización de operaciones comerciales (Behera et al., 2021).

Uno de los aspectos fundamentales de los sistemas de videovigilancia es la Re-Identificación de personas que consiste en verificar si una persona identificada por una cámara coincide en otra cámara instalada en un lugar diferente. Actualmente, la Re-Identificación de personas ha adquirido importancia por la creciente necesidad de monitorización y control de seguridad en varios entornos, desde aeropuertos y estaciones de transporte hasta edificios

gubernamentales y comerciales (Singh et al., 2022). Uno de los principales desafíos de la Re-Identificación de personas es la variabilidad en la apariencia de las personas, que puede deberse a distintos factores como: cambios en la iluminación, el ángulo de visión, la oclusión parcial de la cara o el cuerpo, y otros factores ambientales (Y. Wang et al., 2021). Los investigadores han creado enfoques novedosos para re-identificar a las personas utilizando datos biométricos y/o soft-biométricos. Para abordar y superar estas limitaciones, estas tecnologías constituyen un avance considerable en la tecnología de la identificación (Patruno et al., 2019).

Las huellas dactilares, los escáneres de iris, la voz, el reconocimiento facial y las firmas son algunos de los rasgos biométricos (Anil et al., 2000). Por otro lado, los rasgos soft-biométricos incluyen características no únicas que proporcionan información adicional para la identificación individual, como la ropa (textura y color), el peinado, la altura, la postura e incluso el sexo (Plazas Pirabán & Betancur Sanchez, 2021). En el proceso de Re-Identificación de personas, se han desarrollado tanto enfoques holísticos como no holísticos. Los primeros se basan en el tratamiento de la información global de imágenes y vídeos de personas que se mapean de forma que coincida con las características biométricas y soft-biométricas de un individuo. En cambio, los modelos no holísticos se centran en características específicas de la cara o el cuerpo, como es el contorno facial o la forma de partes del cuerpo, para llevar a cabo una la comparación y la Re-Identificación (Verdeguer Valderrama, 2022).

En el campo de los sistemas de Re-Identificación se emplean técnicas avanzadas computacionales que muestran la integración de enfoques de Visión por Computador y Aprendizaje Automático, esta combinación ha arrojado resultados efectivos y prometedores (Salamon, 2015).

Justificación del interés de la investigación

En este trabajo se pretende realizar un estudio comparativo de sistemas de Re-Identificación de personas mediante el uso de técnicas, modelos y/o algoritmos de Visión por

Computador y Aprendizaje Automático respectivamente, junto con el uso de arquitecturas de alto rendimiento CPUs y GPUs, lo que abre nuevas posibilidades en aplicaciones como el reconocimiento facial, la seguridad de acceso y la autenticación de identidad en diversos campos, desde la seguridad pública hasta el ámbito empresarial. Este tipo de arquitecturas impulsa significativamente el desarrollo de soluciones más rápidas, confiables y precisas para la identificación de personas (Gaikwad & Karmakar, 2022).

Esta investigación comparativa es esencial debido a la necesidad de mejorar y maximizar los sistemas de videovigilancia en lugares regulados como aeropuertos, edificios públicos u otros lugares de alta seguridad. Al comparar diferentes características, técnicas, modelos y/o algoritmos de análisis de Re-Identificación, se busca identificar cuál es la opción más efectiva y eficiente para garantizar la seguridad y el control en estos lugares (Reid et al., 2013). Lo que se traduce en la detección temprana de conductas sospechosas y una respuesta más rápida ante situaciones de riesgo o amenazas.

Los rasgos biométricos, como el rostro y los rasgos soft-biométricos, como la silueta corporal, la textura y el color de la ropa, se utilizan para desarrollar estos sistemas. Los rasgos soft-biométricos son características que superan las limitaciones de la identificación cuando el rostro no es visible y mejoran la accesibilidad de los datos de una persona para su Re-Identificación (Salamon, 2015). Además, con la implementación de diferentes técnicas, modelos y/o algoritmos, como LBP y HoG de Visión por Computador y SVM, CNN y DNN de Machine o Deep Learning, se busca comparar y evaluar la precisión en la identificación de personas, lo que permite seleccionar y optimizar la mejor solución.

Objetivos Generales y Específicos

Los objetivos generales y específicos de este trabajo sobre la integración curricular se los plantean a continuación:

Objetivo General

Desarrollar un estudio comparativo sobre el uso de técnicas, modelos y/o algoritmos, basados en características biométricas y soft-biométricas para la Re-Identificación de personas, mediante arquitecturas de altas prestaciones, CPUs y GPUs.

Objetivo Específicos

- Conocer y estudiar las características biométricas: facial y soft-biométricas: silueta corporal, textura y color de la ropa, aplicando técnicas LBP y HoG de Visión por Computadora y modelos de SVM, CNN y DNN de Machine o Deep Learning, que son utilizadas en la Re-Identificación de personas.
- Implementar técnicas, modelos y algoritmos para la Re-Identificación de personas, utilizando descriptores LBP y HoG, y clasificadores SVM, CNN y DNN a través del uso de arquitecturas paralelas.
- Validar los resultados, analizar los errores y ajustar los modelos de Re-Identificación de personas.

Metodología

Esta investigación utiliza arquitecturas de altas prestaciones, CPUs y GPUs, y se centra en un análisis comparativo de enfoques, modelos y/o algoritmos de Visión por Computadora y Machine Learning basados en el uso de datos biométricos y soft-biométricos para la Re-Identificación de personas.

Inicialmente, se realiza una revisión bibliográfica con un enfoque sistemático-metodológico sobre el objeto de la investigación lo que sentará las bases del marco teórico y práctico. En este contexto, veremos cómo se utilizan las características biométricas (rostro) y soft-biométricas (forma del cuerpo, textura y color de la ropa) durante el proceso de Re-Identificación, así como la forma en que se pueden utilizar técnicas avanzadas de Visión por Computador, Aprendizaje Automático y/o Profundo para Re-Identificar individuos. Para ello, se

lleva a cabo una rigurosa recopilación de datos mediante la búsqueda y el escrutinio de artículos científicos de las bases de datos Scopus, ISI Web e IEEEExplore.

Con los conocimientos adquiridos, el siguiente paso consiste en aplicar el modelo de Re-Identificación. Para ello, se utilizará un sistema de cámaras no superpuestas, compuesto por dos cámaras. La primera cámara reconoce a las personas en tiempo real a partir de las características de su rostro y crea modelos con los datos soft-biométricos como el contorno corporal, la textura y el color de la ropa. Por otro lado, la segunda cámara permite visualizar la parte posterior de la persona y con la aplicación de los modelos previamente construidos Re-Identificar a una persona, aun cuando no se le vea la cara ya que en esta cámara solo se le ve la parte posterior (espalda) de la persona. En la primera etapa, se establece un conjunto de datos (dataset) de rostro y se utiliza la primera cámara para crear un modelo de rostro mediante aprendizaje automático. A través del modelo, se identifica a la persona, y una vez que se identifica, se extraen en tiempo real las características soft-biométricas de la persona, como la silueta del cuerpo, la textura y el color de la ropa, que se combinan para generar un modelo para la Re-Identificación de personas cuando el rostro no es visible. Según la literatura científica, los modelos utilizados para la Re-Identificación de personas que integran variables soft-biométricas pueden aumentar la precisión de la Re-Identificación en comparación con los modelos que utilizan estas características por sí solos (Lu et al., 2022). En primer lugar, estas características se usan para generar descriptores para luego construir modelos y algoritmos de Aprendizaje Automático (Machine Learning) que permitan la identificación de personas en diferentes ubicaciones (predicciones).

Los conjuntos de datos de entrenamiento, prueba y/o validación se utilizan para evaluar el sistema. Esta evaluación sirve para calibrar la fiabilidad y el rendimiento del sistema en la tarea de Re-Identificación. Además, se pueden realizar variaciones en los hiperparámetros de los modelos seleccionados, los cuales podrían mejorar el proceso de aprendizaje.

Por otro lado, para realizar el análisis facial y la Re-Identificación de personas, se utilizan una variedad de técnicas, modelos y/o algoritmos que requieren una gran cantidad de potencia computacional. Esto se aplica tanto al análisis de rostros como a la Re-Identificación de personas a través de la silueta corporal, la textura y el color de la ropa. Las técnicas de Visión por Computador a utilizarse son LBP (Patrones binarios locales, en inglés Local Binary Patterns), que desempeñan un papel importante en la caracterización de diferentes rasgos faciales y mediante el modelo SVM (Support Vector Machine) para describir y clasificar características locales del rostro, también se puede usar DNN (Deep Neural Networks) para desarrollar la capacidad de reconocimiento facial y la comprensión de características más complejas (Fuad et al., 2021; Meena & Suruliandi, 2011; Moreano et al., 2019). Para analizar la textura de la ropa de la persona, se emplea el método HoG (Histogram of Oriented Gradients) en combinación con SVM. Esto permite entrenar clasificadores SVM que pueden extraer características de textura local e identificar diferentes tipos de texturas en la prenda. Por otro lado, LBP y SVM en combinación con transformaciones de máscara de color HSV (Hue, Saturation, Value), se puede identificar el color de la prenda, lo que permite una representación más eficiente del color (Nurthohari et al., 2019). Además, las CNN (Convolutional Neural Networks) usadas en herramientas como YOLO (You Only Look Once) pueden utilizarse para analizar y clasificar los colores de la ropa en una imagen. Otro rasgo utilizado para re-identificar a las personas es la silueta corporal. Esta característica puede describirse y clasificarse eficazmente mediante técnicas como LBP y SVM, así como también pueden emplearse métodos avanzados como CNN y YOLO para detectar y clasificar siluetas corporales en imágenes.

La combinación de características como la silueta corporal, la textura y el color de la ropa permite demostrar ser el enfoque más eficiente para lograr una alta precisión en la detección de personas, en comparación con los resultados obtenidos de forma individual (Tuapanta et al., 2023).

En este trabajo se requiere el uso de arquitecturas de alto rendimiento, por la alta capacidad de procesamiento, a través de las CPUs y las GPUs. Las CPUs (unidades centrales de procesamiento) ejecutan una amplia variedad de tareas computacionales de propósito general, mientras que las GPUs (unidades de procesamiento gráfico) para cálculos paralelos, lo que acelera tiempos de procesamiento. Aprovechar el potencial de estas arquitecturas de alto rendimiento mejora el rendimiento y la eficacia de los algoritmos utilizados.

Por último, se utilizarán métricas de evaluación, como son: Accuracy, Precision y Recall, para medir, evaluar y comparar el rendimiento de distintas combinaciones de algoritmos. Estas técnicas proporcionan datos cuantitativos en forma de porcentajes para evaluar la precisión y fiabilidad de la Re-Identificación, lo que permitirá generar conclusiones acordes a los resultados obtenidos.

Capítulo II

Marco teórico

En el presente capítulo se abordan las definiciones, conceptos, características y componentes que utiliza un sistema de Re-Identificación de personas, la cual es esencial en los sistemas de vigilancia inteligentes y tiene una gran importancia tanto en investigación como en la práctica.

El problema de la Re-Identificación es identificar a las personas que han sido fotografiadas por varias cámaras en diferentes lugares y momentos, ya sea por una cámara diferente o incluso por la misma cámara, y cuyas imágenes no se solapan (Quevedo Mora, 2021). La representación de una persona toma forma de una imagen o secuencia de video. Sin embargo, esta tarea es difícil de realizar por la presencia de muchos factores, como imágenes de baja resolución, iluminación cambiante, poses no controladas, obstáculos, modalidades heterogéneas, entornos de cámara complejos, fondos desordenados y formación de cuadros delimitadores poco fiables. Todos estos factores generan variabilidad y distintos niveles de incertidumbre (Ye et al., 2021).

Además, este estudio utiliza rasgos biométricos y soft-biométricos para identificar y/o re-identificar a las personas. Estas características ayudan a distinguir a las personas basándose en atributos físicos e información descriptiva y contextual. Para extraer este tipo de características se utilizan algoritmos como HoG y SVM, que facilitan el procesamiento de videos captados por cámaras de vigilancia. Además, se utilizan clasificadores como SVM, CNN y DNN para clasificar, identificar y re-identificar a las personas, basándose en las características extraídas previamente.

Características Biométricas y Soft-biométricas

Algunos de los rasgos más utilizados en esta disciplina incluyen los rasgos faciales, el iris, las huellas dactilares, la forma de andar, la textura y silueta del cuerpo y el color de la ropa. Estos rasgos se clasifican como soft-biométricos y biométricos.

Características Biométricas

Las características biométricas son rasgos específicos de un individuo que se utilizan con fines de identificación y autenticación. Estas características son únicas para cada persona y pueden emplearse en diversos sistemas de reconocimiento biométrico. Los sistemas biométricos utilizan rasgos fisiológicos, de comportamiento o morfológicos como son la cara, la huella dactilar, el iris, la retina, la voz o la firma, se ha ganado un lugar en el mundo tecnológico (Sabhanayagam et al., 2018).

El proyecto empleará el reconocimiento facial (método de identificación biométrica), que consiste en evaluar los rasgos distintivos de la cara de una persona, como la forma de los ojos, la nariz y los labios, para identificar o confirmar su identidad (Jain & Li, 2011). Esta forma de identificar consiste en un método no intrusivo que ha despertado gran interés en varios campos, especialmente en los sistemas de videovigilancia por su visibilidad desde cámaras y su facilidad de extracción de características (Sabhanayagam et al., 2018).

El sistema de Re-Identificación de personas utiliza el reconocimiento facial para identificar a las personas. Este proceso registra la identificación de la persona y permite su seguimiento a medida que se desplaza por las diferentes cámaras. Según (Hung, 2021) a precisión de este tipo de detección tiene una variación de entre el 75.43% a un 98.16%.

Características Soft-biométricas

Cada vez más, los sistemas de Re-Identificación utilizan características soft-biométricas, también conocidas como cualidades sociales o de comportamiento, para complementar la información biométrica tradicional. Estos atributos se basan en el análisis de atributos como la silueta corporal, el color y textura de la ropa, alto y ancho que proporcionan información adicional para identificar a un individuo. Cabe notar que estas características por si solas tiene un bajo poder de discriminación, por el contrario, la fusión y/o combinación de estas características mejora la precisión en la identificación de personas (Carrillo-Medina et al., 2022).

El análisis de la ropa ha demostrado ser una característica soft-biométrica efectiva para volver a identificar a una determinada persona. Los patrones de ropa, como la textura, el color o el estilo, se utilizan para distinguir a las personas en diferentes escenarios (Lee et al., 2018). Además, la combinación de estas u otras características podría mejorar los resultados en la Re-Identificación de personas, por ejemplo: al combinarse con la silueta corporal en donde se usa las formas corporales comunes para identificar a una persona en diferentes situaciones, debido a que este rasgo es estable y distintivo (Elharrouss et al., 2021).

Se propone implementar un sistema de Re-Identificación de personas mediante la combinación de las características de la silueta corporal, la textura y el color de la ropa. Esto permitirá identificar a una persona en situaciones en las que el rostro no es visible en la imagen, así como la precisión de la combinación de las tres características.

Visión por computador

La Visión por Computadora es una rama de la inteligencia artificial y la informática que se centra en enseñar a los computadores a interpretar y comprender datos visuales sobre el entorno, de forma muy similar a cómo las personas ven y analizan imágenes y películas (Gonzalez & Woods, 2008). Las aplicaciones importantes que utilizan métodos y algoritmos de visión por computadora incluyen detección y reconocimiento de objetos, clasificación de imágenes, reconocimiento e identificación facial y segmentación de imágenes.

La visión por computadora se utiliza en la Re-Identificación para identificar y seguir a personas específicas a través de varias cámaras o ubicaciones, lo que permite el control de acceso, el análisis del comportamiento y la investigación forense, entre otras aplicaciones. Esto mejora la vigilancia y la seguridad tanto en espacios públicos como privados (K. Wang et al., 2018). El proceso de Re-Identificación presenta una amplia gama de desafíos técnicos y prácticos que dificultan su aplicación efectiva en diversas situaciones. Por ejemplo: la resolución o el ángulo de la cámara, la iluminación, la distancia y la apariencia de la persona (ropa, color, textura, etc.) (K. Zhang et al., 2017).

Para la implementación de sistemas de Re-Identificación de personas, se utilizan ciertas características visuales, a las cuales se les conoce como descriptores, que permiten distinguir de manera única a un individuo. Los descriptores que se utilizara en este trabajo son: los LBP (Local Binary Patterns) y los HOG (Histograms of gradients), algoritmos que se utilizan en la Re-Identificación de personas y que han producido buenos resultados (Greeshma & Gripsy, 2020).


Local Binary Pattern (LBP)

Los descriptores LBP son utilizados en el procesamiento de imágenes para captar patrones locales y variaciones de textura en las imágenes (Pietikäinen, 2005). (Pietikäinen, 2005). El código LBP se basa en comparar cada píxel de una imagen con sus vecinos cercanos y asignar un valor binario (0 o 1) a cada comparación, dependiendo de si el vecino es mayor o menor que el píxel central. Para luego, construir un número binario a partir de estos valores a este número se considera el valor LBP del píxel central. Este proceso se repite para cada píxel de la imagen, generando un mapa de patrones locales que representa las texturas locales de la imagen (Verdeguer Valderrama, 2022).

Los códigos LBP son útiles para hacer comparaciones y asociaciones entre la apariencia de la misma persona en diferentes vistas de cámara (Wu et al., 2021). El funcionamiento del LBP en la Re-Identificación de personas se representa en la Figura 1:

Figura 1

El operador LBP básico



Nota. La imagen muestra el funcionamiento del LBP básico. Tomado de (Pérez Villagómez & Velasteguí Asto, 2023).

La imagen muestra un diagrama que ilustra el proceso de conversión de una imagen en código binario. El diagrama consta de tres partes: la imagen original, la imagen después del umbral y el código binario final. La imagen original es una imagen en escala de grises de un cuadrado con una flecha apuntando hacia la derecha. La imagen después del umbral es una imagen en blanco y negro del cuadrado con la flecha. El código binario final se compone de una serie de 1s y 0s, con el equivalente decimal de 203 (Pérez Villagómez & Velasteguí Asto, 2023).

El procedimiento del LBP en la tarea de Re-Identificación de personas involucra los siguientes pasos: i) se **calculan los códigos LBP** de cada píxel de la imagen facial, se crea un histograma que cuenta la frecuencia de ocurrencia de cada patrón binario local en toda la imagen y se normaliza para que la representación sea más robusta ante cambios en la iluminación y escala, ii) para la identificación del rostro se **compara el histograma LBP** de una imagen de prueba con los histogramas LBP almacenados previamente en un datasets, en donde, se busca la imagen que tenga la mayor similitud con la imagen de prueba. Para esta comparación se pueden utilizar varios métodos de clasificación y métricas de similitud, iii) una vez asociada la apariencia de la misma persona en diferentes imágenes, se puede **realizar la Re-Identificación** de personas determinando si una persona concreta aparece en más de una cámara o escena (Ahonen et al., 2006).

Histogram of Orient Gradient (HoG)

Es un descriptor de características utilizado en visión por ordenador y procesamiento de imágenes para tareas de detección y reconocimiento de objetos (Greeshma & Gripsy, 2020). Se utiliza para representar la distribución de los gradientes de intensidad en una imagen, lo que permite capturar patrones locales y formas de objetos (Surasak et al., 2018).


En la Re-Identificación de personas, el HoG se utiliza como descriptor de características para representar el aspecto visual de una persona en una imagen. Al calcular el descriptor HoG en distintas regiones de la imagen se obtienen vectores de características que resaltan los

bordes y contornos relevantes de la persona. Estos vectores de características son útiles para comparar y relacionar la apariencia de la misma persona en diferentes vistas de cámara, ya que son relativamente invariables a los cambios de iluminación y color (Lu et al., 2022). El procedimiento para obtener este tipo de detector se basa en la evaluación de un conjunto normalizado de HoG (de Mur, 2017).

A continuación, se describen brevemente los pasos de este algoritmo: **normalizar color/gamma**, el cual es un proceso opcional que se aplica para reducir los efectos de iluminación y mejorar la calidad de la imagen y se utiliza en tareas de detección, su aplicación no siempre da lugar a mejoras significativas, **calcular el gradiente**, cuyo objetivo es obtener la información de la silueta mediante el gradiente, esto implica calcular las derivadas en las direcciones x e y de la imagen para obtener la magnitud y la orientación del gradiente en cada punto y **dividir en celdas**, en donde la imagen se divide en celdas rectangulares superpuestas de un tamaño determinado (por ejemplo, 8x8 píxeles), en cada celda, se agrupan los valores de magnitud y orientación del gradiente de los píxeles contenidos en ella y capturar las características locales de la imagen de una manera más robusta y discriminativa, para luego **construir un histograma** para cada celda se genera un histograma que resume la distribución de las orientaciones de los gradientes presentes en esa celda, el siguiente paso es **normalizar los bloques** que es una técnica para mejorar la invariabilidad de la iluminación, el sombreado y el contraste de los bordes, y el último paso es **agrupar los descriptores** para integrar los descriptores HoG de todos los bloques que cubren la imagen se concatenan en un vector unidimensional, lo que produce el descriptor HoG completo que representa la apariencia de la imagen, ver Figura 2:

Figura 2

Pasos de HoG para la Re-Identificación mediante la textura de la ropa



Nota. El diagrama representa el marco para obtener descriptores HoG. Tomado de (de Mur, 2017).

El resultado final del proceso HoG es un vector de características que representa la imagen y captura la distribución de gradientes dirigidos. Estos vectores de características se utilizan para entrenar clasificadores o realizar tareas de detección y reconocimiento de objetos.

CS-HOG. o HOG basado en la similitud del color, es una característica basada en la similitud del color para la detección de objetos de formas. Los métodos convencionales de detección de objetos suelen utilizar características locales basadas en la forma del objeto, de las cuales la característica HOG (Histograma de Gradientes Orientados) es típica. En los últimos años, se ha propuesto la Autosimilitud de Color (CSS) como característica local que utiliza información de color. La CSS consiste en calcular la similitud de color como base para decidir la similitud de los objetos y, por lo tanto, representa una característica eficaz para la detección de objetos. La característica CS-HOG permite clarificar la forma del objeto utilizando la similitud de color para calcular el grado de similitud del objeto, consiguiendo así una detección de objetos muy precisa (Matsumura & Hanazawa, 2019).

Machine Learning (Aprendizaje automático)

Permitir que los computadores "aprendan" sin que se les enseñe explícitamente es el objetivo principal de la rama de la informática conocida como aprendizaje automático. En el aprendizaje automático, las computadoras "aprenden" a través de la "experiencia", lo que les hace más competentes en las tareas (Bi et al., 2019).

En la Re-Identificación de personas, el aprendizaje automático es importante para reconocer si una persona ya se ha observado en una red de cámaras. Se utilizan técnicas de aprendizaje automático para crear modelos que aprenden de la información de entrada al procesar imágenes para obtener características útiles (Lavi et al., 2020).

El aprendizaje automático de Re-Identificación de personas se basa en la extracción y el análisis de características visuales de las personas para realizar la tarea de reconocer e identificar individuos en una variedad de cámaras y/o situaciones. El proceso completo de Re-ID de personas utilizando aprendizaje automático se puede describirse de la siguiente manera: Se **Recopilan los datos**, se coleccionan imágenes o videos que contienen personas en diferentes posturas. Para desarrollar y probar modelos de aprendizaje automático, se utilizan estos conjuntos de datos, también conocidos **dataset**. Luego, se realiza la **Detección y**

extracción de regiones de interés (ROIs), en este paso se utilizan técnicas que permiten localizar y extraer regiones que contengan personas en cada imagen o secuencias de imágenes. Estas regiones contienen el cuerpo completo o partes específicas de la persona. Una vez obtenidas estas ROIs se realiza la **Extracción de características** tiene como objetivo obtener rasgos visuales descriptivas de la persona, utilizando diferentes técnicas como LBP e Histogramas de Color entre otros. Estos métodos encuentran los descriptores de textura y el color de la ropa. Además, existen modelos de redes neuronales, como las redes neuronales convolucionales (CNN), que cuando se aplican a partes específicas de la imagen, permiten la creación automática de descriptores mediante el aprendizaje y el énfasis en la información relevante (H. Zhang et al., 2017). Estas características representan la apariencia visual de las personas y son utilizadas para la comparación y el reconocimiento posterior. Después, se realiza la División de datos para crear conjuntos de entrenamiento y prueba para entrenar el modelo de aprendizaje automático, que puede ser un clasificador, una red neuronal o cualquier otro algoritmo de aprendizaje. El modelo aprende a mapear las características de entrada a una representación espacial que sea discriminativa y que pueda distinguir a las personas entre sí. Se evaluará el modelo a partir del conjunto de pruebas, se **Ajustará** y, si es necesario, se modificarán sus parámetros para aumentar su precisión y aplicabilidad. Y finalmente ejecutar el **Reconocimiento y emparejamiento** de personas (a este proceso se conoce como clasificación) en diferentes cámaras o momentos. Esto sucede cuando se presenta una nueva imagen o secuencia de imágenes el modelo extrae sus características y las compara con las características de las personas conocidas en el conjunto de entrenamiento para determinar si existe una correspondencia. Además, en algunos casos se puede aplicar técnicas de **Post-procesamiento y análisis** para mejorar aún más la precisión de la identificación y enfrentarse a problemas determinados como es la agrupación de resultados similares y el rechazo de coincidencias incorrectas.

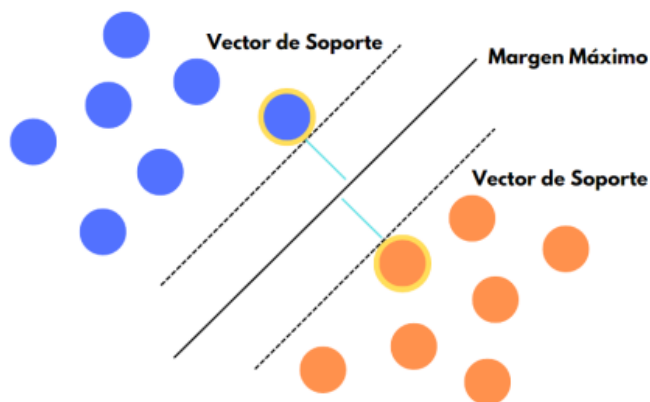
En este trabajo, a Re-Identificación de personas resulta ser un proceso complejo para identificar personas en diferentes lugares y momentos, que combina la extracción de características visuales descriptivas con modelos y/o algoritmos de aprendizaje automático. Algunos de los modelos que se pueden utilizar en la clasificación de personas (identificación) son: SVM, CNN y DNN. Además, se puede indicar que, la elección del clasificador depende de la naturaleza específica del problema de Re-Identificación y de la complejidad de los datos en cuestión, con el fin de lograr una precisión óptima en la Re-Identificación de individuos bajo diferentes vistas y condiciones de cámara.

Support Vector Machine (SVM)

En los ámbitos del procesamiento de imágenes, las SVM son un tipo de método de aprendizaje automático supervisado que se utiliza para realizar tareas de clasificación y regresión. La idea básica de las SVM es encontrar el hiperplano óptimo que mejor separa las Clases de datos en un espacio de características de alta dimensión (Cortes & Vapnik, 1995), conocidos como vectores de soporte (ver Figura 3). Los vectores de soporte son ubicaciones que determinan la mayor separación posible entre los hiperplanos de las distintas Clases. Dado que cubren el mismo número de dimensiones que el espacio de entrada, se denominan vectores en lugar de puntos. En otras palabras, estos puntos multidimensionales se representan mediante vectores n-dimensionales.

Figura 3

Máquina de vectores soporte



Nota. Ilustración del funcionamiento de la SVM. Tomado de (Zubiaga et al., 2009).

Se pueden utilizar SVM para re-identificar a las personas para resolver el problema de la clasificación binaria. Dado un par de imágenes (por ejemplo, la imagen de una persona captada por una cámara y la imagen de una persona captada por otra cámara), la SVM intenta determinar si ambas imágenes corresponden a la misma persona (Han et al., 2015; Navarro Clavería, 2020). La técnica busca un hiperplano en el espacio de características que maximice el margen entre dos clases (misma persona o no); la SVM aprende a diferenciar los datos positivos (pares de imágenes de la misma persona) de los negativos (pares de imágenes de diferentes personas) localizando el mejor hiperplano (Cortes & Vapnik, 1995).

En este estudio se emplea un clasificador de máquina de vectores de soporte (SVM). El clasificador recibe como entrada uno o una mezcla de descriptores, como LBP, HOG y/o CNN, que pueden utilizarse para evaluar si las entradas se ajustan a las características de un determinado individuo.

Convolutional Neural Network (CNN)

Para procesar imágenes, un diseño común de red neuronal profunda es la red neuronal convolucional. Inspirado en el sistema visual humano y ha demostrado ser altamente efectivo en tareas de Visión por Computadora (LeCun et al., 2015).

Las CNN utilizan capas de convolución y agrupación para extraer características relevantes de las imágenes y crear mapas de características mediante filtros de convolución. Estos filtros desarrollan la capacidad de reconocer pequeños patrones en las imágenes, como bordes, texturas y formas (Zheng et al., 2017). A continuación, la dimensionalidad de los mapas de características se reduce mediante la agrupación de capas para mantener las características más importantes (LeCun et al., 2015). A medida que avanza la red, las capas convolucionales y de agrupación se combinan con capas totalmente conectadas. Este último realiza la clasificación final según las características extraídas. El entrenamiento de las CNN se realiza a través de la retropropagación de errores, donde los pesos de conexión se ajustan para minimizar la diferencia entre la salida prevista y la etiqueta real. Este proceso de entrenamiento se realiza utilizando grandes conjuntos de datos etiquetados (LeCun et al., 2015).

En la Re-Identificación de personas, las CNN pueden utilizarse en varias configuraciones, siendo una de las más populares el uso de redes siamesas. Una red simulada consiste en dos ramas CNN idénticas que comparten los mismos pesos y la misma arquitectura. Estas dos ramas procesan simultáneamente dos imágenes de entrada. Cada rama extrae características visuales de las imágenes y finalmente compara la similitud de las características entre las dos imágenes en la capa de comparación (Song et al., 2019).

Deep Neural Network (DNN)

Una red neuronal profunda (DNN) modela el cerebro humano aprendiendo representaciones abstractas y complicadas a partir de los datos entrantes mediante el empleo de varias capas ocultas (LeCun et al., 2015).

El funcionamiento de una DNN se basa en la propagación de errores hacia adelante y hacia atrás. Durante la propagación directa, los datos de entrada pasan a través de capas ocultas de la red, donde se aplican una transformación lineal y una función de activación no lineal para obtener la salida final. Durante la retropropagación de errores, calculamos la diferencia entre los resultados previstos y esperados y ajustamos los pesos de las conexiones de red para minimizar este error (Goodfellow et al., 2016).

Las DNN son eficaces en el procesamiento de imágenes por su capacidad para aprender automáticamente características relevantes de los datos. La primera capa del proceso de tratamiento de una imagen encuentra bordes, texturas y patrones, y las siguientes capas combinan estas características en muestras claras y abstractas. Esto permite que las DNN capturen información visual de alto nivel para sobresalir en tareas como la clasificación de objetos, la detección de características y la segmentación semántica (He et al., 2016; Krizhevsky et al., 2012). Las siguientes etapas pueden servir para ilustrar el funcionamiento de una DNN: En la **Fase de entrada**, la red neuronal recibe datos de entrada, que en este caso adoptan la forma de una imagen. Cada píxel de la imagen se expresa como un valor numérico, que constituye la base para el posterior tratamiento y análisis de los datos en el marco computacional de la red. La **Fase de propagación directa** es donde los datos de entrada se propagan sistemáticamente por las capas sucesivas de la red neuronal, empezando por la capa de entrada y terminando en la capa de salida. Las neuronas de cada capa utilizan funciones de activación y pesos para realizar las actividades. El **Paso computacional** en cada neurona, se calcula una combinación lineal de entradas ponderadas por pesos sinápticos. Luego se aplica una función de activación no lineal para introducir la no linealidad en la red. Capaz de aprender representaciones de datos complejas (LeCun et al., 2015). El **Paso de retropropagación** es donde se calcula el error comparando la salida de la red con el valor esperado y, a continuación, propaga el error hacia atrás para ajustar los pesos de forma iterativa utilizando algoritmos de optimización como el descenso de gradiente para mejorar el rendimiento de la

red. La **Etapa de salida**: finalmente, obtenemos una salida que puede ser una clasificación, regresión u otra tarea específica dependiendo del problema que queramos resolver en la red.

Las DNN son especialmente útiles para la Re-Identificación de personas por su capacidad para extraer representaciones de alto nivel y características semánticas de las imágenes. Estas redes pueden aprender a reconocer patrones y rasgos distintivos de una persona, como la ropa, el peinado, la postura y otros atributos visuales. Estas características pueden utilizarse para comparar personas en distintas imágenes y determinar si se trata de la misma persona (Mihaescu et al., 2020).

You Only Look Once (YOLO)

YOLO es un algoritmo de detección de objetos que está basado en redes neuronales convolucionales (CNN), aborda el problema asignado como una única tarea de regresión en la que la CNN predice simultáneamente las coordenadas de los cuadros delimitadores de los objetos y las clases de los objetos en esas regiones (Ultralytics, 2023).

YOLOv8 es una versión actualizada del conocido modelo de detección de objetos y segmentación de imágenes en tiempo real presentado por Ultralytics y disponible comercialmente desde el 10 de enero de 2023 (Manzoor et al., 2023). Esta herramienta ofrece rendimiento, flexibilidad y eficacia, con funciones como la detección y la segmentación, la estimación de la ubicación, el seguimiento y la clasificación de personas. YOLOv8 puede aplicarse a una amplia gama de tareas de inteligencia artificial visual, lo que lo hace lo suficientemente versátil para su uso en una gran variedad de aplicaciones y dominios (Ultralytics, 2023).

En el marco del problema de la Re-Identificación de personas, se utiliza el modelo YOLO, para abordar el reto de relacionar la apariencia de una misma persona a través de diferentes vistas de cámara. La eficacia y rapidez del modelo YOLO en la detección de objetos permite predecir la posición de un objeto y su correspondiente probabilidad directamente a

partir de la imagen original en tiempo real. Esta característica lo hace ideal para aplicaciones que requieren un reconocimiento de personas rápido y preciso (Mihaescu et al., 2020).

Las principales ventajas e inconvenientes del empleo de YOLO para la detección de objetos se exponen en la Tabla 1.

Tabla 1

Resume las principales ventajas y desventajas de utilizar YOLO

Ventajas	Desventajas
- Detección de objetos en tiempo real	- Precisión reducida para objetos pequeños
- Un solo pase adelante para la detección	- Errores de localización
- Enfoque unificado para la predicción de cajas delimitadoras y Clases	- Tiempo de entrenamiento puede ser computacionalmente costoso
- Manejo eficiente de múltiples objetos	- Información contextual limitada
	- Falta de invariancia a la rotación

Nota. Esta Tabla muestra las ventajas que motivaron a usar YOLO dentro del proyecto de Re-ID de personas. Tomado de (Moreira Ramos, 2021).

Además, YOLO puede mejorar los modelos de aprendizaje automático proporcionando la detección de objetos de forma rápida y eficaz, lo que permite gestionar aplicaciones en tiempo real y mejorar la generalización de los modelos mediante una representación más robusta de los objetos en las imágenes. Es, por tanto, una valiosa herramienta para mejorar el rendimiento de los sistemas de videovigilancia.

Comparación de descriptores y clasificadores en la Re-Identificación de personas

El objetivo del proyecto es la comparación de diferentes modelos de Re-Identificación de personas concretas a partir del uso de características biométricas y soft-biométricas y de técnicas avanzadas computacionales con el fin de encontrar el modelo más preciso y fiable. Para ello, se han investigado los descriptores LBP y HoG, así como, los clasificadores SVM, CNN y DNN. Al incorporar atributos físicos como el rostro y junto con aspectos sutiles como la silueta corporal, la textura y el color de la ropa, se prevé que la introducción de estas técnicas aumente la precisión del proceso de Re-Identificación. La selección de descriptores y clasificadores adecuados hace posible lograr una mayor precisión en la Re-Identificación de

individuos, contribuyendo así a los avances en aplicaciones de seguridad y vigilancia, así como a mejorar la experiencia del usuario en entornos como el comercio electrónico y la biometría.

Para abordar este tema, se recogió información de diversos repositorios académicos y científicos sobre las combinaciones realizadas entre descriptores y clasificadores para la Re-Identificación de personas. La investigación permitió construir Tablas comparativas sobre las características y las combinaciones de los descriptores y clasificadores analizados anteriormente. En estas Tablas se resumen las técnicas y enfoques utilizadas, así como de los resultados de precisión obtenidos. Lo que proporciona una base sólida para comprender las fortalezas y limitaciones de cada combinación y facilita la identificación de las estrategias más efectivas en la Re-Identificación de personas.

En la Tabla 2 se presenta las precisiones obtenidas en la identificación de la característica biométrica facial de un individuo, recopiladas a partir de la revisión de diversos artículos científicos.

Tabla 2

Resumen de la característica biométrica, descriptores, clasificadores y porcentajes de precisión reportados en la literatura

Característica Biométrica	Descriptor	Clasificador	Precisión Máxima	Precisión Mínima
Facial	LBP	SVM	96.83%	90%
	HoG	CNN	95.33%	90.5%
	HoG	SVM	92%	64.6%
	LBP	CNN	98.16%	75.43%

Nota. Valores máximo y mínimo de precisión en el reconocimiento facial determinados por las bibliografías de varios estudios.

Para obtener la información presente en la Tabla 2 se examinaron artículos que utilizaron el descriptor LBP en combinación con el clasificador SVM. En donde, se encontró que la precisión máxima alcanzada fue del 96.83% (Shi et al., 2020), mientras que la precisión mínima fue del 90% (Aissaoui et al., 2014). Asimismo, se revisaron trabajos que utilizaron el

descriptor LBP junto con el clasificador CNN, obteniendo una precisión máxima del 95.33% y una precisión mínima del 90.5% (H. Zhang et al., 2017).

Además, los resultados se compararon con trabajos anteriores sobre el descriptor HoG junto con el clasificador SVM. En este caso, se registró una precisión máxima del 92% y una precisión mínima del 64.6% (Dadi & Pillutla, 2016). Por otro lado, se examinaron artículos que utilizaron el descriptor HoG junto con el clasificador CNN para la detección de rostros, y se obtuvo una precisión máxima del 98.16% y una precisión mínima del 75.43% (Hung, 2021).

En la revisión realizada se observa que tanto el descriptor LBP como el descriptor HoG pueden usarse con éxito para identificar la característica biométrica facial de un individuo. En cuanto al clasificador, tanto el SVM como el CNN han demostrado ser eficaces para este propósito. Los resultados muestran que el uso del descriptor HoG y el clasificador CNN arrojaron las mayores precisiones, con una precisión máxima del 98,16 %. También se lograron buenos resultados utilizando el descriptor LBP en combinación con ambos clasificadores, alcanzando precisiones máximas de hasta el 96.83 %. Estos hallazgos subrayan la importancia de elegir cuidadosamente los descriptores y clasificadores adecuados según las necesidades y las limitaciones del sistema de identificación biométrica facial.

En el presente estudio se evaluaron varios trabajos de investigación sobre el reconocimiento de rasgos soft-biométricos para la Re-Identificación de personas. Se recopilaron datos sobre los descriptores y clasificadores utilizados, así como los porcentajes de precisión reportados en los estudios revisados. Los resultados se resumen en la Tabla 3.

Tabla 3

Resumen de las características Soft-biométricas, descriptores, clasificadores y porcentajes de precisión reportados en la literatura

Característica Soft-biométricas	Descriptor	Clasificador	Precisión Máxima	Precisión Mínima
Silüeta corporal	LBP	CNN	28.95 %	17.93%
Textura de la ropa	LBP	CNN	50.95 %	-

Característica Soft-biométricas	Descriptor	Clasificador	Precisión Máxima	Precisión Mínima
	HoG	SVM	86.53 %	80.59 %
		CNN	100%	33.3 %
Color de la ropa	LBP	SVM	78%	62%

Nota. Se presentan los valores máximos y mínimos de precisión en base a las características soft-biométricas según la literatura investigada.

La Tabla 3 muestra los resultados obtenidos para las características soft-biométricas: la silueta corporal, la textura y color de la ropa. Para la silueta corporal, se encontraron dos artículos que usan el descriptor LBP junto con el clasificador CNN. Según ese estudio, se reportó una precisión máxima del 28.95% (Carrillo-Medina et al., 2022), y en otro una precisión mínima del 17.93% (Gavilanes et al., 2022).

En cuanto a la textura de la ropa, se identificó un artículo que exploraron el descriptor LBP con el clasificador CNN. Que reportó una precisión máxima del 50.95% (Carrillo-Medina et al., 2022), el mismo no proporcionó información sobre la precisión mínima.

Además, se encontró un artículo que empleó el descriptor HoG junto con el clasificador SVM para analizar la textura de la ropa. Según ese estudio, se obtuvo una precisión máxima del 86.53% (Greeshma & Gripsy, 2020), mientras que en otro trabajo la precisión mínima fue del 80.59% (Kumar & Mishra, 2020).

En relación con otro artículo que investigó el descriptor HoG junto al clasificador CNN. Según los resultados obtenidos, se alcanzó una precisión máxima del 100% y una precisión mínima del 33.3% (Nodehi & Shahbahrami, 2021).

En el curso de un estudio de clasificación mediante una combinación de descriptores LBPH y clasificación SVM, se comprobó que la Re-Identificación de individuos mediante cámaras de bucle cerrado arrojaba una notable precisión de hasta el 78,77% y una precisión mínima del 62% en la evaluación del atributo soft-biométrico identificable, el color de la ropa (Echeverría Perugachi & Segovia Espinosa, 2023).

Los presentes resultados reflejan la variabilidad en el rendimiento de las características soft-biométricas en función de los descriptores y clasificadores utilizados, tal y como se recoge en la bibliografía revisada. Los porcentajes de precisión presentados en la Tabla 3 se obtienen de estudios previos y no de una experimentación realizada en investigación.

Arquitecturas de altas prestaciones (GPU y CPU)

Los sistemas informáticos dependen en gran medida de las unidades de procesamiento gráfico (GPU) y las unidades centrales de procesamiento (CPU). Las CPU son procesadores diseñados específicamente para realizar tareas que van desde el cálculo matemático a la gestión de datos, mientras que las GPU se utilizan para generar gráficos diseñados para acelerar el renderizado y el procesamiento paralelo, algo esencial para aplicaciones estéticas y de cálculo intensivo (Kidger & Lyons, 2020).

Las GPU tienen un gran número de núcleos dedicados al procesamiento paralelo como resultado de su diseño, lo que permite una gran capacidad de procesamiento paralelo. Debido a que estos núcleos están contruidos para acelerar el procesamiento computacional y paralelo, son perfectos para aplicaciones de aprendizaje automático, que con frecuencia requieren una gran cantidad de datos y un procesamiento pesado. En particular, las GPU Nvidia se utilizan ampliamente en aplicaciones de aprendizaje automático debido a su alto rendimiento y compatibilidad con marcos y librerías comunes (Buber & Banu, 2018).

Las CPU, por su parte, son procesadores de propósito general que realizan tareas de forma secuencial y se distinguen por su adaptabilidad y capacidad para manejar una amplia variedad de tareas. Aunque tienen menos núcleos que las GPU, las CPU pueden procesar con rapidez tareas complejas de lógica, control y ejecución secuencial de instrucciones gracias a su diseño estructural. Además, las CPU tienen mayor capacidad de caché y están mejor preparadas para soportar tareas de entrada y salida de datos (Buber & Banu, 2018).

A continuación, en la Tabla 4 se resume las principales ventajas y desventajas de utilizar las arquitecturas de altas prestaciones.

Tabla 4

Ventajas y desventajas de las arquitecturas de altas prestaciones

Aspecto	Ventajas	Desventajas
GPU	<ul style="list-style-type: none"> - Alto rendimiento en tareas de procesamiento paralelo. - Acelera el aprendizaje y la inferencia de modelos. - Eficiente uso de marcos y bibliotecas de aprendizaje profundo. - Simplifica el desarrollo y la implantación de modelos complejos. 	<ul style="list-style-type: none"> - Mayor consumo de energía y generación de calor. - No todas las tareas se benefician del paralelismo.
CPU	<ul style="list-style-type: none"> - Versatilidad y capacidad para manejar diversas tareas. - Eficiencia en tareas de lógica compleja y secuenciales. - Soporta tareas de entrada y salida de datos. 	<ul style="list-style-type: none"> - Menor rendimiento en tareas de procesamiento paralelo. - Capacidad de caché limitada comparada con GPU. - Requiere enfoque secuencial para ciertas tareas.

Nota. en esta Tabla se detallan los beneficios que ofrece el uso de CPU y GPU. Tomado de (De Giusti et al., 2014).

En conclusión, tanto las GPU como las CPU desempeñan un papel importante en el aprendizaje automático. Las GPU ofrecen un gran rendimiento en aplicaciones altamente paralelas, acelerando tanto el entrenamiento como la inferencia de modelos. La decisión entre GPU y CPU depende del tipo de actividad de aprendizaje automático, los requisitos de rendimiento y los límites de coste y energía. Las CPU, por su parte, son más adaptables e ideales para operaciones lógicas secuenciales y complicadas.


Metodología SCRUM

Debido a las importantes ventajas que ofrece la técnica Scrum en el desarrollo ágil, decidimos aplicarla en nuestro proyecto. Scrum se basa en un enfoque iterativo e incremental que promueve la entrega continua de valor por parte de los equipos de desarrollo (Sims & Johnson, 2012). Esta metodología permite la demostración temprana de resultados tangibles y promueve la retroalimentación oportuna. Además, Scrum fomenta la mejora continua a través

de un ciclo retrospectivo en el que se analizan los procesos y se identifican las oportunidades de mejora.

Figura 4

Marco de trabajo de SCRUM



Nota. En la imagen se presenta el flujo con el que trabaja la metodología SCRUM. Tomado de (Foreman, 2018).

La Figura 4 es un diagrama de flujo del marco de trabajo Scrum. El diagrama está en orientación horizontal y está dividido en 7 secciones, cada una representando una etapa diferente del marco de trabajo Scrum. Las secciones están conectadas por flechas, indicando el flujo del proceso. El proceso comienza con una lista priorizada de características y requisitos del producto, conocida como "Backlog del producto". Luego, durante la "Planificación de Sprint", el equipo selecciona los elementos del inventario de productos que se completarán durante el próximo Sprint y los agrega al "Sprint Backlog". Para coordinar sus esfuerzos durante el Sprint, el equipo celebra reuniones diarias llamadas "Scrum Diario". Durante la "Revisión de Sprint", el equipo presenta el "Incremento" de producto terminado. Finalmente, el equipo realiza una "Retrospectiva del Sprint" para reflexionar sobre el Sprint y encontrar formas de mejorar. Los "Sprints" se implementan entre dos a cuatro semanas. El equipo se concentra en el desarrollo de un conjunto de características a lo largo de cada sprint, que se presentan en

una lista de prioridades predeterminada llamada "backlog de productos". El trabajo se organiza en elementos más pequeños denominados "historias de usuario", que son necesidades y requisitos proporcionados por los clientes (Turner, 2020).

Capítulo III

Implementación del sistema


En el presente capítulo se explica de manera detallada el proceso de desarrollo del estudio comparativo sobre el uso de técnicas, modelos y/o algoritmos, basados en características biométricas y soft-biométricas para la Re-Identificación de personas, mediante arquitecturas de altas prestaciones, CPUs y GPUs. Para lo cual se implementa un sistema de Re-Identificación de personas, en donde se combinarán distintos descriptores y clasificadores comparando su rendimiento durante la detección de personas.

Para tener claro el funcionamiento del sistema de Re-Identificación de personas en un circuito cerrado de cámaras, se señala de manera general dicho proceso, así como también se plasma, a manera de esquema, en la Figura 5:

- Creación del dataset a partir de las imágenes captadas en un circuito cerrado de cámaras.
- Procesamiento de las imágenes captadas por las cámaras son procesadas usando por los diferentes algoritmos que extraen sus características biométricas y soft-biométricas.
- Entrenamiento del modelo mediante los datasets con el que se realizará la Re-Identificación de personas.
- Aplicación de métricas de evaluación que permiten verificar la eficiencia del sistema de Re-Identificación de personas.

Figura 5

Funcionamiento de un sistema de RE-ID de personas



Nota. Conservando la misma nomenclatura de nombres, así por ejemplo al inicio se llama sistema de Re-Identificación, ahora se llama sistema de RE-ID. Tomado de (Betancourt et al., 2023)

Para establecer un marco más organizado y un camino claro para el desarrollo del proyecto, como se ha señalado antes. Para ello, se adoptó la metodología ágil Scrum, esta elección está motivada por su capacidad para gestionar de forma coherente las expectativas del cliente y predecir los resultados del proyecto (Sims & Johnson, 2012). Scrum está enfocado en cumplir con las necesidades de usuarios que poseen requisitos organizados en los denominados Sprints. Los Sprints son particiones de entregables que pueden elaborarse en plazos de 2 a 4 semanas. En estos periodos se desarrollan activamente segmentos de los entregables del producto final (Godoy, 2015).

Otra de las razones por las que se escogió Scrum como metodología de desarrollo, debido a roles definidos para cada miembro del equipo, en donde todos poseen responsabilidades y funciones propias, como se detalla en la Tabla 5.

Tabla 5*Roles principales en SCRUM*

Rol de SCRUM	Descripción
Scrum Master / Líder del Equipo de Scrum	Es el encargado de asegurar que todos los miembros del equipo comprendan y apliquen de manera correcta las bases y prácticas de SCRUM.
Product Owner / Propietario del Producto	Su responsabilidad dentro del proyecto es decir que cosas se deben implementar, es decir es como el “dueño del producto”.
Development Team / Equipo de Desarrollo	Son responsables de elaborar el producto de software de acuerdo con los requisitos definidos.

Nota. Roles principales del SCRUM. Tomado de (Schwaber & Sutherland, 2020).

Según Cadavid *et al.* (2013) menciona las actividades que son de vital importancia, dentro la metodología Scrum, para el desarrollo de un proyecto de software, las cuales se detallan a manera de esquema en la Figura 6:


- **Sprint:** es un lapso establecido y corto, que generalmente tiene una duración de una a cuatro semanas, en donde el equipo se concentra en trabajar para culminar un conjunto de elementos del Backlog (lista ordenada de elementos de trabajo que representan las funcionalidades) del Producto (Cadavid et al., 2013).
- **Planificación del Sprint (Sprint Planning):** es una reunión que se realiza al inicio de cada sprint, en la cual el Product Owner y el Scrum Team trabajan de manera colaborativa para definir qué elementos del Product Backlog van a ser abordados durante el Sprint (Cadavid et al., 2013).
- **Reuniones diarias (Daily Scrum):** es una reunión corta que generalmente tiene una duración de 15 minutos, en donde todos los miembros de Scrum coordinan su trabajo y su progreso (Cadavid et al., 2013).
- **Revisión del Sprint (Sprint Review):** esta etapa sucede al final de cada Sprint, en la cual el equipo Scrum muestra el trabajo realizado al Product Owner y a las demás

partes interesadas, para que de esta manera se obtenga una retroalimentación que ayude a ajustar el Backlog del producto según se necesite (Cadavid et al., 2013).

- **Retrospectiva del Sprint (Sprint Retrospective):** en una reunión, el equipo dialoga acerca de su rendimiento durante el sprint y busca la forma de mejorar su manera de trabajar para el próximo sprint. Se identifican los aspectos que funcionaron bien y las oportunidades para mejorar (Cadavid et al., 2013).

Figura 6

Marco de trabajo de SCRUM



Nota. En la imagen se presenta el flujo con el que trabaja la metodología SCRUM Tomado de (Foreman, 2018).

En el ámbito de desarrollo de software es importante medir y cuantificar el rendimiento de las tareas que se realizan en determinadas etapas del proyecto. Este apartado se enfoca en las métricas de evaluación, que se aplican durante la fase de pruebas del sistema de Re-Identificación de personas. El uso de estas métricas es importante para el equipo de desarrollo,

ya que proporcionan información significativa sobre el estado del proyecto, mejoran su comprensión, permiten prevenir fallos y buscar mejoras (Almeida & Carneiro, 2021).

De lo anteriormente descrito, para evaluar la efectividad del sistema de Re-Identificación de personas, en base a las características biométricas (rostro) y soft-biométricas (silueta corporal, textura y color de la ropa), se deben aplicar métricas de evaluación que ayudan a determinarla de manera cuantitativa. Las métricas de evaluación usadas son las siguientes:

- **Exactitud (Accuracy):** mide la proporción de casos acertados por el modelo (conjunto de algoritmos y técnicas de aprendizaje automático que se emplean para extraer, comparar y reconocer rasgos particulares en imágenes de personas), es decir, mide la cantidad de predicciones (resultados que un modelo produce al analizar los videos para determinar la similitud de las personas involucradas) correctas tiene sobre el número total de predicciones (Muñoz Villanueva, 2022).

$$Accuracy = \frac{\# \text{ de predicciones correctas}}{\# \text{ total de predicciones}} = \frac{VP + VN}{VP + VN + FP + FN}$$

- **Sensibilidad (Recall):** esta métrica brinda datos referentes a la capacidad que tiene el modelo de Machine Learning para identificar correctamente a la misma persona, en esencia representa de manera porcentual la cantidad de personar que el modelo es capaz de detectar con precisión (Yunga Pedraza, 2023).

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

- **Precisión (Precision):** esta métrica mide la exactitud del modelo de Machine Learning en cuanto a las tareas de clasificación de datos, por lo que mide la cantidad de aciertos en la predicción de patrones positivos, tomando en cuenta el total de predicciones positivas realizadas por el modelo en una Clase positiva (Sánchez Vidal, 2021).

$$Precision = \frac{VP}{VP + FP}$$

Para realizar los cálculos de las métricas en base a las fórmulas anteriores, se crea la matriz de confusión. En esta matriz, se ubican los valores que indican la cantidad de verdaderos positivos, falsos positivos, verdaderos negativos y falsos negativos, de la manera que se indica en la Figura 7.

Figura 7

Matriz de confusión



Nota. Se observa el esquema de funcionamiento de la matriz de confusión.

Con el propósito de mejorar el análisis de los valores que conforman la matriz de confusión en la Tabla 6 se muestran los resultados que se obtienen al realizar las pruebas. En esta tabla las Clases reales están representadas por las filas y las Clases que el modelo predijo por las columnas.

Tabla 6

Valores de la matriz de confusión

	Positivos	Negativos
Positivos	Verdaderos Positivos (VP)	Falsos Positivos (FP)
Negativos	Falsos Negativos (FN)	Verdaderos Negativos (VN)

Nota. Se muestran las abreviaciones y los significados de los valores.

A continuación, se detalla el significado de cada elemento de la matriz de confusión:

- **Positivo (P):** sucede cuando la detección es correcta, se le asigna el valor de (1).
- **Negativo (N):** sucede en el caso de que la detección falla se le asigna el valor de (0).
- **Verdadero Positivo (VP):** cuando el valor real es positivo y el modelo predice correctamente (1,1).
- **Verdadero Negativo (VN):** cuando el modelo realiza una predicción acertada para una Clase negativa (0,0).
- **Falso Positivo (FP):** cuando el modelo comete el error de predecir que una Clase es positiva cuando en realidad es negativa (0,1).
- **Falso Negativo (FN):** cuando el modelo comete el error de predecir que una Clase es negativa cuando en realidad es positiva (1,0).

Las métricas de evaluación del sistema de Re-Identificación de personas permiten realizar una comparación entre los rendimientos que presentan tanto la CPU como la GPU, para lo cual se han seleccionado las siguientes:

- **Tiempo de ejecución:** Es una métrica fundamental que indica el tiempo que tarda el programa en completar su ejecución. Se mide en segundos o milisegundos. Un menor tiempo de ejecución indica una mayor eficiencia en el rendimiento del programa (Dorronsoro Larbide, 2023).

$$Time = Tiempo\ final - Tiempo\ inicial$$

- **Uso de la CPU o GPU:** Mide la carga de trabajo de la CPU o GPU durante la ejecución del programa. Se puede expresar en términos de porcentaje de uso o porcentaje de recursos disponibles. Un uso más eficiente de la CPU o GPU indica que el programa está aprovechando adecuadamente el hardware para realizar las tareas requeridas.

$$Utilization = \frac{Tiempo\ de\ uso\ de\ CPU\ o\ GPU}{Tiempo\ total\ de\ ejecucion} \times 100$$

- **Frecuencia de cuadros (FPS):** Es una métrica común en aplicaciones gráficas o de visualización en tiempo real. Representa la cantidad de cuadros por segundo que el

programa puede renderizar o mostrar en pantalla. Un FPS más alto indica una experiencia de usuario más fluida y una mayor capacidad para procesar información visual en tiempo real (Machado de Benedetti, 2021).

$$FPS = \frac{1}{Tiempo\ por\ cuadro}$$

- **Utilización de memoria:** Mide la cantidad de memoria utilizada por el programa durante su ejecución. Tanto la CPU como la GPU tienen sus propias memorias, y una utilización eficiente de la memoria es esencial para un rendimiento óptimo (Montes de Oca, 2018).

$$Memory\ Utilization = \frac{Memoria\ utilizada\ por\ el\ programa}{Memoria\ total\ disponible} \times 100$$

- **Aceleración:** Para programas que usan GPU para aceleración, se puede medir la cantidad de aceleración comparada con una versión del programa que solo usa la CPU. La aceleración se refiere a la mejora en el rendimiento que se logra al utilizar la GPU para tareas específicas.

$$Acceleration = \frac{Tiempo\ de\ ejecucion\ utilizando\ solo\ CPU}{Tiempo\ de\ ejecucion\ utilizando\ GPU} \times 100$$

Estas métricas son solo algunos ejemplos con los cuales se puede evaluar el rendimiento de un programa en plataformas con GPU o CPU. La selección de las métricas adecuadas dependerá del tipo de programa y los objetivos específicos de rendimiento que se deseen alcanzar. Es importante realizar pruebas exhaustivas y comparativas para obtener una evaluación completa y precisa del rendimiento del programa en cada plataforma.

La eficiencia es un equilibrio entre el rendimiento obtenido y los recursos utilizados. Un sistema eficiente es capaz de lograr resultados deseados en un tiempo razonable y con un uso adecuado de los recursos disponibles. La evaluación de la eficiencia en un sistema de Re-Identificación de Personas debe considerar tanto el rendimiento técnico como los objetivos y las necesidades específicas de la aplicación.

Análisis y Diseño del Sistema

Análisis del Sistema

Una vez definida la metodología, se realiza la asignación de roles a cada miembro del equipo Scrum. Dentro del proceso de desarrollo cada rol juega un papel fundamental, ya que cada uno aporta con habilidades especializadas y responsabilidades claves. Gracias a esta estructura de roles, se puede asegurar una colaboración efectiva, una dinámica de trabajo fluida y el cumplimiento de los objetivos establecidos de manera exitosa. En la Tabla 7 se detallan los roles designados y las funciones específicas que desempeñan el equipo Scrum:

Tabla 7

Team Scrum / Equipo Scrum

N°.	Rol Scrum	Integrante	Funciones
1	Product Owner	Dr. José Luis Carrillo Medina	Definir los requisitos del sistema, establece los plazos de entrega y evalúa su cumplimiento.
2	Scrum Master	Steven Alexander Lema Velásquez	Líder del equipo, constata que se cumplan los tiempos establecidos a para cada sprint.
3	Development Team	Steven Alexander Lema Velásquez Alex Xavier Robayo Bastidas	Implementar el sistema de Re-Identificación de personas

Nota. Roles asignados a cada integrante del proyecto.

El equipo de desarrollo del proyecto lo forman 2 personas, para lo cual se asignó los roles de la Tabla 7. Como se puede observar estos miembros están encargados de las actividades del equipo de desarrollo y uno de ellos asume el rol de Scrum Master, el líder del proyecto ya que una de sus primeras tareas es pactar una reunión con todos los integrantes del proyecto. Una vez que los roles están definidos se procede con la especificación de requisitos, para lo cual se elaboran las historias de usuario necesarias para el desarrollo del proyecto, detalladas en la Tabla 8:

Tabla 8*Historias de Usuario*

ID	Nombre	Rol	Característica / Funcionalidad	Razón/resultado
1	HU.1	Como usuario	Necesito obtener un dataset con imágenes que contengan el rostro de una persona.	Para el entrenamiento del modelo de Identificación facial.
2	HU.2	Como usuario	Quiero un modelo de identificación facial mediante la aplicación de técnicas de Visión por Computadora y algoritmos de Machine Learning.	Para Identificar personas mediante su rostro.
3	HU.3	Como usuario	Necesito un dataset que contenga imágenes de las características soft-biométricas silueta corporal, textura y color de la ropa.	Para el entrenamiento del modelo de Machine Learning para Re-Identificar personas
4	HU.4	Como usuario	Quiero desarrollar modelos capaces de Re-identificar personas al combinar características soft-biométricas como la silueta corporal, la textura y color de la ropa.	Para Re-Identificar personas con el uso de cámaras no solapadas.
5	HU.5	Como usuario	Necesito validar los resultados de los modelos de Re-Identificación de personas y realizar una comparación del rendimiento del uso de procesadores (CPU y GPU).	Para validar los resultados de los modelos y realizar una comparación de rendimientos de la CPU y GPU.

Nota. Detalle de las historias de usuario.

Product Backlog del Proyecto

Una vez definidas las historias de usuario, el siguiente paso es la creación del Product Backlog del proyecto, en donde a cada historia de usuario se le asigna un plazo de tiempo (fecha de inicio y fecha de fin) de modo que pueda ser terminada, así como también el número de Sprint en el que se llevarán a cabo, siendo un total de tres sprints planificados, como se observa en la Tabla 9 de una manera más detallada.

Tabla 9*Product Backlog*

Historia de usuario	Nombre	Estimación (días)	Fecha inicio	Fecha fin	N° de Sprint
1	HU.1	4	02/05/2023	05/05/2023	1
2	HU.2	15	08/05/2023	26/05/2023	1
3	HU.3	15	29/05/2023	16/06/2023	2
4	HU.4	20	19/06/2023	14/07/2023	2
5	HU.5	20	17/07/2023	11/08/2023	3

Nota. Detalle del Product Backlog del proyecto.

La Tabla muestra historias de usuario con estimaciones de tiempo en días, fechas de inicio y finalización, y el número de Sprints en los que se llevarán a cabo. Cada historia tiene un nombre único y se asocia con detalles de planificación y desarrollo.

Escenario para el sistema de Re-Identificación de personas

Para la implementación del sistema de Re-identificación de personas se ha elegido un entorno controlado de la Universidad de las Fuerzas Armadas ESPE Sede Latacunga. La institución cuenta con gran variedad de espacios, para la elaboración de este proyecto se han seleccionado los pasillos de la institución, en esta área se han colocado cámaras con enfoques y ángulos de visión diferentes para abarcar y capturar la mayor parte del entorno. En este entorno se ejecutarán las pruebas del sistema de Re-Identificación de personas, como se observa en la Figura 8 y en la Figura 9.

Figura 8

Pasillo de la ESPE campus Belisario Quevedo




Nota. Este es lugar donde se realizarán las pruebas y validaciones.

En la Figura 8, se presenta un esquema de la disposición de las cámaras utilizadas para este proyecto, la cámara 1 está destinada al reconocimiento facial y generación de dataset mediante la extracción de características biométricas y soft-biométricas, la cámara 2 realiza el seguimiento de la persona mediante la Re-Identificación en base a las características soft-biométricas extraídas previamente.

Figura 9

Esquema de la disposición de las cámaras y su funcionalidad



Nota. Esquema con la disposición de la cámara 1, cámara 2 y la persona que será identificada.

La Figura 9 muestra el proceso de Re-Identificación el cual consta de las siguientes actividades:

1. Se crea el datasets de rostros con el cual se construye el modelo de rostros.
2. Con la 1ra Cámara:
 - 2.1. Se identifica a la persona mediante el modelo de rostro.
3. Con la 1ra Cámara:
 - 3.1. Se adquiere las imágenes de cuerpo completo.
 - 3.2. Se crea los descriptores de silueta, textura y color de la ropa.
 - 3.3. Se crea el modelo combinado de silueta, textura, y color de la ropa.
4. Con la 2da cámara:

- 4.1. Se emplea el modelo creado en el paso 3.3. para Re-Identificar a una persona, aunque no se le vea el rostro

Herramientas de Software para el Desarrollo del Sistema de Re-Identificación de Personas

Las herramientas que se utilizarán en el desarrollo de este proyecto se detallan en la Tabla 10, además se indica la versión de cada una de ellas, estas serán necesarias para la creación del Sistema de Re-Identificación de personas.

Tabla 10

Herramientas de software para el desarrollo del sistema de Re-Identificación de personas

Herramienta (Elemento Software)	Descripción
Codificación de la lógica del sistema mediante un Entorno de Desarrollo Integrado (IDE)	Para la codificación se usó Python versión 3.10 y como editor de código a Visual Studio Code
Procesamiento de imágenes, identificación por rostro, silueta corporal, textura de la ropa y color de la ropa	Algoritmos de Visión por Computadora: LBP y HoG, y Machine Learning: SVM, CNN (YOLOv8), DNN
Descriptores para la identificación por rostro, silueta corporal, textura de la ropa y color de la ropa	Descriptores LBP y HoG, los cuales son técnicas de Visión por Computadora
Clasificadores para la identificación por rostro, silueta corporal, textura de la ropa y color de la ropa	Clasificación de imágenes usando los algoritmos de SVM, DNN y CNN este último implementado mediante las facilidades que ofrece la arquitectura de detección de objetos YOLO
Algoritmos de identificación facial	Identificación facial usando los descriptores LBP y HoG, a fin de comparar las precisiones en esos porcentajes de acierto

Nota. Recursos de software usados dentro del proyecto de Re-ID.

Herramientas de Hardware para el Desarrollo del Sistema de Re-Identificación de Personas

A continuación, se presentan las herramientas de hardware que serán utilizadas en el desarrollo del sistema de Re-Identificación de personas, esta información se detalla en la Tabla 11.

Tabla 11*Herramientas de Hardware para el desarrollo*

Herramienta (Elemento Hardware)	Descripción
Procesador	Intel Core i7-13700K, 3.4Ghz, 16 Core
Memoria RAM	Memoria RAM DDR4, 32 GB
Disco Duro	Disco SSD de 1000 GB Kingston
Tarjeta Gráfica	NVIDIA GEFORCE RTX 3060 12GB

Nota. Recursos de hardware usados dentro del proyecto de Re-ID.

Implementación de técnicas de Visión por Computadora y algoritmos de Machine***Learning para la identificación facial, silueta corporal, textura y color de la ropa***

Continuando con la guía que proporciona la metodología Scrum, una vez creado el Product Backlog del proyecto en donde se detalló las diferentes Historias de Usuario con el número de Sprint asignado, se procede con la planificación para cada periodo de trabajo (Sprint), considerando de manera cuidadosa la prioridad y el orden en el que va a desarrollar a tarea según la importancia que tenga para el desarrollo, de esta manera los objetivos planteados para cada Sprint serán alcanzados en el tiempo establecido.

Acorde a la metodología Scrum es de vital importancia organizar reuniones sean estas presenciales o virtuales, para lo cual es necesario recalcar que, a lo largo de la planificación, se han pactado varias reuniones virtuales usando la plataforma Google Meet y además reuniones presenciales en la Universidad de Las Fuerzas Armadas ESPE Sede Latacunga.

Sprint 01: Generación de dataset de rostros y algoritmo de identificación facial

En base a las reuniones de planificación se definió que para el Sprint 01 se tomará en cuenta a las historias de usuario H.U.01 y H.U.02, especificadas en la Tabla 8, el principal objetivo de este Sprint es obtener un dataset que contenga imágenes de rostros.

H.U.01: Obtención de dataset de rostros

En la historia de usuario H.U.01, se especifica la necesidad de la creación de un dataset que contenga imágenes de rostros de personas. A continuación, en la Tabla 12 se detalla la

historia de usuario H.U.01, tomando en cuenta las personas a cargo del desarrollo y los requisitos que deben cumplirse para la creación del dataset de rostros.

Tabla 12

Historia de usuario H.U.01

Historia de Usuario	
Numero: H.U.01	Usuario: Usuario
Nombre historia: Obtención de dataset de rostros	Numero Sprint: 01
Prioridad: Alta	Riesgo de desarrollo: Media
Días estimados: 4	Interacción asignada: 1
Desarrolladores responsables: Steven Lema, Alex Robayo	
Descripción: Como usuario necesito obtener un dataset con imágenes que contengan el rostro de una persona.	
Validación:	
<ul style="list-style-type: none"> • Generar videos en un entorno controlado del Campus de la Universidad. • Extraer imágenes de los rostros obtenidos con sus respectivas etiquetas de cada frame de los videos generados. • Almacenar las imágenes y etiquetas de los rostros de cada persona. 	

Nota. Información detallada de la H.U.01.

Sprint Backlog. Todas las actividades que se realizan durante el Sprint 01 se detallan en el Sprint Backlog 01 de la Tabla 13, en donde también se considera a la persona encargada de cada actividad, el rango de fechas programado para el Sprint, la estimación en horas para completar cada tarea asignada y el su estado actual de su progreso.

Tabla 13

Sprint Backlog 01

Sprint 1		Fecha Inicio: 02/05/2023		Fecha Fin: 05/05/2023		Jornada: 8 horas	
HU ID	Tareas	Horas	Inicio	Fin	Responsable	Estado	
H.U.01	Grabación de videos de personas en un entorno controlado.	4	02/05/2023	02/05/2023	Steven Lema Alex Robayo	Finalizado	
H.U.01	Construcción del algoritmo destinado a la captura de imágenes y etiquetas para el dataset de rostros.	20	02/05/2023	04/02/2023	Steven Lema Alex Robayo	Finalizado	
H.U.01	Creación de carpetas independientes para imágenes y etiquetas de los rostros y almacenamiento del dataset.	8	05/05/2023	05/05/2023	Steven Lema Alex Robayo	Finalizado	
Total de horas y días:		32 horas	4 días				

Nota. Información detallada del Sprint Backlog 01.

Resultados de la historia de usuario H.U.01. Para la generación del dataset se obtuvo un total de 5 videos que tienen una duración aproximada de 10 a 11 segundos, mediante la utilización de YOLO, de cada video se extraen un total de 300 imágenes de cada persona.

Construcción del algoritmo destinado a la captura de imágenes y etiquetas para el dataset de rostros. Una vez que los videos hayan sido generados, el siguiente paso implica la creación del algoritmo diseñado para la captura de imágenes y etiquetas. Esto se lleva a cabo con el propósito de construir un dataset de rostros. Los detalles específicos de este proceso

están presentados en la Tabla 14, donde se muestra la representación en forma de pseudocódigo de dicho algoritmo.

Tabla 14

Algoritmo para la captura de imágenes y etiquetas para el dataset de rostros

Algoritmo 1: Algoritmo para la captura de imágenes y etiquetas para el dataset de rostros
<pre> # Importar bibliotecas import os import cv2 import numpy as np import imutils # Definir variables personName = 'Alex' classId = '0' trainPath = 'YOLOv8/train' validPath = 'YOLOv8/valid' patch = validPath # Crear carpetas si no existen si no existe trainPath entonces crear carpeta trainPath/images crear carpeta trainPath/labels si no existe validPath entonces crear carpeta validPath crear carpeta validPath/images crear carpeta validPath/labels # Capturar video desde la cámara cap = capturar video desde 'Tests/' + personName + '2_Cam1.mp4' net = cargar red neuronal desde 'YOLOv8/yolov8n-face.onnx' # Función para capturar y procesar frames función capturar(CUDA) contar = 0 si CUDA es verdadero entonces configurar backend preferido de net como DNN_BACKEND_CUDA configurar objetivo preferido de net como DNN_TARGET_CUDA_FP16 sino configurar backend preferido de net como DNN_BACKEND_OPENCV configurar objetivo preferido de net como DNN_TARGET_CPU mientras Verdadero hacer (ret, frame) = leer captura desde cap si no ret entonces romper [alto, ancho, _] = dimensiones de frame </pre>

Algoritmo 1: Algoritmo para la captura de imágenes y etiquetas para el dataset de rostros

```

longitud = máximo de (alto, ancho)
imagen = crear matriz vacía de tamaño longitud x longitud x 3
imagen[0:alto, 0:ancho] = frame
escala = longitud / 640

blob = generar blob de imagen para entrada a la red neuronal
net configurar entrada como blob
outputs = correr red neuronal

# Procesar detecciones y guardar imágenes
para cada salida en outputs hacer
    procesar detección y puntuación
    si puntuación >= 0.25 entonces
        agregar caja y puntuación a listas

cajas_filtradas = aplicar supresión no máxima a cajas y puntuaciones

para cada caja en cajas_filtradas hacer
    redimensionar frame proporcionalmente
    guardar imagen redimensionada en patch + '/images' + '/face_' + personName + '_{}.jpg'.format(contar)
    dibujar caja en frame y guardar coordenadas en archivo
    contar = contar + 1

si tecla presionada es Esc entonces
    romper

redimensionar frame a ancho de 640
mostrar frame en ventana

# Función para dibujar caja y guardar coordenadas
función dibujar_caja_y_guardar_coordenadas(img, x, y, w, h, contar)
    [alto, ancho, _] = dimensiones de img
    archivo = abrir archivo en modo escritura en patch + '/labels' + '/face_' + personName + '_{}.txt'.format(contar)
    escribir coordenadas normalizadas en archivo
    cerrar archivo
    dibujar caja en img
    mostrar nombre en caja

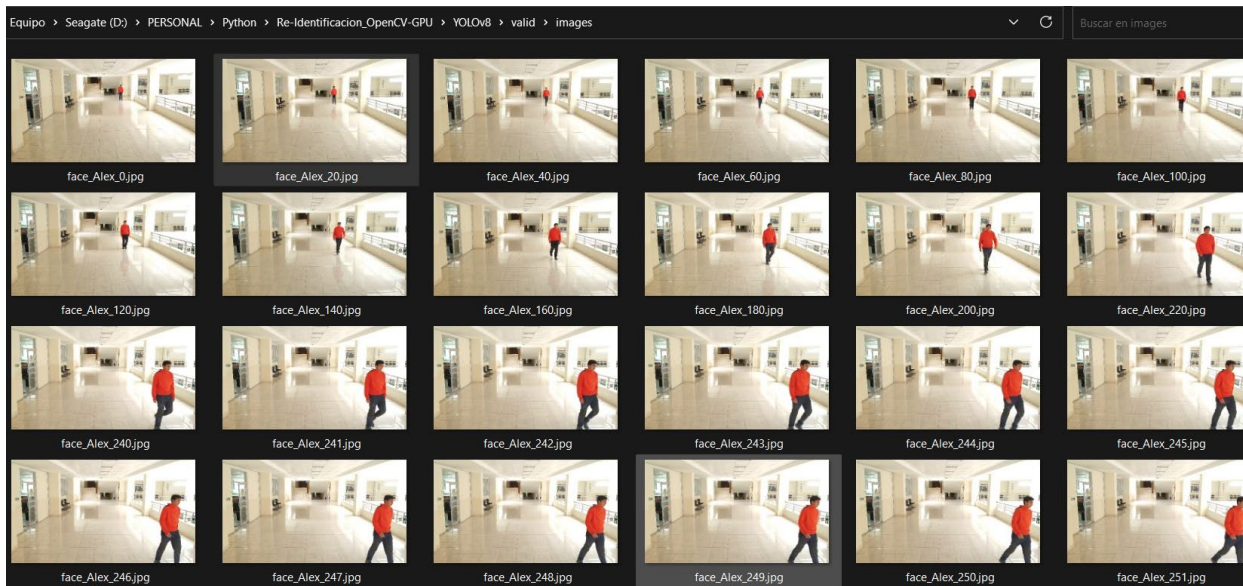
```

Nota. Este pseudocódigo detalla el proceso de captura de imágenes y generación de etiquetas para crear un conjunto de datos de rostros a partir de videos.

A continuación, en la Figura 10 se muestra un ejemplo de las imágenes que son extraídas para el dataset de rostros de la Clase 1: Alex.

Figura 10


Dataset con las imágenes de la Clase 1: Alex para el entrenamiento del modelo de identificación facial



Nota. Imágenes obtenidas de la Clase 1. Alex, se presentan 18 imágenes de un total de 300 que conforman el datasets de la Clase Alex. Las imágenes se presentan cuando está cerca o cuando están lejos.

Figura 11

Carpeta con las etiquetas correspondientes a las imágenes de la Clase 1




Nota. Disposición de archivos etiquetados de la Clase 1.

Las etiquetas de las imágenes se almacenaron en formato YOLO (*.txt), que define la Clase y las coordenadas de los rectángulos de referencia con la estructura siguiente: (c, xn, yn, wn, hn), como se muestra en la Figura 12, donde:

- **c**: representa el número de la Clase.
- **xn**: corresponde al centro normalizado del cuadro delimitador en la dirección x.
- **yn**: indica el centro normalizado del cuadro delimitador en la dirección y.
- **wn**: denota el ancho normalizado del cuadro delimitador en la dirección x.
- **hn**: muestra el alto normalizado del cuadro delimitador en la dirección y.

Figura 12

Formato de etiquetado en YOLO




Nota. En esta imagen se muestra un ejemplo de la información que contiene la etiqueta face_Alex_0.txt, generada por YOLO.

Creación de carpetas independientes para imágenes y etiquetas de los rostros y almacenamiento del dataset. Finalmente, el dataset resultante de rostros se segmenta y se organiza de manera que se crea una carpeta denominada "train", que a su vez contiene dos subcarpetas. Una de estas subcarpetas alberga las imágenes capturadas, mientras que la otra almacena las correspondientes etiquetas como se muestra en la Figura 13.

Figura 13

Distribución de almacenamiento del dataset de rostros



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

Dentro de la historia de usuario H.U.02, se plantea la necesidad de desarrollar un modelo capaz de reconocer la identidad de una persona a través de su rostro. Este cometido se llevará a cabo mediante la implementación de un modelo y/o algoritmo diseñado para ejecutar la identificación facial, haciendo uso de técnicas de Visión por Computadora.

Historias de usuario detalladas. Se procede a explicar de manera detallada la historia de usuario H.U.02, que se refiere a al desarrollo de un modelo y/o algoritmo para la identificación de rostros utilizando técnicas de Visión por Computadora ver Tabla 15, además esta tabla proporciona información de las personas que están a cargo del desarrollo.

Tabla 15

Historia de usuario H.U.02

Historia de Usuario	
Numero: H.U.02	Usuario: Usuario
Nombre historia: Desarrollo un modelo de identificación facial.	Numero Sprint: 01
Prioridad: Alta	Riesgo de desarrollo: Media
Días estimados: 15	Interacción asignada: 1
Desarrolladores responsables: Steven Lema, Alex Robayo	
Descripción: Como usuario quiero un modelo de identificación facial mediante la aplicación de técnicas de Visión por Computadora y algoritmos de Machine Learning.	
Validación:	
<ul style="list-style-type: none"> • Generar un modelo y/o algoritmo que permita reconocer a una persona mediante la identificación facial. • Desarrollar un algoritmo para la identificación de personas a través del rostro. • Realizar pruebas aplicando técnicas LBP y HOG de Visión por Computadora y modelos de SVM, CNN y DNN. • Evaluar al algoritmo de identificación de personas a través del rostro. 	

Nota. Información detallada de la H.U.02.

Sprint Backlog. En este Sprint Backlog se detallan las actividades que se realizarán en la historia de usuario H.U.02 del Sprint 01, en donde también se consideran la persona

encargada de cada actividad, el rango de fechas programado para el Sprint, la estimación en horas para completar cada tarea asignada y el su estado actual de su progreso.

Tabla 16

Sprint Backlog 02

Sprint 1						
Fecha Inicio: 08/05/2023		Fecha Fin: 26/05/2023		Jornada: 8 horas		
HU ID	Tareas	Horas	Inicio	Fin	Responsable	Estado
H.U.02	Elaboración del algoritmo de entrenamiento del modelo mediante el uso del dataset de rostros, utilizando combinaciones posibles LBP y HOG, con los clasificadores SVM, CNN y DNN.	40	08/05/2023	12/05/2023	Steven Lema Alex Robayo	Finalizado
H.U.02	Creación de algoritmos para la identificación de personas a través de reconocimiento facial.	40	15/05/2023	19/05/2023	Steven Lema Alex Robayo	Finalizado
H.U.02	Realización de pruebas al algoritmo de identificación facial.	24	22/05/2023	24/05/2023	Steven Lema Alex Robayo	Finalizado
H.U.02	Evaluación del sistema mediante la matriz de confusión y las métricas de evaluación.	16	25/05/2023	26/05/2023	Steven Lema Alex Robayo	Finalizado
Total de horas y días:		120 horas	15 días			

Nota. Información detallada del Sprint Backlog 02.

Resultados de la historia de usuario H.U.02. El proceso de esta historia de usuario se inicia con la elaboración de un algoritmo destinado a entrenar el modelo, aprovechando el conjunto de datos de rostros. Posteriormente, se desarrolla un algoritmo con el propósito de

reconocer personas a través de la técnica de reconocimiento facial. En la fase de pruebas, se somete este algoritmo a diversos escenarios, explorando las posibles combinaciones de descriptores como LBP y HOG, junto con la implementación de clasificadores como SVM, CNN y DNN. La evaluación del sistema se realiza a través de métricas de rendimiento y la construcción de una matriz de confusión. Estos análisis en conjunto permiten determinar la precisión alcanzada por los clasificadores SVM, DNN y CNN en este contexto.

Elaboración del algoritmo de entrenamiento del modelo mediante el uso del dataset de rostros, utilizando combinaciones posibles LBP y HOG, con los clasificadores SVM, CNN y DNN. En la Tabla 17 se presenta un ejemplo simplificado en pseudocódigo de cómo trabajar con un modelo YOLO para detección de objetos. El pseudocódigo ilustra el proceso de carga y uso de un modelo YOLO, incluyendo la opción de entrenar el modelo desde cero o cargar un modelo preentrenado. Además, se describen las etapas de entrenamiento, evaluación y exportación del modelo en formato “.pt”.

Tabla 17

Pseudocódigo del algoritmo de entrenamiento del modelo de identificación de personas por su rostro

Algoritmo 2: Entrenamiento del modelo de identificación facial utilizando YOLO

Inicio

```
# Cargar un modelo
modelo = YOLO("yolov8n.yaml") # construir un nuevo modelo desde cero
# cargar un modelo preentrenado (recomendado para el entrenamiento)
modelo = YOLO("YOLOv8/yolov8n.pt")

# Usar el modelo
modelo.entrenar(datos="YOLOv8/persons.yaml", epocas=164, tam_img=640) # entrenar el modelo
metricas = modelo.evaluar() # evaluar el rendimiento del modelo en el conjunto de validación
# exportar el modelo en formato ONNX
exito = modelo.exportar(formato="pt", opset=12)
```

Fin

Nota. Proceso de entrenamiento de un modelo utilizando YOLO.

El algoritmo de entrenamiento de YOLO realiza el procesamiento de datos a través de divisiones internas, como se aprecia en la Figura 14, que demuestra cómo YOLO delimita el

rostro de la persona mediante un recuadro y lo relaciona con su Clase, representada numéricamente.

Figura 14

Entrenamiento del modelo de detección facial



Nota. En la imagen se presenta dos imágenes del dataset de la Clase 1: Alex, usadas para el entrenamiento del modelo rostro con YOLO.

Es importante considerar que al entrenar un modelo con YOLO nos ofrece 2 alternativas, la primera es la best.pt que corresponde al modelo mejor entrenado y la last.pt que corresponde a la última iteración de entrenamiento realizado. En este contexto, optaremos por seleccionar el modelo mejor entrenado (best.pt) para llevar a cabo la identificación de rostros de las personas.

Creación de algoritmos para la identificación de personas a través de reconocimiento facial. La Tabla 18 presenta el pseudocódigo detallando el proceso para llevar a cabo la identificación de rostros mediante la utilización de la arquitectura YOLO.

Tabla 18

Pseudocódigo del algoritmo para la identificación de personas por su rostro

Algoritmo 3: Identificación del rostro

```
# Importar bibliotecas
Importar cv2
Importar imutils
Importar os
Importar time
Importar numpy como np
```

Algoritmo 3: Identificación del rostro

```
# Definir las etiquetas de Clase
class_name = []
Abrir y leer el archivo "YOLOv8/classe.txt"
Para cada línea en el archivo leído
    Agregar la línea sin espacios al final a la lista class_name
Fin del ciclo

# Establecer umbrales de confianza
CONFIDENCE_THRESHOLD = 0.2
NMS_THRESHOLD = 0.6

# Abrir el video de entrada
cap = Abrir el video "Tests/Alex2_Cam1.mp4"

# Cargar el modelo YOLOv8
net = Cargar el modelo YOLOv8 desde el archivo 'YOLOv8/persons.onnx'

# Definir función para dibujar el cuadro delimitador
Función draw_bounding_box(img, class_id, confidence, x, y, x_plus_w, y_plus_h)
    label = "Nombre de Clase" + " (" + confidence formateado a 2 decimales + ")"
    Dibujar un rectángulo en la imagen 'img' desde (x, y) hasta (x_plus_w, y_plus_h) con un color rojo (0, 0, 255) y grosor de línea 3
    Dibujar el texto 'label' en la imagen 'img' en la posición (x - 10, y - 10) con una fuente y un tamaño específicos, color verde (0, 255, 0) y grosor de línea 3
Fin de la función

# Definir función para procesar el video y mostrar la salida
Función Salida(CUDA)
    Iniciar el temporizador 'init'

    Si CUDA es Verdadero
        Establecer el backend preferido del modelo a 'cv2.dnn.DNN_BACKEND_CUDA'
        Establecer el objetivo preferido del modelo a 'cv2.dnn.DNN_TARGET_CUDA_FP16'
    Sino
        Establecer el backend preferido del modelo a 'cv2.dnn.DNN_BACKEND_OPENCV'
        Establecer el objetivo preferido del modelo a 'cv2.dnn.DNN_TARGET_CPU'
    Fin Si

    Mientras verdadero (bucle infinito)
        Leer un fotograma del video en 'grabbed' y 'frame'

        Si no se pudo leer un fotograma ('grabbed' es falso)
            Romper el bucle
        Fin Si

        Iniciar el temporizador 'start'

        Obtener las dimensiones del fotograma 'height' y 'width'
        Calcular la longitud máxima entre 'height' y 'width' y almacenarla en 'length'
        Crear una imagen en negro 'image' con dimensiones (length, length, 3)
        Copiar el fotograma original en la parte superior izquierda de 'image'
        Calcular el factor de escala 'scale' como la relación entre 'length' y 640
```

Algoritmo 3: Identificación del rostro

Crear un blob de entrada para el modelo a partir de 'image' con dimensiones (640, 640) y normalización 1/255

Configurar la entrada del modelo con el blob
Ejecutar la red neuronal y obtener los resultados en 'outputs'

Transponer los resultados 'outputs' y almacenarlos en 'outputs'

Obtener el número de filas 'rows' en 'outputs'

Inicializar listas para almacenar las cajas, puntuaciones y IDs de Clase detectadas

Para cada fila 'i' en 'rows'

 Obtener las puntuaciones de las Clases en 'classes_scores' para la fila 'i'

 Encontrar el puntaje máximo 'maxScore' y su índice 'maxClassIndex' en 'classes_scores'

 Si 'maxScore' es mayor o igual que 0.1

 Calcular las coordenadas de la caja 'box' a partir de los valores en 'outputs'

 Agregar 'box', 'maxScore' y 'maxClassIndex' a las listas correspondientes

 Fin Si

Fin Para

Aplicar el algoritmo Non-Maximum Suppression (NMS) para eliminar detecciones superpuestas y obtener índices de detecciones seleccionadas en 'result_boxes'

Inicializar una lista 'detections' para almacenar los detalles de las detecciones seleccionadas

Para cada índice 'index' en 'result_boxes'

 Obtener la caja 'box' correspondiente a 'index'

 Crear un diccionario 'detection' con 'class_id', 'class_name', 'confidence', 'box' y 'scale'

 Agregar 'detection' a la lista 'detections'

 Dibujar el cuadro delimitador en el fotograma original usando la función 'draw_bounding_box'

Fin Para

Mostrar el fotograma con los cuadros delimitadores y la etiqueta FPS

Si se presiona la tecla Esc (27) durante la ejecución

 Romper el bucle

Fin Si

Finalizar el temporizador 'end'

Redimensionar el fotograma para que tenga un ancho de 640 píxeles usando 'imutils.resize'

Calcular el FPS y mostrarlo en el fotograma

Si CUDA es Verdadero

 Mostrar el fotograma con el título "CAPTURA GPU"

Sino

 Mostrar el fotograma con el título "CAPTURA CPU"

Fin Si

Fin Mientras

Fin de la función

Llamar a la función Salida con el argumento 'CUDA' para procesar el video y mostrar la salida
Salida(CUDA)

Nota. Pseudocódigo del algoritmo para la identificación de una persona mediante el rostro, en donde se detallan los pasos realizados para su creación.

El siguiente paso es usar el modelo para identificar a una persona usando el video captado por la cámara 1. Para realizar esta detección, la persona pasará por el primer recorrido como se evidencia en la Figura 15, en donde el rostro de la persona se enmarca en un recuadro de color con su nombre respectivo.

Figura 15

Persona identificada por el rostro, con su nombre correspondiente

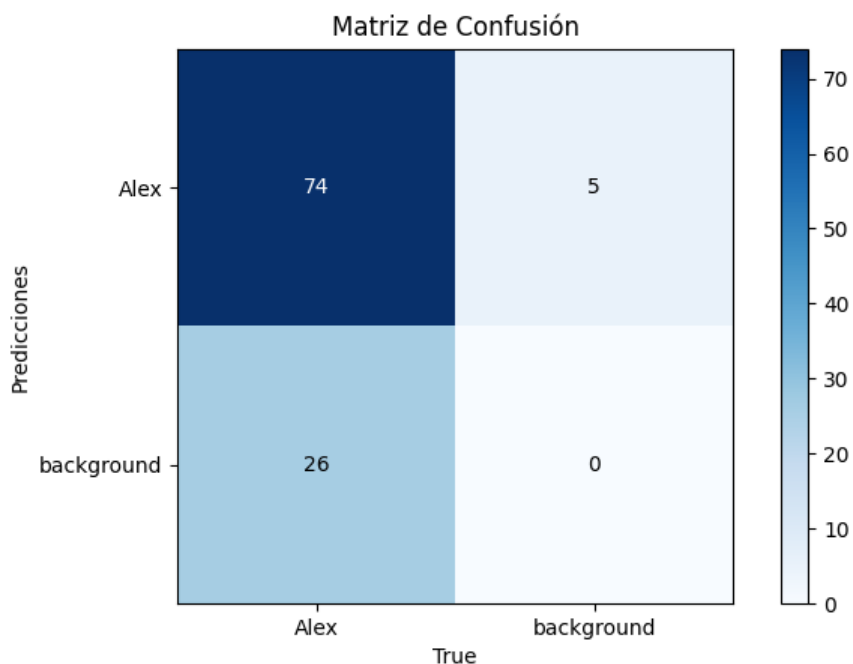


Nota. Imagen de la identificación del rostro de la Clase 1 donde se indica que su nombre es Alex.

Durante el proceso de entrenamiento del modelo mediante YOLO, se generan diversas gráficas, destacándose entre ellas la matriz de confusión, la cual está representada en la Figura 16.

Figura 16

Matriz de confusión generada al entrenar el modelo de reconocimiento facial con la arquitectura YOLO



Nota. Matriz de confusión del entrenamiento con YOLO para la detección por medio el rostro.

Realización de pruebas al algoritmo de identificación facial. Las pruebas realizadas han culminado en la creación de la Tabla 19 que se enfoca en la Identificación Facial de la Clase 1, que corresponde a "Alex". A lo largo de estas pruebas, se utilizaron dos tipos de tipos de descriptores: LBP y HoG. Además, se aplicaron tres clasificadores distintos: SVM, DNN y CNN. La tabla de la matriz de confusión recoge los resultados de estas pruebas. Con cada coincidencia de predicción e identificación, ofrece una visión detallada del rendimiento de cada descriptor y clasificador en la tarea. Esta matriz nos permite examinar en profundidad la eficacia y precisión de los distintos enfoques empleados en la identificación facial, especialmente en lo que respecta a la Clase 1, en la que buscábamos identificar a "Alex".

Tabla 19

Matriz de confusión de la Identificación facial de la Clase 1: Alex

Descriptor		Identificación Facial										
		LBP			HOG							
Clasificador	SVM	DNN	CNN	SVM	DNN	CNN						
	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos					
Positivos	155	4	182	0	174	3	124	28	146	6	139	10
Negativos	2	5	0	0	0	0	1	4	0	2	1	3

Nota. Valores obtenidos de la matriz de confusión de la detección mediante el reconocimiento facial de la Clase 1: Alex, utilizando los descriptores LBP y HoG y los clasificadores SVM, DNN y CNN.

Evaluación del sistema mediante la matriz de confusión y las métricas de evaluación. Una vez que las pruebas se han realizado, se procede a exponer los resultados obtenidos en base a la información recopilada, resultante de la aplicación del algoritmo de identificación facial. Para ello, se toman en cuenta las métricas explicadas en el apartado de métricas de evaluación. Además, los resultados incluyen la exactitud de las predicciones, para personas conocidas.

Tal como se puede apreciar en la Tabla 20, los resultados obtenidos de la matriz de confusión presentan variaciones de los datos totales según el clasificador utilizado, debido a que el recuento de detecciones difiere entre los diferentes clasificadores.

Tabla 20

Aplicación de métricas a los resultados obtenidos de la combinación de LBP y HoG con los clasificadores SVM, DNN y CNN

Métricas	LBP			HoG		
	SVM	DNN	CNN	SVM	DNN	CNN
Accuracy	0.96	1.00	0.98	0.82	0.95	0.92
Recall	0.99	1.00	1.00	0.99	0.99	0.98
Precisión	0.97	1.00	0.98	0.82	0.96	0.93

Nota. Valores obtenidos al aplicar la métrica a la detección facial de la Clase 1 usando las diferentes combinaciones de LBP y HoG con los clasificadores SVM, DNN y CNN.

En la Tabla 19 se muestran los valores obtenidos de la matriz de confusión utilizando las diferentes combinaciones de descriptores LBP y HoG y clasificadores SVM, DNN y CNN. Con estos valores se obtienen las métricas Exactitud (Accuracy), Recuperación (Recall) y Precisión (Precision) las mismas que se presentan en la Tabla 20. Con la combinación LBP y DNN se obtienen los mejores resultados, en todas las métricas (Accuracy, Recall y Precisión), dando el valor de 1.00.

Nota. Finalizado el Sprint, los objetivos se cumplieron correctamente.

Sprint 02: Obtención de dataset de silueta corporal, textura y color de la ropa e implementación de algoritmos para el Re-Identificación de personas utilizando características soft-biométricas (silueta corporal, la textura y el color de la ropa).

Para la ejecución del Sprint 02 se tomó en cuenta las historias de usuario H.U.03 y H.U.04, en donde el objetivo es obtener datasets de la silueta corporal, la textura y color de la ropa de una persona, que es captada por la cámara 1, usando los descriptores LBP y HoG, y los clasificadores SVM, CNN, DNN para Re-Identificar a un individuo mediante la cámara 2.

H.U.03: Creación de datasets de silueta corporal, textura y color de la ropa

La historia de usuario para la creación de datasets con características soft-biométricas: silueta corporal, textura y color de la ropa, se especifica de manera detallada en la Tabla 21,

donde se encuentran designados los responsables del proyecto y los criterios de aceptación para la generación de los datasets.

Tabla 21

Historia de usuario H.U.03

Historia de Usuario	
Numero: H.U.03	Usuario: Usuario
Nombre historia: Creación del dataset con imágenes de la silueta corporal, de la textura y color de la ropa de una persona	Numero Sprint: 02
Prioridad: Alta	Riesgo de desarrollo: Media
Días estimados: 15	Interacción asignada: 1
Desarrolladores responsables: Steven Lema, Alex Robayo	
Descripción: Como usuario solicito tener un dataset que contenga imágenes de las características soft-biométricas silueta corporal, de la textura y color de la vestimenta de una persona.	
Validación:	
<ul style="list-style-type: none"> • Generar videos de personas de espaldas caminando en un entorno controlado del Campus de la Universidad • Extraer datos e imágenes de la silueta corporal, color y textura de la ropa de una persona. • Almacenar las imágenes y datos de las características soft-biométricas en una carpeta por persona. 	

Nota. Información detallada de la H.U.03

Sprint Backlog. En la Tabla 22, se puede observar el Sprint Backlog 03, que corresponde a las tareas que se realizarán según lo especificado en la historia de usuario H.U.03 del Sprint 2, donde se detalla la persona encargada de cada actividad, el rango de fechas programado para el Sprint, la estimación en horas para completar cada tarea asignada y su estado actual de progreso.

Tabla 22

Sprint Backlog 03

Sprint 2	Fecha Inicio: 29/05/2023	Fecha Fin: 16/06/2023		Jornada: 8 horas		
HU ID	Tareas	Horas	Inicio	Fin	Responsable	Estado
H.U.03	Grabación de videos con varias	8	29/05/2023	29/05/2023	Steven Lema Alex Robayo	Finalizado

Sprint 2		Fecha Inicio: 29/05/2023	Fecha Fin: 16/06/2023	Jornada: 8 horas		
HU ID	Tareas	Horas	Inicio	Fin	Responsable	Estado
	personas de espaldas caminando en un entorno controlado.					
H.U.03	Codificación del algoritmo para extracción de características soft-biométricas.	96	30/05/2023	14/06/2023	Steven Lema Alex Robayo	Finalizado
H.U.03	Creación de carpetas independientes por personas y almacenamiento del dataset.	16	15/06/2023	16/06/2023	Steven Lema Alex Robayo	Finalizado
Total de horas y días:		120 horas	15 días			

Nota. Información detallada del Sprint Backlog 03.

Resultados de la historia de usuario H.U.03. El objetivo principal de la historia de usuario H.U.03 es extraer características soft-biométricas de la silueta corporal, textura y color de la ropa, para lo cual se obtuvo 5 videos personas diferentes, de cada uno se extrajo 300 imágenes de las características soft-biométricas.

Codificación del algoritmo para extracción de características soft-biométricas. En la Tabla 23 se muestra el seudocódigo diseñado para llevar a cabo la extracción de características soft-biométricas. A través de este seudocódigo, se establece un proceso detallado y paso a paso para capturar estas características específicas.

Tabla 23

Pseudocódigo del algoritmo para la extracción de características soft-biométricas

Algoritmo 4: Extracción de características soft-biométricas

```
# Paso 1: Cargar la imagen
imagen = cargar_imagen("ruta_de_la_imagen.jpg")
```

```
# Paso 2: Extraer la silueta corporal
```

Algoritmo 4: Extracción de características soft-biométricas

```
silueta = extraer_silueta(imagen)
```

```
# Paso 3: Extraer características de textura
```

```
caracteristicas_textura = extraer_caracteristicas_textura(imagen)
```

```
# Paso 4: Extraer características de color de la ropa
```

```
caracteristicas_color = extraer_caracteristicas_color(imagen)
```

```
# Paso 5: Almacenar las características extraídas en una estructura de datos
```

```
caracteristicas = {
```

```
    "silueta": silueta,
```

```
    "textura": caracteristicas_textura,
```

```
    "color": caracteristicas_color
```

```
}
```

```
# Paso 6: Utilizar las características para identificación o reidentificación
```

```
identificar_persona(caracteristicas)
```

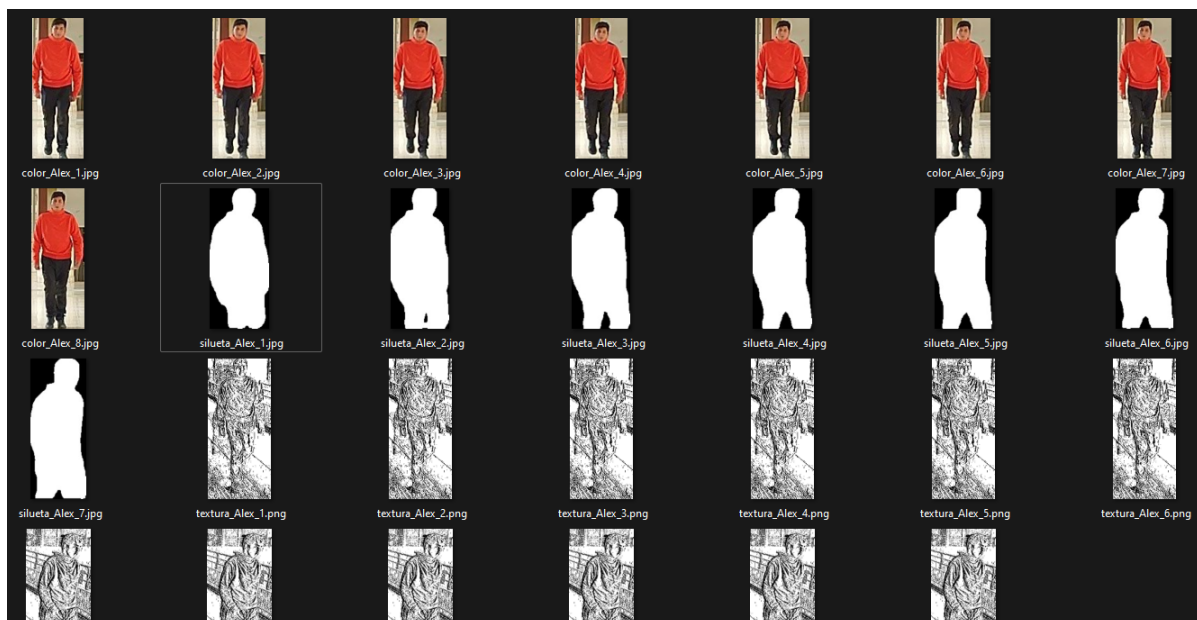
Nota. Pseudocódigo del algoritmo para la extracción de características soft-biométricas silueta corporal, textura y color de la ropa en donde se detallan los pasos realizados para su creación

Creación de carpetas independientes por personas y almacenamiento del dataset.

El algoritmo realiza la extracción de imágenes que contienen la silueta corporal, así como detalles de la textura y el color de la ropa de una persona. Estas imágenes se capturan y posteriormente son almacenadas en una carpeta específica. Se puede observar el dataset generado en la Figura 17 que se presenta a continuación.

Figura 17

Dataset con las imágenes de silueta, textura y color de la Clase 1: Alex



Nota. Con las imágenes obtenidas del dataset se extraen las características soft-biométricas de silueta corporal, textura y color de la ropa de la Clase 1: Alex. Los nombres de las imágenes tienen la estructura de característica_clase_NN.png. En donde, característica indica el tipo de característica procesada, clase se refiere al nombre de la clase y NN al número de imagen.

Estas imágenes son guardadas en una carpeta que lleva el nombre de su Clase correspondiente. En esta situación particular, la Clase 1 está asignada a la etiqueta "Alex".

H.U.04: Implementación de modelos capaces de Re-identificar personas al combinar características soft-biométricas: silueta corporal, textura y color de la ropa

En esta historia de usuario se especifica la necesidad de crear un sistema que permita la Re-Identificar personas, en base a sus características soft-biométricas con el uso de cámaras no solapadas.

Historias de usuario detalladas. La Tabla 24 corresponde a la historia de usuario H.U.04 del Sprint 02, la cual tiene como objetivo principal la creación de modelos de Re-ID de

personas con el uso de las características soft-biométricas: silueta corporal, textura y color de la ropa, que son extraídas de una persona al ser captada en video de la cámara 1.

Tabla 24

Historia de usuario H.U.04

Historia de Usuario	
Numero: H.U.04	Usuario: Usuario
Nombre historia:	
Implementación modelos capaces de Re-identificar personas al combinar características soft-biométricas	Numero Sprint: 02
Prioridad: Alta	Riesgo de desarrollo: Media
Días estimados: 20	Interacción asignada: 1
Desarrolladores responsables: Steven Lema, Alex Robayo	
Descripción: como usuario quiero desarrollar modelos capaces de Re-identificar personas al combinar características soft-biométricas como la silueta corporal, la textura y color de la ropa.	
Validación:	
<ul style="list-style-type: none"> • Generar un modelo y/o algoritmo que permita reconocer a una persona mediante sus características soft-biométricas. • Desarrollar un algoritmo para la Re-Identificación de personas por medio de su silueta corporal, textura y color de la ropa. • Realizar pruebas aplicando técnicas LBP y HOG de Visión por Computadora y modelos de SVM, CNN y DNN. • Evaluar al algoritmo de Re-Identificación de personas que utiliza la silueta corporal, textura y color de la ropa. 	

Nota. Información detallada de la H.U.04.

Sprint Backlog. En la Tabla 25, se puede observar el Sprint Backlog 04, correspondiente a las tareas que se van a realizar conforme a lo especificado en la historia de usuario H.U.04 del Sprint 02, detallando la persona a cargo de cada actividad, el rango de fechas programado para el Sprint, la estimación en horas para completar cada tarea asignada y el estado actual de su progreso.

Tabla 25

Sprint Backlog 04

Sprint 2		Fecha Inicio: 19/06/2023		Fecha Fin: 14/07/2023		Jornada: 8 horas	
HU ID	Tareas	Horas	Inicio	Fin	Responsable	Estado	
H.U.04	Elaboración de algoritmos de entrenamiento de modelos mediante el uso del dataset de silueta corporal, textura y color de la ropa, utilizando combinaciones posibles LBP y HOG, con los clasificadores SVM, CNN y DNN	40	19/06/2023	23/06/2023	Steven Lema Alex Robayo	Finalizado	
H.U.04	Creación del algoritmo para la Re-Identificación de personas por medio de su silueta corporal, textura y color de la ropa.	40	26/06/2023	30/06/2023	Steven Lema Alex Robayo	Finalizado	
H.U.04	Realización de pruebas al algoritmo de Re-Identificación.	40	03/07/2023	07/07/2023	Steven Lema Alex Robayo	Finalizado	
H.U.04	Evaluación del sistema mediante la matriz de confusión y las métricas de evaluación.	40	10/07/2023	14/07/2023	Steven Lema Alex Robayo	Finalizado	
Total de horas y días:		160 horas	20 días				

Nota. Información detallada del Sprint Backlog 04.

Resultados de la historia de usuario H.U.04. Esta historia de usuario inicia el proceso con la creación de un algoritmo destinado a entrenar el modelo utilizando un conjunto de datos

que abarca la silueta corporal, textura y color de la ropa. Posteriormente, se desarrolla un algoritmo específico para llevar a cabo la Re-Identificación de individuos a través de características como la silueta corporal, textura y color de la ropa. En el proceso de pruebas, se somete este algoritmo de Re-Identificación a una serie de escenarios variados, explorando las posibles combinaciones de descriptores como LBP y HOG, en conjunto con la implementación de clasificadores como SVM, CNN y DNN. La evaluación del sistema se lleva a cabo a través de métricas de rendimiento y la construcción de una matriz de confusión, proporcionando una visión detallada de la precisión alcanzada por los clasificadores SVM, DNN y CNN en el contexto de la Re-Identificación basada en características de silueta corporal, textura y color de la ropa.

Elaboración de algoritmos de entrenamiento de modelos mediante el uso del dataset de silueta corporal, textura y color de la ropa, utilizando combinaciones posibles LBP y HOG, con los clasificadores SVM, CNN y DNN. Una vez recopilado un conjunto de datos de imágenes, el siguiente paso importante es entrenar un modelo de Re-Identificación de personas. El modelo está diseñado para identificar y distinguir con precisión entre personas en distintos lugares y momentos basándose en características visuales únicas como la silueta, la textura y el color de la ropa. El método de entrenamiento sigue una estrategia apoyada en un pseudocódigo que se muestra en la Tabla 26 que establece un enfoque claro.

Tabla 26

Pseudocódigo para el entrenamiento del modelo de Re-Identificación de personas

Algoritmo 5: Pseudocódigo para el entrenamiento del modelo de Re-Identificación de personas

Paso 1: Recopilación y preparación de datos

def cargar_datos_entrenamiento():

 # Cargar datos de siluetas corporales, texturas y colores de ropa con etiquetas de identidad

 # Dividir los datos en conjuntos de entrenamiento, validación y prueba

 return datos_entrenamiento, datos_validacion, datos_prueba

Paso 2: Diseño de la arquitectura del modelo

def construir_modelo():

 # Crear una arquitectura de red neuronal convolucional (CNN) que acepte siluetas, texturas y colores de ropa

Algoritmo 5: Pseudocódigo para el entrenamiento del modelo de Re-Identificación de personas

```

# Extraer características compartidas de las tres modalidades y fusionarlas
# Agregar capas de clasificación para predecir la identidad de la persona
return modelo

# Paso 3: Definir funciones de pérdida y optimizador
def definir_funcion_de_perdida_y_optimizador():
    # Utilizar una función de pérdida apropiada para el problema de re-identificación (por ejemplo, la pérdida de tripletas)
    # Seleccionar un optimizador, como el optimizador Adam
    return funcion_de_perdida, optimizador

# Paso 4: Ciclo de entrenamiento
def entrenar_modelo(modelo, datos_entrenamiento, datos_validacion, funcion_de_perdida, optimizador):
    para cada época de entrenamiento:
        for batch en datos_entrenamiento:
            # Obtener lotes de siluetas, texturas y colores de ropa junto con las etiquetas de identidad
            # Calcular las salidas del modelo
            # Calcular la pérdida usando la función de pérdida y las salidas del modelo
            # Realizar retropropagación y actualizar los pesos del modelo usando el optimizador

        # Evaluar el modelo en los datos de validación para hacer un seguimiento del rendimiento

# Paso 5: Evaluación del modelo
def evaluar_modelo(modelo, datos_prueba):
    # Para cada muestra en datos_prueba:
    # Obtener las características de siluetas, texturas y colores de ropa
    # Calcular las salidas del modelo
    # Comparar las salidas con las identidades reales y medir la precisión de la re-identificación

# Paso 6: Uso del modelo entrenado
def reidentificar_persona(modelo, nueva_persona):
    # Obtener las características de silueta, textura y color de ropa de la nueva persona
    # Calcular las salidas del modelo
    # Comparar las salidas con las características de las personas en el conjunto de entrenamiento
    # Identificar a la persona con la característica más similar

# Paso 7: Ejecutar el proceso
datos_entrenamiento, datos_validacion, datos_prueba = cargar_datos_entrenamiento()
modelo = construir_modelo()
funcion_de_perdida, optimizador = definir_funcion_de_perdida_y_optimizador()
entrenar_modelo(modelo, datos_entrenamiento, datos_validacion, funcion_de_perdida, optimizador)
evaluar_modelo(modelo, datos_prueba)

```

Nota. Este pseudocódigo es una representación conceptual simplificada del proceso de entrenamiento de un modelo de Re-Identificación de personas basado en siluetas corporales, texturas y colores de ropa.

El pseudocódigo presentado en la Tabla 26 proporciona una descripción simplificada y general del proceso de entrenamiento de un modelo utilizando datos de silueta corporal, textura

y color de la ropa. La implementación real requerirá el uso de bibliotecas específicas de programación y ajustes detallados según las herramientas y lenguajes seleccionados. Además, se recomienda realizar una validación y ajustes adicionales en la arquitectura y los hiperparámetros del modelo para lograr resultados óptimos en escenarios reales.

Creación del algoritmo para la Re-Identificación de personas por medio de su silueta corporal, textura y color de la ropa. La Tabla 27 muestra al pseudocódigo del algoritmo para la Re-Identificación de una persona mediante sus características soft-biométricas, en donde se detallan los pasos realizados para su creación también se colocó una condición para que el sistema realice la detección cada 2 frames, de manera que no se sobrecargue el procesador, ya que no existe mucha diferencia de un frame al otro.

Tabla 27

Pseudocódigo del algoritmo para la Re-Identificación de personas

Algoritmo 3: Re-Identificación de personas

```
# Importar bibliotecas
Importar cv2
Importar imutils
Importar time
Importar threading desde Thread
Importar multiprocessing
Importar Process desde multiprocessing
Importar YOLOv8Seg, YOLOv8 desde YOLOv8
Importar draw_detections desde YOLOv8.utils

# Seleccionar el dispositivo con el que se va a ejecutar (cuda o cpu)
device = "cuda"

# Inicializar el modelo YOLOv8
model_path_persons = "models/personsv2.onnx"
model_path_siluite_persons = "models/siluite_persons.onnx"
yolov8_detector_siluite = Inicializar YOLOv8Seg con (model_path_siluite_persons, device, 0.3, 0.3)
yolov8_detector_texture = Inicializar YOLOv8Seg con (model_path_persons, device, 0.3, 0.3)
yolov8_detector_color = Inicializar YOLOv8 con (model_path_persons, device, 0.3, 0.5)

# Inicializar vídeo
cap = cv2.VideoCapture(0)
cap = Inicializar la captura de vídeo desde la cámara o archivo ("Tests/Alex2_Cam2.mp4")
print(cap.get(cv2.CAP_PROP_FPS))

Si __name__ == "__main__":
    Multiprocessing.set_start_method("spawn")
```

Algoritmo 3: Re-Identificación de personas

```

processes = Inicializar lista de procesos vacía
frames = Inicializar lista de cuadros vacía
class_ids_face = Inicializar lista de IDs de Clase de rostros vacía

Mientras verdadero (bucle infinito)
    start = Iniciar temporizador

    Leer un fotograma del vídeo en 'grabbed' y 'frame'
    Si no se pudo leer un fotograma (si 'grabbed' es falso)
        Romper el bucle
    Fin Si

    Si se presiona la tecla "q", romper el bucle
    Fin Si

    Calcular el nuevo tamaño del fotograma en base a un porcentaje de escala del tamaño original
    Redimensionar el fotograma con el nuevo tamaño usando 'cv2.resize'

    Agregar el fotograma redimensionado a la lista 'frames'

    Si la longitud de la lista 'frames' es igual a 2
        Ejecutar YOLOv8Seg en los fotogramas de la lista 'frames' y obtener las cajas, puntuaciones y IDs de
        Clase de rostros detectados
        Ejecutar YOLOv8Seg en los fotogramas de la lista 'frames' y obtener las cajas, puntuaciones y IDs de
        Clase de texturas de personas detectadas
        Ejecutar YOLOv8 en los fotogramas de la lista 'frames' y obtener las cajas, puntuaciones y IDs de
        Clase de personas detectadas
        Borrar la lista 'frames'
    Fin Si

    Si la lista 'class_ids_face' no está vacía
        Dibujar los cuadros delimitadores en el fotograma usando la función 'draw_detections'
        Incrementar el contador 'cont'
    Fin Si

    Redimensionar el fotograma para que tenga un ancho de 720 píxeles usando 'imutils.resize'
    Calcular el FPS y mostrarlo en el fotograma usando 'cv2.putText'

    Mostrar el fotograma en una ventana con título "CAPTUR A GPU" si el dispositivo es "cuda", o en una
    ventana con título "CAPTUR A CPU" si el dispositivo es "cpu"

    Fin Mientras
    fin = Detener temporizador
    final = fin - init
    Mostrar el tiempo de ejecución en segundos y formateado a 2 decimales
    Mostrar el valor del contador 'cont'

Fin Si


```

Nota. El pseudocódigo describe un algoritmo de Re-Identificación basado en características soft-biométricas.

Al implementar el algoritmo de Re-Identificación en una persona, se emplea un video registrado por la cámara 2, como se ilustra en la Figura 18. En esta representación gráfica, la persona en cuestión es resaltada con un recuadro de color que enmarca su figura, y adicionalmente, se muestra el nombre correspondiente a su Clase.

Figura 18

Persona Re-Identificada por las características soft-biométricas con su respectivo nombre de la clase.



Nota. Imagen de una persona que se encuentra de espaldas Re-Identificada mediante sus características soft-biométricas indicando que es Alex con un 84% de precisión.

Realización de pruebas al algoritmo de Re-Identificación. Las pruebas realizadas han culminado en la creación de la Tabla 28 que se enfoca en la Re-Identificación de la Clase 1, que corresponde a "Alex". A lo largo de estas pruebas, se utilizaron dos tipos de tipos de descriptores: LBP y HoG. Además, se aplicaron tres clasificadores distintos: SVM, DNN y CNN. La tabla de la matriz de confusión recoge los resultados de estas pruebas. Con cada coincidencia de predicción e identificación, ofrece una visión detallada del rendimiento de cada descriptor y clasificador en la tarea. Esta matriz nos permite examinar en profundidad la

eficacia y precisión de los distintos enfoques empleados en la Re-Identificación de personas utilizando características soft-biométricas (silueta corporal, textura y color de la ropa), especialmente en lo que respecta a la Clase 1, en la que buscábamos identificar a "Alex".

Tabla 28

Datos de las matrices de confusión de la Re-Identificación de la Clase 1 mediante la silueta corporal, textura y color de la ropa

Descriptor	Re-Identificación Silueta				Re-Identificación Textura						Re-Identificación Color									
	LBP				LBP			HOG			LBP			HOG						
	DNN		CNN		DNN	CNN	SVM	DNN	CNN	DNN	CNN	SVM	DNN	CNN	DNN	CNN				
Clasificador	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos				
Positivos	13	29	11	21	89	1	87	4	75	12	127	4	103	10	73	23	83	12	80	26
Negativos	8	9	15	17	0	1	2	1	3	7	0	2	0	3	13	5	4	10	9	12

Nota. Valores obtenidos para las matrices de confusión de la Clase 1 mediante el uso de las características soft-biométricas silueta corporal, textura y color de la ropa usando las combinaciones de LBP y HoG con los clasificadores SVM, DNN y CNN.

Evaluación del sistema mediante la matriz de confusión y las métricas de evaluación. El análisis de la Tabla 29 muestra que los resultados obtenidos a partir de la matriz de confusión varían notablemente en función del descriptor de características soft-biométricas empleado y del clasificador utilizado. Este fenómeno se debe a las diferencias en el número de detecciones que se producen entre los distintos clasificadores.

Tabla 29

Aplicación de métricas a los resultados obtenidos de la combinación de LBP y HoG

Características soft-biométricas	Silueta Corporal		Textura de la Ropa				Color de la Ropa			
	LBP		LBP		HoG		LBP	HoG		
	Métricas	DNN	CNN	DNN	CNN	SVM	DNN	CNN	SVM	DNN
Accuracy	0.37	0.44	0.99	0.94	0.85	0.95	0.91	0.68	0.85	0.72
Recall	0.62	0.42	1.00	0.98	0.96	0.98	1.00	0.85	0.95	0.90
Precisión	0.31	0.34	0.99	0.96	0.86	0.97	0.91	0.76	0.87	0.75

Nota. Valores obtenidos al aplicar la métrica a la Re-Identificación de personas mediante la silueta corporal, textura y color de la ropa de la Clase 1 usando las diferentes combinaciones de LBP y HoG con los clasificadores SVM, DNN y CNN.

En la Tabla 28 se muestran los valores de la matriz de confusión utilizado en las diferentes combinaciones de LBP con DNN y CNN, basadas en la información previa, los valores de Accuracy, Presicion y Recall se presentan en la Tabla 29. Entre todas las combinaciones evaluadas para la Re-Identificación de personas mediante el uso de la silueta corporal, la utilización de LBP junto con CNN, arroja los mejores valores de exactitud, recuperación y precisión son de 0.44, 0.42 y 0.34 respectivamente, por otro lado, entre todas las configuraciones exploradas para la Re-Identificación de personas mediante el análisis de la textura de su ropa, la más destacada corresponde al uso de LBP junto con DNN, cuyos valores de exactitud, recuperación y precisión alcanzan 0.99, 1.00 y 0.99 respectivamente y en última instancia entre todas las configuraciones exploradas para la Re-Identificación de personas mediante el uso del color de la ropa es la que involucra la utilización de HoG junto con DNN, en este caso, los valores de exactitud, recuperación y precisión son de 0.85, 0.95 y 0.87 respectivamente.

Una vez realizadas la comparativas se procede con la unión de los mejores descriptores para Re-Identificar a una persona a través de sus características combinadas, en el caso de la

silueta el mejor descriptor de silueta fue LBP, en cuanto a las características de la textura y el color de la ropa el mejor descripto fue HoG.

Tabla 30

Re-Identificación de la Clase 1: Alex a través de la combinación de su silueta corporal, textura y color de la ropa

Re-Identificación de las personas a través de su silueta corporal, textura y color de la ropa (Combinación de características)			
Característica	Silueta LBP Textura HoG Color HoG	Silueta LBP Textura HoG Color HoG	Silueta LBP Textura HoG Color HoG
Descriptor	SVM	CNN	DNN
Precisión	0,59	0,76	0,79

Nota. Combinación de las características soft-biométricas silueta corporal, textura y color de la ropa aplicado a la Clase 1: Alex.

En la Tabla 30 se muestra la Precisión del sistema de Re-ID al utilizar las 3 características soft-biométricas silueta corporal (LBP), textura y color de la ropa (HoG) de forma conjunta aplicada a la Clase 1: Alex. Los resultados revelan que, al aplicar SVM, se obtiene una precisión de 0.59; mientras que mediante CNN se alcanza un valor de 0.76, y con DNN se logra el nivel más alto de precisión, con 0.79.

Nota. Finalizado el Sprint los objetivos se cumplieron correctamente.

Sprint 03: Comparación del procesamiento de CPU y GPU, en el modelo combinado de características soft-biométricas (silueta corporal, textura y color de la ropa) con sus distintos clasificadores.

El Sprint 03 está basado únicamente en el cumplimiento de objetivos planteados por la historia de usuario H.U.05, en donde se indica que se requiere realizar pruebas comparativas de los algoritmos utilizados para la Re-Identificación, en un entorno de ejecución que utilice tanto CPU como GPU, los datos que se desea registrar son los tiempos de ejecución, precisión

y rendimientos, de tal manera que se pueda analizar el impacto que genera el hardware en los algoritmos desarrollados.

H.U.05: Comparación de rendimientos del sistema de Re-Identificación de personas mediante el uso de arquitecturas de altas prestaciones

La presente historia de usuario se crea bajo la necesidad de realizar pruebas de los algoritmos de Re-ID de personas, en diferentes entornos de ejecución como son las CPUs y GPUs. En la Tabla 31, se explica de una manera detallada la historia de usuario H.U.05 correspondiente al Sprint 3.

Tabla 31

Historia de Usuario H.U.05

Historia de Usuario	
Numero: H.U.05	Usuario: Usuario
Nombre historia: Comparación de rendimientos de la CPU y GPU en el procesamiento del modelo combinado de características.	Numero Sprint: 03
Prioridad: Alta	Riesgo de desarrollo: Media
Días estimados: 20	Interacción asignada: 1
Desarrolladores responsables: Steven Lema, Alex Robayo	
Descripción: Como usuario necesito validar los resultados de los modelos de Re-Identificación de personas y realizar una comparación del rendimiento del uso de procesadores (CPU y GPU).	
Validación:	
<ul style="list-style-type: none"> • Medir el tiempo empleado en el entrenamiento de modelos de identificación por el rostro y Re-Identificación de personas. • Comparar los porcentajes de utilización de CPUs vs GPUs. • Comparar los porcentajes de utilización de CPU y GPU según el tipo de uso dentro del sistema de Re-Identificación de personas. • Aplicar métricas para medir la eficiencia del sistema de Re-Identificación de personas usando el modelo combinado y el mejor clasificador. 	

Nota. Información detallada de la H.U.05

Sprint Backlog. En la Tabla 32, se detalla el Sprint Backlog 05, correspondiente a las tareas que se realizan de acuerdo con las especificaciones de la historia de usuario H.U.05 del

Sprint 05, detallando la persona a cargo de cada actividad, el rango de fechas programado para el Sprint, la estimación en horas para completar cada tarea asignada y el estado actual de su progreso.

Tabla 32

Sprint Backlog 05

Sprint 3						
Fecha Inicio: 17/07/2023		Fecha Fin: 11/08/2023			Jornada: 8 horas	
HU ID	Tareas	Horas	Inicio	Fin	Responsable	Estado
H.U.05	Calcular el tiempo empleado en el entrenamiento de modelos de identificación por el rostro y Re-Identificación de personas	40	17/07/2023	21/07/2023	Steven Lema Alex Robayo	Finalizado
H.U.05	Comparación de los porcentajes de utilización de CPUs vs GPUs	40	24/06/2023	28/07/2023	Steven Lema Alex Robayo	Finalizado
H.U.05	Comparación de los porcentajes de utilización de CPU y GPU según el tipo de uso dentro del sistema de Re-Identificación de personas.	40	31/07/2023	04/08/2023	Steven Lema Alex Robayo	Finalizado
H.U.05	Aplicación de métricas para medir la eficiencia del sistema de Re-Identificación de personas usando el modelo combinado y el mejor clasificador	40	07/08/2023	11/08/2023	Steven Lema Alex Robayo	Finalizado
Total de horas y días:		200 horas	20 días			

Nota. Información detallada del Sprint Backlog 05.

Tiempo empleado en el entrenamiento de modelos de identificación de rostros y Re-Identificación de personas. La comparativa del tiempo que le toma a los procesadores CPU y GPU, ofrece una visión fundamental acerca de cuál de estas unidades de procesamiento resulta más eficiente para los modelos de identificación facial y de Re-ID a través de características soft-biométricas silueta, color y textura de la ropa.

Tiempo empleado en el modelo de identificación de rostros. A continuación, en la Tabla 33 se muestra los tiempos empleados para el entrenamiento del modelo de detección facial usando CNN a través de YOLO, con un dataset de 300 imágenes de rostros de la clase 1: Alex.

Tabla 33

Comparación del tiempo empleado en el entrenamiento del modelo de reconocimiento facial

Tipo de procesador	Cantidad de datos	Tamaño del modelo	Tiempo de entrenamiento
CPU	300	11,95 MB	9.52 seg
GPU	300	11,95 MB	4.30 seg

Nota. Tiempo empleado para el entrenamiento del modelo de detección facial con el uso de GPU y CPU de la clase 1: Alex.

En la Tabla 33 se presentan los datos obtenidos al momento de entrenar el modelo para el reconocimiento facial con el uso del algoritmo CNN, además la cantidad de datos y el tamaño del modelo es el mismo para los 2 casos, una vez realizada la medición de tiempos de entrenamiento con el uso de CPU fue de 9.5 seg, mientras que con el uso de GPU el tiempo de entrenamiento fue de 4.3 seg.

En base a los datos previamente obtenidos el procesador óptimo para entrenar el modelo de identificación facial es la GPU, ya que presenta un menor tiempo de entrenamiento que fue de 4.3 seg, en comparación al tiempo empleado por la CPU que fue 9.5 seg.

Tiempo empleado modelo Re-ID de personas utilizando las características soft-biométricas: Silueta corporal (LBP), Textura (HoG) y Color (HoG) de la ropa. En el caso de Re-Identificación de personas hay que tener en cuenta que este proceso se realiza al instante por ello en la Tabla 34.

Tabla 34

Comparación del tiempo empleado en el entrenamiento del modelo de Re-Identificación de personas con el uso de GPU y CPU

Tipo de procesador	Algoritmo	Cantidad de datos	Tamaño del modelo	Tiempo de entrenamiento
CPU	CNN	300	19,95	2.45 seg
GPU				1.07 seg
CPU	DNN	300	19.95	2.10 seg
GPU				0.57 seg
CPU	SVM	300	18,9	3.45 seg
GPU				1.57 seg

Nota. Tiempo empleado para el entrenamiento del modelo de Re-ID.

En la Tabla 34 se muestran los datos obtenidos al momento de entrenar el modelo para la Re-Identificación de personas utilizando características soft-biométricas (silueta corporal, textura y color de la ropa) con CNN, DNN y SVM como clasificadores, además la cantidad de datos y el tamaño del modelo es el mismo para CNN y DNN debido a que solo se cambia el formato de archivo del modelo, para SVM el tamaño se reduce ya que el modelo que se genera es en formato de tipo xml, una vez realizada la medición de tiempos usando DNN como clasificador y la GPU como procesador donde se obtuvo un tiempo de 0.57 segundos

En base a los datos de la Tabla 34 se concluye que el procesador óptimo para entrenar el modelo de Re-Identificación de personas a través de la silueta corporal, textura y color de la ropa es la GPU conjuntamente con DNN, ya que presenta un menor tiempo de entrenamiento que fue de 0.57 segundos, en comparación al tiempo empleado por las demás combinaciones.

Porcentaje de Utilización de CPUs vs GPUs. En la Re-Identificación de personas, las GPUs son más utilizadas que las CPUs debido a la necesidad de procesar imágenes y cálculos complejos. Esto conduce a un mayor porcentaje de utilización en las GPUs en comparación con las CPUs.

Tabla 35

Comparación del porcentaje de utilización de la CPU y GPU para el entrenamiento de modelo para la identificación del rostro

Tipo de procesador	Algoritmo	Cantidad de datos	Tamaño del modelo	Porcentaje de utilización
CPU	CNN	300	11,6	100%
GPU				100%

Nota. Porcentaje de utilización de la CPU y la GPU para el entrenamiento del modelo de detección facial.

Para el entrenamiento el modelo de detección facial con el uso de CNN como clasificador y como procesador único la CPU, el porcentaje de utilización es del 100%, cuando se usó la GPU para el entrenamiento del modelo con el mismo clasificador, el resultado fue que se empleó el 100% de la GPU ya que al ser un procesamiento gráfico ocupa toda su capacidad en esta tarea.

Por lo observado anteriormente en la Tabla 35, en los dos casos se puede observar que el porcentaje de utilización no varía ya que se emplean todos los recursos para realizar esta tarea, esto debido a que tanto para la CPU y la GPU se usa el mismo modelo, por lo tanto, poseen el mismo tamaño.

En cuanto a los tiempos de subida de los datos para el entrenamiento a la GPU y de bajar la información procesada desde la GPU a la CPU, no influyen en el tiempo ni en porcentaje de procesamiento debido a que no es una cantidad significativa de información, por lo cual este proceso pasa imperceptible.

Tabla 36

Comparación del porcentaje de utilización de la CPU y GPU para el entrenamiento del modelo de Re-Identificación de personas

Tipo de procesador	Algoritmo	Cantidad de datos	Tamaño del modelo	Porcentaje de utilización
CPU	CNN	300	18,9	100%
GPU				100%
CPU	DNN	300	19.1	100%
GPU				100%
CPU	SVM	300	17,6	100%
GPU				100%

Nota. Porcentaje de utilización de la CPU y la GPU para el entrenamiento del modelo de Re-ID.

Durante el proceso de entrenamiento del modelo de Re-Identificación de personas a través de características soft-biométricas, al utilizar CNN, DNN y SVM como clasificadores y la CPU como el único procesador, se alcanza un nivel de utilización del 100%. De la misma manera, al realizar el entrenamiento utilizando la GPU con los mismos clasificadores, se observa una ocupación total de la GPU al 100%. De la misma manera que en el entrenamiento del modelo para la Identificación se puede observar una constancia en el porcentaje de utilización ya que los modelos con los que se trabaja son los mismo tanto para CPU como para GPU.

El tiempo empleado para cargar los datos en la GPU con fines de entrenamiento y para transferir los resultados procesados de la GPU a la CPU, no tienen impacto en el tiempo ni en el porcentaje de procesamiento. Esto se debe a que la cantidad de información involucrada no es considerable, lo que hace que este procedimiento transcurra desapercibido en términos de tiempo y eficiencia de procesamiento.

Tabla 37

Comparación del porcentaje de utilización de la CPU y GPU según el tipo de uso dentro del sistema de Re-Identificación de personas

Tipo de Procesador	Tipo de uso	Carga de trabajo	Porcentaje de utilización
CPU	Identificación facial	Alta	98%
	Re-ID (Silueta LBP, Textura y Color HoG)	Alta	99%
GPU	Identificación facial	Alta	35%
	Re-ID (Silueta LBP, Textura y Color HoG)	Alta	43%

Nota. Se indican los porcentajes de utilización para la Re-ID con la CPU y GPU.

En la Tabla 37 se muestran los valores obtenidos en donde difiere el uso que se le ha dado a cada tipo de procesador, la carga de trabajo para todos los casos es alta. En cuanto al uso de la CPU, para la identificación facial el porcentaje de utilización del procesador es de 98 % y para la Re-Identificación de personas a través del modelo combinado de silueta corporal (LBP), textura y color de la ropa (HoG), el porcentaje de utilización es de 98%, lo cual quiere decir que se requiere procesamiento exhaustivo de la CPU para el tratamiento de la información.

En cuanto a los porcentajes de utilización de la GPU, para la identificación de rostro se usa un 35% de la GPU, para la Re-Identificación de personas a través del modelo combinado de silueta corporal (LBP), textura y color de la ropa (HoG), el porcentaje de utilización es de 43%. Según los resultados se puede observar que, aunque la carga de trabajo sea alta la GPU no opera a su máxima capacidad para ejecutar esta tarea.

Según los resultados anteriores, cuando la CPU trabaja sola en el procesamiento tiene un porcentaje de utilización cercano al 100%, en cambio cuando se usa la GPU el mayor porcentaje de utilización es 43%, el cual se da cuando se realiza la Re-Identificación a través del modelo combinado de características, debido a que procesar esta información es una tarea que requiere más tratamiento en la parte gráfica.

Aplicación de métricas para medir la eficiencia del sistema de Re-Identificación de personas usando el modelo combinado y el mejor clasificador. A continuación, se realizará la aplicación de métricas para medir la eficiencia del sistema de Re-Identificación de personas, con el modelo combinado de características soft-biométricas y modelo DNN que destacó en los resultados anteriores, por lo que permite comparar el desempeño de la CPU y la GPU. Estas métricas incluyen el tiempo de ejecución, el uso de la CPU o GPU en relación con el tiempo total, los cuadros por segundo (FPS), la utilización de memoria y la aceleración. El **Tiempo de ejecución** se calcula restando el tiempo inicial del tiempo final. El **Uso de la CPU o GPU** se obtiene dividiendo el tiempo de uso de CPU o GPU por el tiempo total de ejecución y multiplicando por 100. Los **FPS** se calcula dividiendo 1 entre el tiempo por cuadro. La **Utilización de memoria** se calcula dividiendo la memoria utilizada por el programa entre la memoria total disponible y multiplicando por 100. La **Aceleración** se obtiene dividiendo el tiempo de ejecución utilizando solo la CPU entre el tiempo de ejecución utilizando la GPU y multiplicando por 100. Estas métricas revelan cómo cada componente afecta la eficiencia en el sistema de Re-Identificación.

La Tabla 38 muestra los valores de las variables mencionadas en el párrafo anterior.

Tabla 38

Variables de las métricas de evaluación de rendimiento de GPU y CPU

Variables	Video	Tiempo de ejecución		Uso de la CPU o GPU		FPS	Utilización de memoria		Aceleración	
	Tiempo	Tiempo Inicial	Tiempo Final	Tiempo de uso de CPU o GPU	Tiempo total de ejecución	Tiempo por cuadro	Memoria utilizada por el programa	Memoria total disponible	Tiempo de ejecución utilizando solo CPU	Tiempo de ejecución utilizando GPU
CPU	10 seg	0	15.27 seg	15 seg	15.27 seg	0.46 seg	0.19 GB	32 GB RAM	15.27 seg	10.34 seg
GPU		0	10.34 seg	10 seg	10.34 seg	0.21 seg	2.04 GB			

Nota. Se presentan dos configuraciones diferentes: una en la que se utiliza la CPU y otra en la que se utiliza la GPU para procesar el video.

La Tabla 38 muestra una comparación del rendimiento de una CPU y una GPU. Según los datos presentados, la GPU tiene un tiempo de ejecución más rápido y utiliza menos

memoria que la CPU. Esto sugiere que la GPU es más eficiente en términos de tiempo y uso de memoria para el video en cuestión.

En la Tabla 39, se realiza una comparación exhaustiva de los resultados obtenidos aplicando las métricas establecidas anteriormente. Esta evaluación detallada proporciona una visión global de cómo se comportan los enfoques de Reconocimiento Facial y Re-ID en términos de eficiencia y rendimiento, permitiendo una comprensión más precisa de su impacto en el sistema.

Tabla 39

Comparación usando las métricas para evaluar el rendimiento de GPU y CPU

Algoritmo	Tiempo de ejecución (segundos)	Uso de la CPU o GPU (%)	FPS	Utilización de memoria (%)	Aceleración (%)
Reconocimiento Facial	15.09	CPU: 99%	63	22.4%	46%
		GPU: 9%			
Re-ID	14.05	CPU: 99%	42	46.8%	38%
		GPU: 8%			

Nota. Aplicación de métricas para evaluar el rendimiento de GPU y CPU, en el reconocimiento de personas y en la Re-Identificación de personas.

La Tabla 39 muestra los resultados de pruebas de rendimiento para los procesadores en la identificación facial y en la Re-ID de personas, en el caso del algoritmo "Reconocimiento Facial", se toman 10.09 segundos para ejecutarlo en la CPU con una utilización de recursos del 99%, mientras que en la GPU se ejecuta en 9% de su capacidad con una aceleración del 46%. El tiempo total de uso es de 15 segundos, se obtienen 63 FPS y se utiliza un 22.4% de memoria. Para el algoritmo "Re-ID", se necesitan 14.05 segundos para ejecutarlo en la CPU con una utilización del 99%, mientras que en la GPU se ejecuta en 8% de sus recursos con una aceleración del 38%. El tiempo total de uso es de 20 segundos, se obtienen 42 FPS y se utiliza un 46.8% de memoria. Estos resultados reflejan el desempeño de los algoritmos en términos de tiempo, velocidad, utilización de recursos y aprovechamiento de la aceleración en la GPU en comparación con la CPU.

Nota. Finalizado el Sprint los objetivos se cumplieron correctamente.

Capítulo IV

Validación del Sistema

En este capítulo se realiza la validación del sistema de Re-ID de personas a partir de la característica biométrica, el rostro, y la combinación de características soft-biométricas, la silueta corporal, la textura y color de la ropa. Se añaden 4 nuevos videos que corresponden a 4 personas (Clases Ángel, Diego, Flor y Jhon) que se encuentran registradas en el dataset de rostros. Estos videos se analizan a fin de Identificar a las personas, mediante el modelo de rostros, y Detectarlas y Re-Identificarlas, a través del modelo de Re-Identificación de personas, para luego a través de las métricas propuestas evaluar los resultados.

Marco de evaluación

El sistema de Re-ID de personas se realiza en un entorno controlado y se divide en dos casos para las validaciones. En el primer caso, se busca identificar a las personas utilizando sus características biométricas, específicamente el rostro, a través de la cámara 1. En el segundo caso, se lleva a cabo la detección y Re-ID de personas utilizando características soft-biométricas, que incluyen la silueta corporal, la textura y el color de la ropa, mediante la cámara 2.

El sistema hace uso de la CPU y la GPU juntas en la Re-Identificación de personas, aprovechando sus fortalezas individuales para lograr un rendimiento y eficiencia relevantes en el proceso de Re-Identificación de personas, a través de cámaras. En este proceso se utiliza tres procesadores, para distribuir la carga del sistema, y mejorar el rendimiento de procesamiento (velocidad), mediante la ejecución de procesamiento paralelo de tareas. El primer procesador realiza la detección y la Identificación de personas mediante el análisis de rostros a través de la primera cámara. Con esta cámara se captura imágenes del individuo, mediante el segundo procesador, para construir el conjunto de datos relacionado con la silueta corporal, textura y color de la ropa, que se almacenan en una carpeta específica y construir el conjunto de descriptores que permitirá entrenar uno de los clasificadores propuestos. El tercer

procesador se encarga, a través de la segunda cámara, de la detección y Re-ID de personas utilizando las características de la silueta corporal, textura y color de la ropa aprendidas por uno de los modelos. Es importante destacar que este proceso se lleva a cabo utilizando videos previamente grabados de diferentes personas en un entorno controlado, con dos perspectivas de cámara, ver sección “Escenario para el sistema de Re-Identificación de personas” y Figura 9 del capítulo III.

Aplicación de las métricas de evaluación

En esta sección la única métrica que se va a utilizar es la de precisión, debido a que esta métrica se obtiene el valor exacto de que tan eficientes son los algoritmos, mediante el uso de la matriz de confusión, con el fin de calcular las métricas de evaluación. Para realizar la validación se usa el equipo hardware que se especifica en la sección “Herramientas de Hardware para el Desarrollo del Sistema de Re-Identificación de Personas”, capítulo III.


Pruebas del algoritmo de identificación facial y Re-Identificación de la silueta corporal, textura y color de la ropa.

Se hicieron varias pruebas con dos videos de una persona caminando en dos pasillos diferentes. En la primera prueba, la cámara 1 grabó un video de la persona caminando hacia adelante en el primer pasillo. En la segunda prueba, la cámara 2 capturó un video de la misma persona de espaldas caminando en el segundo pasillo.

El sistema de Re-Identificación de personas fue sometido a pruebas utilizando 3 procesadores, cada uno con funciones específicas y operando en espacios de memoria separados. Estos procesadores trabajan en paralelo para ejecutar las tareas de manera más eficiente, como se representa en la Figura 19.

Figura 19

Representación de ejecución del sistema en multiprocesamiento




Nota. Esquema del sistema de multiprocesamiento.

El sistema de Re-Identificación de personas utiliza la CPU y la GPU de forma conjunta, aprovechando sus fortalezas individuales para lograr un rendimiento y eficiencia óptimos en el proceso de identificación y seguimiento de personas a través de cámaras y momentos diferentes. A continuación, en la Figura 20, se muestra un diagrama de las tareas que se realizan y que arquitectura interviene.

Figura 20

Descripción de cómo trabajan la CPU y GPU en el sistema de Re-Identificación de personas



Nota. Esquema del modo de trabajo de la CPU y la GPU.

En la Re-Identificación de personas, la CPU se encarga del **preprocesamiento** de imágenes y la gestión general del sistema, mientras que la GPU realiza cálculos intensivos en paralelo para la **extracción de características** y la **comparación de datos**. La CPU **coordina las operaciones**, administra la base de datos y garantiza la fluidez del flujo de trabajo,

mientras que la GPU acelera las operaciones matemáticas y de análisis de imágenes, permitiendo una identificación y seguimiento eficiente a través de múltiples cámaras y momentos. Juntas, CPU y GPU **optimizan el rendimiento** del proceso de Re-Identificación al aprovechar sus respectivas fortalezas (Bağ et al., 2011).

Resultados de las Pruebas

En la Figura 21 se presentan los resultados obtenidos en las pruebas del sistema de Re-ID con énfasis en la característica facial, cabe indicar que para realizar las pruebas el dataset tiene 300 imágenes por cada Clase, ya que se dispone 5 clases, se tiene un total de 1500 imágenes.

Figura 21

Al dataset se añade de 4 nuevas Clases para llevar a cabo la Re-ID mediante el modelo de rostro



Nota. Para la validación del sistema se dispone de 4 nuevas clases. Todas las pruebas se llevaron a cabo en un entorno controlado, específicamente en las instalaciones de la Universidad de las Fuerzas Armadas.

Tabla 40

Resultados de la matriz de confusión de las nuevas clases, aplicando el modelo de rostros para la Identificación de personas.

Descriptor		Identificación Facial										
		LBP			HOG							
Clasificador	SVM	DNN		CNN		SVM	DNN		CNN			
	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos		
Angel												
Positivos	136	1	166	0	149	0	114	21	157	7	145	7
Negativos	4	2	0	0	1	1	3	4	0	2	1	3
Diego												
Positivos	132	3	174	0	153	0	126	27	156	1	127	6
Negativos	4	5	0	0	1	1	1	1	2	2	3	0
Flor												
Positivos	129	4	186	0	134	0	110	28	138	1	122	7
Negativos	4	4	0	0	1	1	3	1	3	3	4	3
Jhon												
Positivos	113	3	154	0	160	1	113	2	130	5	126	7
Negativos	5	3	0	0	0	0	2	5	0	1	0	2

Nota. En la tabla se presentan los resultados de las pruebas con las nuevas clases aplicando el modelo de rostros para la Identificación de personas, mediante la Matriz de Confusión al combinar descriptores LBP y HoG y clasificadores SVM, DNN y CNN.

Del análisis de la Tabla 40 se deduce que los resultados obtenidos a partir de la matriz de confusión varían en función del descriptor y del clasificador utilizados para la identificación facial. Este fenómeno se debe a las diferencias en el número de detecciones que se producen entre los distintos clasificadores, así como del tiempo del video y de la iluminación de este para cada Clase.

Tabla 41

Resultados de las pruebas realizadas con las nuevas clases, aplicando las métricas de evaluación

Escenario		Cámara 1, primer pasillo, hora: 11:30 am				
Identificación Facial						
Descriptor	LBP			HOG		
Clasificador	SVM	DNN	CNN	SVM	DNN	CNN
Clase	Angel					
Precisión	0,97	1,00	0,99	0,83	0,96	0,95
Clase	Diego					
Precisión	0,95	1,00	0,99	0,82	0,98	0,93
Clase	Flor					
Precisión	0,94	1,00	0,99	0,78	0,97	0,95
Clase	Jhon					
Precisión	0,94	1,00	0,99	0,97	0,96	0,95
Promedio	0,95±0,01	1,00±0,00	0,99±0,00	0,85±0,08	0,97±0,01	0,95±0,01

Nota. Para realizar estas pruebas se utilizó la métrica de evaluación precisión con las nuevas Clases, los porcentajes incluyen el valor de la desviación estándar al emplear las combinaciones de LBP y HoG junto a SVM, DNN y CNN.

La Tabla 41 exhibe los resultados y los valores derivados de las pruebas llevadas a cabo en el primer escenario, el cual corresponde a la Cámara 1 en el primer pasillo a las 11:30 a.m. En la Tabla se detallan las Clases y los valores de Precisión al aplicar las combinaciones de LBP y HoG con SVM, DNN y CNN. Los resultados señalan que la mejor configuración para la identificación facial es la que involucra al descriptor LBP junto al clasificador DNN, de acuerdo con el promedio alcanzado de 1.00 ± 0.00 , por dicho modelo.

A continuación, se presentan los resultados obtenidos en varias pruebas utilizando el sistema de Re-ID, con énfasis en las características soft-biométricas silueta corporal, textura y color de la ropa.

Figura 22

Resultados de las pruebas realizadas con las nuevas clases, aplicando la combinación de características



Nota. Se utilizaron las 4 nuevas Clases en todas las pruebas del sistema, las cuales se llevaron a cabo en un entorno controlado, específicamente en las instalaciones de la Universidad de las Fuerzas Armadas.

Tabla 42

Resultados de la matriz de confusión de las nuevas clases al aplicar los distintos modelos de Re-Identificación de personas

Descriptor Clasificador	Re-Identificación Silueta				Re-Identificación Textura						Re-Identificación Color									
	LBP		CNN		LBP		HOG		SVM		DNN		CNN		LBP		HOG			
	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos		
Angel																				
Positivos	16	22	19	31	85	0	87	2	76	2	120	4	118	9	65	26	85	7	87	28
Negativos	4	7	18	14	0	0	2	2	4	6	2	3	2	3	7	4	8	14	4	12
Diego																				
Positivos	10	11	18	35	82	0	78	2	76	1	112	1	96	6	62	12	89	15	86	13
Negativos	5	9	17	17	0	0	3	1	2	6	3	1	2	2	14	8	9	4	1	9
Flor																				
Positivos	10	39	15	21	80	0	79	1	79	13	113	3	109	8	77	25	75	10	76	13
Negativos	4	8	13	18	0	0	3	1	5	5	1	0	1	1	7	3	4	6	9	8
Jhon																				
Positivos	19	16	13	14	75	0	86	1	79	2	125	3	106	9	79	14	87	10	82	10
Negativos	9	6	13	16	1	0	1	3	5	2	2	2	2	2	6	7	1	9	3	13

Nota. Se presentan los valores de la matriz de confusión de las nuevas Clases, al aplicar los distintos modelos de Re-Identificación de personas, al combinar LBP o HoG junto a SVM, DNN y CNN, para las características soft-biométricas silueta corporal, textura y color de la ropa por separado.

Del análisis de la Tabla 42 se deduce que los resultados obtenidos a partir de la matriz de confusión varían en función del descriptor y del clasificador utilizados para la identificación facial. Este fenómeno se debe a las diferencias en el número de detecciones que se producen entre los distintos clasificadores, así como del tiempo del video y de la iluminación de este para cada Clase.

Tabla 43

Resultados de las pruebas realizadas con las nuevas clases, aplicando las métricas de evaluación precisión

Cámara 2, segundo pasillo, hora: 11:30 am										
Escenario	Re-Identificación Silueta			Re-Identificación Textura				Re-Identificación Color		
Descriptor	LBP		LBP		HOG		LBP	HOG		
Clasificador	DNN	CNN	DNN	CNN	SVM	DNN	CNN	SVM	DNN	CNN
Clase	Angel									
Precisión	0,47	0,40	1,00	0,96	0,93	0,95	0,92	0,68	0,87	0,76
Clase	Diego									
Precisión	0,54	0,40	1,00	0,94	0,96	0,97	0,92	0,73	0,79	0,87
Clase	Flor									
Precisión	0,30	0,49	1,00	0,95	0,82	0,97	0,92	0,71	0,85	0,79
Clase	Jhon									
Precisión	0,50	0,52	0,99	0,98	0,92	0,96	0,91	0,81	0,90	0,88
Promedio	0,45±0,11	0,45±0,06	0,99±0,01	0,96±0,02	0,91±0,06	0,96±0,01	0,92±0,01	0,73±0,06	0,85±0,05	0,83±0,06

Nota. Para realizar estas pruebas se utilizó la métrica de evaluación precisión con las nuevas Clases, los porcentajes incluyen el valor de la desviación estándar al emplear las combinaciones de LBP y HoG junto a SVM, DNN y CNN.

La Tabla 42, exhibe los resultados y los valores derivados de las pruebas llevadas a cabo en el primer escenario, el cual corresponde a la Cámara 2 en el primer pasillo a las 11:30 a.m. En la Tabla 43, se detallan las Clases y los valores de precisión al aplicar las combinaciones de LBP y HoG en conjunción con los algoritmos SVM, DNN y CNN. Los resultados señalan que la mejor configuración para la Re-Identificación de personas a través de la silueta corporal es la que involucra el descriptor LBP con el clasificador CNN, evidenciando un valor promedio y desviación estándar de 0.45 ± 0.06 . Por otro lado, la mejor configuración para la Re-Identificación mediante la textura de la ropa es la que involucra a LBP con DNN, evidenciando un valor promedio y desviación estándar de 0.99 ± 0.01 , y finalmente, la configuración para la Re-Identificación mediante el uso del color de la ropa es la que involucra HoG con DNN, evidenciando un valor promedio y desviación estándar de 0.85 ± 0.05 .

Tabla 44

Resultados de las pruebas realizadas con las nuevas clases, aplicando la métrica de evaluación precisión

Re-Identificación de las personas a través de su silueta corporal, textura y color de la ropa			
(Combinación de características)			
Característica	Silueta LBP Textura HoG Color HoG	Silueta LBP Textura HoG Color HoG	Silueta LBP Textura HoG Color HoG
Clasificador	SVM	DNN	CNN
Clase		Ángel	
Precisión	0,64	0,78	0,88
Clase		Diego	
Precisión	0,53	0,98	0,72
Clase		Flor	
Precisión	0,77	0,77	0,82
Clase		Jhon	
Precisión	0,69	0,91	0,95
PROMEDIO	0,66±0,1	0,86±0,1	0,84±0,1

Nota. Combinación de las características soft-biométricas silueta corporal, textura y color de la ropa aplicado a las 4 Clases.

La Tabla 44 presenta las precisiones del sistema Re-ID al emplear conjuntamente las tres características biométricas blandas: silueta corporal, textura y color de la ropa, en relación con las cuatro clases. Los resultados indican que la combinación óptima de características consiste en la silueta corporal junto con el descriptor LBP, mientras que la textura y el color de la ropa se asocian con el descriptor HoG, con el apoyo del clasificador DNN. El conjunto de datos alcanza una precisión media de 0,86, con una desviación estándar de $\pm 0,1$. Estos resultados evidencian la coherencia y eficacia de la metodología en el campo de la Re-Identificación de personas.

Validación de la eficiencia del sistema de Re-Identificación

Cámara 1: Identificación de personas (Característica biométrica: rostro)

Tabla 45

Comparación del uso de la CPU y GPU, en el modelo de identificación facial

Descriptor	Clasificador	CPUs	GPUs	Literatura Científica	
		Precisión	Precisión	Precisión mínima	Precisión máxima
YOLO	SVM	83±1,7	83±1,7	64,6%	96,83%

Nota. Tabla comparativa de la precisión en la detección facial.

En la Tabla 45 se observa la comparación entre el uso de CPUs vs GPUs para la Re-Identificación de personas utilizando la característica biométrica el rostro y como clasificador SVM dando una precisión del $83\pm 1,7$. Según la literatura los resultados de precisión arrojados por el modelo se encuentran dentro del rango mínimo 64,6% (Dadi & Pillutla, 2016) y máximo 96,83% (Shi et al., 2020) de detección de rostros, por lo cual se dice que el modelo es óptimo para el reconocimiento facial de personas.

Una vez que se han obtenido los datos de precisión tanto de CPU como GPU, se puede observar que estos datos no varían, presentan el mismo valor, por lo que se concluye que el tipo de procesador no influye en la precisión del modelo al momento de realizar la detección.

Cámara 2: Re-identificación de personas a través del uso de características soft-biométricas: Silueta corporal, textura y color de la ropa

Tabla 46

Comparación de la precisión en la Re-Identificación de personas con el uso de CPU y GPU

Descriptor	Clasificador	CPUs	GPUs	Literatura Científica	
		Precisión	Precisión	Precisión mínima	Precisión máxima
Silueta LBP	SVM	0,66±0,1	0,66±0,1		
Textura HoG					
Color HoG					
Silueta LBP	DNN	0,86±0,1	0,86±0,1	33,30%	86,53%
Textura HoG					
Color HoG					
Silueta LBP	CNN	0,84±0,1	0,84±0,1		
Textura HoG					
Color HoG					

Nota. Tabla comparativa de la precisión de la Re-ID de personas.

En la Tabla 46 se presenta la comparación entre la utilización de CPUs y GPUs para llevar a cabo la tarea de Re-Identificación de personas. Esta tarea involucra el análisis de características, descriptores específicos y clasificadores. La silueta corporal se extrae a través del descriptor LBP, la textura y el color de la ropa se describe con HoG, los cuales se combinan con los clasificadores SVM, DNN y CNN. En el escenario que se hace uso de la CPU y se emplea el clasificador SVM, se logra una precisión de aproximadamente del 0,66 con un margen de error de $\pm 0,1$. Por otro lado, con DNN arroja una precisión de 0,86 y un margen de error de $\pm 0,1$. Y finalmente con CNN y las mismas características y descriptores se obtiene un valor de precisión del 0,84 con un margen de error de $\pm 0,1$. Con la GPU los resultados de precisión no varían, de tal manera que la precisión que fue obtenida con la CPU también se mantiene en la GPU. El uso de la GPU no afecta al valor de precisión al Re-Identificar a una persona, la utilización de este tipo de procesador acelera el tiempo de procesamiento y detección, mas no afecta a la precisión debido a la naturaleza de las tareas que se ejecutan.

De este análisis realizado se deduce que el modelo de Re-Identificación de personas más efectivo resulta ser al aplicar el clasificador DNN, con un índice de precisión del $0,86 \pm 0,1$.

Esta elección se basa en su destacada precisión, la cual se encuentra dentro del intervalo de precisión mínimo y máximo previamente documentado en la literatura revisada.

Validación de los tiempos de entrenamiento de los modelos de identificación del rostro y de Re-Identificación de personas

En este apartado se muestran los tiempos de entrenamiento de los distintos modelos de rostros, para las 1500 imágenes que representan las 5 clases que conforman el dataset de rostros. En la Tabla 47 se muestra los tiempos empleados para el entrenamiento del modelo de detección facial usando CNN a través de YOLO

Tabla 47

Comparación del tiempo empleados en el entrenamiento del modelo de reconocimiento facial con el uso de GPU y CPU de las clases Alex, Ángel, Diego, Flor y Jhon

No. Clase	Cantidad de datos	Tamaño del modelo	Tiempo de entrenamiento (segundos)	
			CPU	GPU
5	1500	11,95 MB	9,52	4,30

Nota. Tiempo empleado para el entrenamiento del modelo de Identificación facial con las clases Alex, Ángel, Diego, Flor y Jhon.

En la Tabla 47 se muestran los promedios obtenidos en los tiempos de entrenamiento del modelo de identificación de todas las clases, en donde se obtienen dos resultados. El tiempo promedio de entrenamiento del modelo de identificación facial utilizando exclusivamente la CPU es de 9.52 segundos. Por otro lado, al emplear la GPU, el tiempo promedio se reduce a 4.30 segundos, lo que supone una diferencia significativa de 5.22 segundos con respecto al uso exclusivo de la CPU. Esta variación en los tiempos resalta la eficiencia de la GPU en las labores de entrenamiento del modelo de identificación facial.

Tiempo empleado en el modelo para Re-ID de personas utilizando las características soft-biométricas: Silueta corporal (LBP), Textura (HoG) y Color (HoG) de la ropa.

En la Tabla 48 se muestran los tiempos empleados en el entrenamiento del modelo de Re-Identificación de personas para las 4 clases: Ángel, Diego, Flor y Jhon.

Tabla 48

Comparación del tiempo empleado en el entrenamiento del modelo de Re-Identificación de personas combinando las características

Clase	Algoritmo	Cantidad de datos	Tamaño del modelo	Tiempo de entrenamiento	
				CPU	GPU
Ángel	CNN	300	19,95 MB	2,45	1,3
	DNN			1,57	1,11
	SVM			2,97	1,57
Diego	CNN	300	19,95 MB	3,36	1,84
	DNN			2,01	1,1
	SVM			2,86	1,96
Flor	CNN	300	19,95 MB	2,42	1,52
	DNN			2,27	1,17
	SVM			3,54	1,67
Jhon	CNN	300	19,95 MB	3,84	1,54
	DNN			2,49	1,37
	SVM			3,97	1,69
Promedio tiempo de entrenamiento:			CNN	3,02±0,7	1,55±0,22
			DNN	2,09±0,4	1,19±0,13
			SVM	3,34±0,52	1,72±0,17

Nota. Tiempo empleado para el entrenamiento del modelo de Re-ID de personas con 4 clases:

Ángel, Diego, Flor y Jhon.

En la Tabla 48, se observa los promedios obtenidos en los tiempos de entrenamiento del modelo de Re-Identificación de personas, combinando las características de silueta corporal (LBP), textura (HoG) y color (HoG) de la ropa junto con los clasificadores CNN, DNN y SVM de las 4 clases. El promedio del tiempo de entrenamiento del modelo de Re-ID usando CNN en el caso de la CPU en promedio es de 3,02±0,7 y con la GPU es de 1,55±0,22, valores que determinan una diferencia aproximada de 1.47 segundos con respecto a la CPU. Con DNN el promedio de tiempo de uso de la CPU es 2,09±0,4 y de la GPU es 1,19±0,13, cuya diferencia

aproximada es 0,9 segundos con respecto a la CPU. Usando SVM como clasificador el promedio de tiempo de entrenamiento con la CPU es de $3,34 \pm 0,52$ y de la GPU es de $1,72 \pm 0,17$, con una diferencia aproximada de 1,62. Estos resultados demuestran que los tiempos de la GPU son inferiores a los de la CPU.

Por lo expuesto anteriormente se puede concluir que la GPU muestra una notable diferencia por su mayor eficiencia en las tareas de entrenamiento para el modelo combinado de características soft-biométricas: silueta corporal (LBP), textura (HoG) y color (HoG) de la ropa junto con los clasificadores CNN, DNN y SVM con las 4 nuevas Clases.

Capítulo V

Conclusiones

Las conclusiones obtenidas con este trabajo se presentan a continuación:

A partir del análisis exhaustivo de la literatura de diversos artículos científicos, se obtuvo información acerca de diversas técnicas avanzadas computacionales que fueron esenciales para la implementación del sistema de Re-Identificación de personas. En este trabajo se emplearon definiciones, la característica biométrica del rostro, así como descriptores de rostros (LBP y/o HoG) y modelos (SVM, CNN, DNN) con el propósito de llevar a cabo la identificación de individuos mediante el análisis facial. Además, se emplean definiciones, características soft-biométricas como la silueta corporal, la textura y el color de la ropa, junto con descriptores y modelos, con el propósito de llevar a cabo la detección y Re-Identificación de individuos mediante la combinación de estas características.

Con el propósito de construir un dataset se eligieron cinco individuos como modelos a partir de los cuales se generaron dos conjuntos de información. El primer conjunto contenía 300 imágenes diferentes del rostro de cada persona y se utilizó específicamente en el proceso de reconocimiento facial. El segundo conjunto se consideró desde la perspectiva de la identificación de una persona en un momento dado. En donde, el dataset construido está conformado por 1500 imágenes de personas (Clases) de todo el cuerpo. A partir de estas imágenes, se generaron los descriptores correspondientes a la silueta corporal, la textura y el color de la ropa, con los cuales se construyó un modelo que combina dichos descriptores.

Con el enfoque desarrollado en este trabajo y las pruebas realizadas al modelo de Re-identificación de personas se determina que el uso de la GPU no tiene impacto en este proceso, ya que se observa una notable constancia en la precisión de los datos obtenidos, tanto en la CPU como en la GPU.

El porcentaje de uso de procesadores para el entrenamiento del modelo de identificación facial y de los modelos de Re-Identificación de personas se mantienen

constantes, tanto en la CPU como en la GPU al aprovechar todos los recursos disponibles en el desarrollo de las tareas asignadas. Sin embargo, existe una variación en los tiempos de finalización del proceso de entrenamiento, que difieren según el tipo de procesador. Estas observaciones indican que la eficiencia en el uso de recursos es uniforme, aunque el rendimiento temporal varía entre CPU y GPU.

La creación y aplicación de un modelo que combina las características soft-biométricas de silueta corporal, textura y color de la ropa en un sistema de Re-Identificación de personas demostró ser una estrategia prometedora. Estas características fueron extraídas por los descriptores LBP y HOG mismas que fueron combinadas con clasificadores SVM, CNN y DNN, dando buenos resultados de precisión. La combinación más efectiva encontrada fue con el uso de los descriptores de, silueta (LBP), textura y color (HoG) usando como clasificador DNN. Esta unión dio como resultado una precisión de $0,86 \pm 0,1$, resultado que se encuentra en el rango de precisión mínimo y máximo encontrados en literatura científica investigada, con un 33,3% (Nodehi & Shahbahrami, 2021) y un 86,53% de Re-Identificación respectivamente (Greeshma & Gripsy, 2020).

En cuanto al uso de los procesadores la GPU es el procesador más eficiente al realizar las tareas que requieren el manejo de gráficos, ya que el tiempo y la calidad con las que realiza el trabajo es mejor que cuando se usa únicamente la CPU, en el caso del entrenamiento del modelo de identificación facial la CPU presenta un tiempo promedio de $9,61 \pm 0,27$ y la GPU de $4,53 \pm 0,01$, teniendo un procesamiento 5.08 segundos más rápido que la CPU, de la misma manera para el entrenamiento con características soft-biométricas usando DNN como clasificador la GPU logra un tiempo de $1,19 \pm 0,13$ segundos, en contraste a los $2,09 \pm 0,4$ segundos requeridos por la CPU.

Bibliografía

- Ahonen, T., Hadid, A., & Pietikainen, M. (2006). Face description with local binary patterns: Application to face recognition. *IEEE transactions on pattern analysis and machine intelligence*, 28(12), 2037-2041.
- Aissaoui, A., Martinet, J., & Djeraba, C. (2014). *DLBP: A novel descriptor for depth image based face recognition*. 298-302.
- Almeida, F., & Carneiro, P. (2021). Performance metrics in scrum software engineering companies. *International Journal of Agile Systems and Management*, 14(2), 205-223.
- Anil, J., Hong, L., & Sharath, P. (2000). *Biometric identification: Communications of the ACM*.
- Bąk, S., Kurowski, K., & Napierała, K. (2011). *Human re-identification system on highly parallel gpu and cpu architectures*. 293-300.
- Behera, N. K. S., Behera, T. K., Nappi, M., Bakshi, S., & Sa, P. K. (2021). Futuristic person re-identification over internet of biometrics things (IoBT): Technical potential versus practical reality. *Pattern Recognition Letters*, 151, 163-171.
- Betancourt, D., Carrillo, J., & Jacho, N. (2023). Sistema de Re-Identificación de personas a través de las características faciales y soft-biométricas la textura de la utilizando algoritmos de Visión por Computadora y Machine Learning. 2023.
- Bi, Q., Goodman, K. E., Kaminsky, J., & Lessler, J. (2019). What is machine learning? A primer for the epidemiologist. *American journal of epidemiology*, 188(12), 2222-2239.
- Buber, E., & Banu, D. (2018). *Performance analysis and CPU vs GPU comparison for deep learning*. 1-6.
- Cadavid, A. N., Martínez, J. D. F., & Vélez, J. M. (2013). Revisión de metodologías ágiles para el desarrollo de software. *Prospectiva*, 11(2), 30-39.
- 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*. 1-8.

- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20, 273-297.
- Dadi, H. S., & Pillutla, G. M. (2016). Improved face recognition rate using HOG features and SVM classifier. *IOSR Journal of Electronics and Communication Engineering*, 11(4), 34-44.
- De Giusti, A. E., Tinetti, F. G., Naiouf, M., Chichizola, F., De Giusti, L. C., Villagarcía Wanza, H. A., Montezanti, D. M., Frati, F. E., Pousa, A., & Rodriguez, I. P. (2014). *Arquitecturas multiprocesador en cómputo de altas prestaciones: Software de base, métricas y aplicaciones*. XVI Workshop de Investigadores en Ciencias de la Computación.
- de Mur, A. (2017). *Detección de personas en secuencias de imágenes en entornos interiores*.
- Dorronsoro Larbide, I. (2023). *Desarrollo, optimización y despliegue de un servidor eficiente para la inferencia de redes neuronales de apoyo al radiodiagnóstico*.
- Echeverría Perugachi, Á. S., & Segovia Espinosa, F. M. (2023). Sistema de re-identificación de personas a través de las características faciales y soft-biométricas el color de la , utilizando algoritmos de Visión por Computadora y Machine Learning. *Universidad de las Fuerzas Armadas ESPE Extensión Latacunga. Carrera de Ingeniería en Software*.
- Elharrouss, O., Almaadeed, N., Al-Maadeed, S., & Bouridane, A. (2021). Gait recognition for person re-identification. *The Journal of Supercomputing*, 77, 3653-3672.
- Foreman, E. (2018). *What is Scrum?* Scrum.Org. <https://www.scrum.org/learning-series/what-is-scrum>
- Fuad, M. T. H., Fime, A. A., Sikder, D., Iftee, M. A. R., Rabbi, J., Al-Rakhami, M. S., Gumaei, A., Sen, O., Fuad, M., & Islam, M. N. (2021). Recent advances in deep learning techniques for face recognition. *IEEE Access*, 9, 99112-99142.
- Gaikwad, B., & Karmakar, A. (2022). End-to-end person re-identification: Real-time video surveillance over edge-cloud environment. *Computers and Electrical Engineering*, 99, 107824.

- 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*. 14-20.
- Godoy, D. A. (2015). *Diseño de un Simulador Dinámico de Proyectos de Desarrollo de Software que utilizan metodología Scrum*.
- Gonzalez, R. C., & Woods, R. E. (2008). Object recognition. *Digital image processing, 3rd ed.* Pearson, 861-909.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Greeshma, K., & Gripsy, J. V. (2020). Image classification using HOG and LBP feature descriptors with SVM and CNN. *Int J Eng Res Technol*, 8(4), 1-4.
- Han, S., Mao, H., & Dally, W. J. (2015). Deep compression: Compressing deep neural networks with pruning, trained quantization and huffman coding. *arXiv preprint arXiv:1510.00149*.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. 770-778.
- Hung, B. T. (2021). *Face recognition using hybrid HOG-CNN approach*. 715-723.
- Jain, A. K., & Li, S. Z. (2011). *Handbook of face recognition* (Vol. 1). Springer.
- Kidger, P., & Lyons, T. (2020). Signatory: Differentiable computations of the signature and logsignature transforms, on both CPU and GPU. *arXiv preprint arXiv:2001.00706*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- Kumar, K., & Mishra, R. K. (2020). A heuristic SVM based pedestrian detection approach employing shape and texture descriptors. *Multimedia Tools and Applications*, 79(29), 21389-21408. <https://doi.org/10.1007/s11042-020-08864-z>
- Lavi, B., Ullah, I., Fatan, M., & Rocha, A. (2020). Survey on reliable deep learning-based person re-identification models: Are we there yet? *arXiv preprint arXiv:2005.00355*.

- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lee, K. W., Sankaran, N., Setlur, S., Napp, N., & Govindaraju, V. (2018). *Wardrobe model for long term re-identification and appearance prediction*. 1-6.
- Lu, X., Li, X., Sheng, W., & Ge, S. S. (2022). Long-term person re-identification based on appearance and gait feature fusion under covariate changes. *Processes*, 10(4), 770.
- Machado de Benedetti, M. (2021). *Renderizado en tiempo real acelerado mediante hardware de ray tracing*.
- Manzoor, S., An, Y.-C., In, G.-G., Zhang, Y., Kim, S., & Kuc, T.-Y. (2023). SPT: Single Pedestrian Tracking Framework with Re-Identification-Based Learning Using the Siamese Model. *Sensors*, 23(10), 4906.
- Matsumura, R., & Hanazawa, A. (2019). Human detection using color contrast-based histograms of oriented gradients. *International Journal of Innovative Computing, Information and Control*, 15(4), 1211-1222.
- Meena, K., & Suruliandi, A. (2011). *Local binary patterns and its variants for face recognition*. 782-786.
- Mihaescu, R.-E., Chindea, M., Paleologu, C., Carata, S., & Ghenescu, M. (2020). Person Re-identification across data distributions based on general purpose DNN object detector. *Algorithms*, 13(12), 343.
- Moctezuma-Ochoa, D. A. (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.
- Montes de Oca, E. S. (2018). *Análisis de consumo energético en Cluster de GPU y MultiGPU en un problema de alta demanda computacional*.
- Moreano, J. A. C., Palomino, N. L. S., & Casa, A. C. L. (2019). Facial recognition techniques using SVM: A comparative analysis. *Enfoque UTE*, 10(3), 98-111.

- Moreira Ramos, D. L. (2021). *Aplicación de un modelo de reconocimiento de objetos utilizando YOLO (you only look once)*.
- Muñoz Villanueva, C. B. (2022). *Algoritmos de reconocimiento facial mediante aprendizaje automático para la identificación de personas en una institución educativa de Pasco-2021*.
- Navarro Clavería, C. F. (2020). *Clasificación de patrones complejos de textura-color mediante extracción de características globales y locales, un clasificador SVM, y post-procesamiento*.
- Nodehi, H., & Shahbahrami, A. (2021). Multi-metric re-identification for online multi-person tracking. *IEEE Transactions on Circuits and Systems for Video Technology*, 32(1), 147-159.
- Nurthohari, Z., Murti, M. A., & Setianingsih, C. (2019). *Wood quality classification based on texture and fiber pattern recognition using hog feature and svm classifier*. 123-128.
- Patrino, C., Marani, R., Cicirelli, G., Stella, E., & D'Orazio, T. (2019). People re-identification using skeleton standard posture and color descriptors from RGB-D data. *Pattern Recognition*, 89, 77-90.
- Pérez Villagómez, D. A., & Velasteguí Asto, A. K. (2023). Sistema de re-identificación de personas a través de las características faciales y soft-biométricas la silueta corporal, utilizando algoritmos de Visión por Computadora y Machine Learning. *Universidad de las Fuerzas Armadas ESPE. ESPEL. Carrera de Ingeniería en Software*.
- Pietikäinen, M. (2005). *Image analysis with local binary patterns*. 115-118.
- Plazas Pirabán, L. A., & Betancur Sanchez, B. S. (2021). *Desarrollo de un algoritmo de re-identificación multi-modal de personas para mejorar la asistencia personalizada en una casa familiar*.
- Quevedo Mora, M. Á. (2021). *Sistema de identificación de personas mediante uso de GAN*.

- Reid, D. A., Samangooei, S., Chen, C., Nixon, M. S., & Ross, A. (2013). Soft biometrics for surveillance: An overview. *Handbook of statistics*, 31, 327-352.
- Sabhanayagam, T., Venkatesan, V. P., & Senthamarai Kannan, K. (2018). A comprehensive survey on various biometric systems. *International Journal of Applied Engineering Research*, 13(5), 2276-2297.
- Salamon, N. Z. (2015). *Re-identificação de pessoas em imagens através de características descritivas de cores e grupos*.
- Sánchez Vidal, L. (2021). *Clasificación automática de señales de tráfico basada en Deep Learning*.
- Schwaber, K., & Sutherland, J. (2020). *La guía definitiva de Scrum: Las reglas del juego*.
- Shi, L., Wang, X., & Shen, Y. (2020). Research on 3D face recognition method based on LBP and SVM. *Optik*, 220, 165157.
- Sims, C., & Johnson, H. L. (2012). *Scrum: A breathtakingly brief and agile introduction*. Dymax.
- Singh, N. K., Khare, M., & Jethva, H. B. (2022). A comprehensive survey on person re-identification approaches: Various aspects. *Multimedia Tools and Applications*, 81(11), 15747-15791.
- Song, W., Li, S., Chang, T., Hao, A., Zhao, Q., & Qin, H. (2019). Context-interactive CNN for person re-identification. *IEEE Transactions on Image processing*, 29, 2860-2874.
- Surasak, T., Takahiro, I., Cheng, C., Wang, C., & Sheng, P. (2018). *Histogram of oriented gradients for human detection in video*. 172-176.
- Tuapanta, L., David, L., Tandalla, P., Vinicio, R., Medina, C., & Luis, J. (2023). *Textura de la , y modelos holísticos y no holísticos, utilizando algoritmos de Visión por Computadora y Machine Learning*.
- Turner, J. (2020). *Kanban: The Ultimate Beginner's Guide to Learn Kanban Step by Step*. Publishing Factory.
- Ultralytics. (2023). *Home*. <https://docs.ultralytics.com/>

- Verdeguer Valderrama, D. C. (2022). *Diseño e implementación de un sistema de identificación de personas para la seguridad de los accesos a condominios, basado en el algoritmo de reconocimiento facial LBPH Faces.*
- Wang, K., Wang, H., Liu, M., Xing, X., & Han, T. (2018). Survey on person re-identification based on deep learning. *CAAI Transactions on Intelligence Technology*, 3(4), 219-227.
- Wang, Y., Li, L., Yang, J., & Dang, J. (2021). Re-identificación de personas basada en mecanismo de atención y en ponderación adaptativa. *DYNA*, 96(2), 186-193.
- Wu, W., Tao, D., Li, H., Yang, Z., & Cheng, J. (2021). Deep features for person re-identification on metric learning. *Pattern Recognition*, 110, 107424.
- Ye, M., Shen, J., Lin, G., Xiang, T., Shao, L., & Hoi, S. C. (2021). Deep learning for person re-identification: A survey and outlook. *IEEE transactions on pattern analysis and machine intelligence*, 44(6), 2872-2893.
- Yunga Pedraza, J. O. (2023). *Estudio del estado del arte sobre la predicción de deserción universitaria usando machine learning.*
- Zhang, H., Qu, Z., Yuan, L., & Li, G. (2017). A face recognition method based on LBP feature for CNN. 544-547.
- Zhang, K., Zuo, W., Chen, Y., Meng, D., & Zhang, L. (2017). Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising. *IEEE transactions on image processing*, 26(7), 3142-3155.
- Zheng, H., Fu, J., Mei, T., & Luo, J. (2017). *Learning multi-attention convolutional neural network for fine-grained image recognition.* 5209-5217.
- Zubiaga, A., Fresno, V., & Martínez, R. (2009). Comparativa de Aproximaciones a SVM Semisupervisado Multiclase para Clasificación de Páginas Web. *Procesamiento del lenguaje natural*, 42, 63-70.

Anexos