

**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**

Tema: 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.

Autores:

**Lema Velásquez, Steven Alexander
Robayo Bastidas, Alex Xavier**

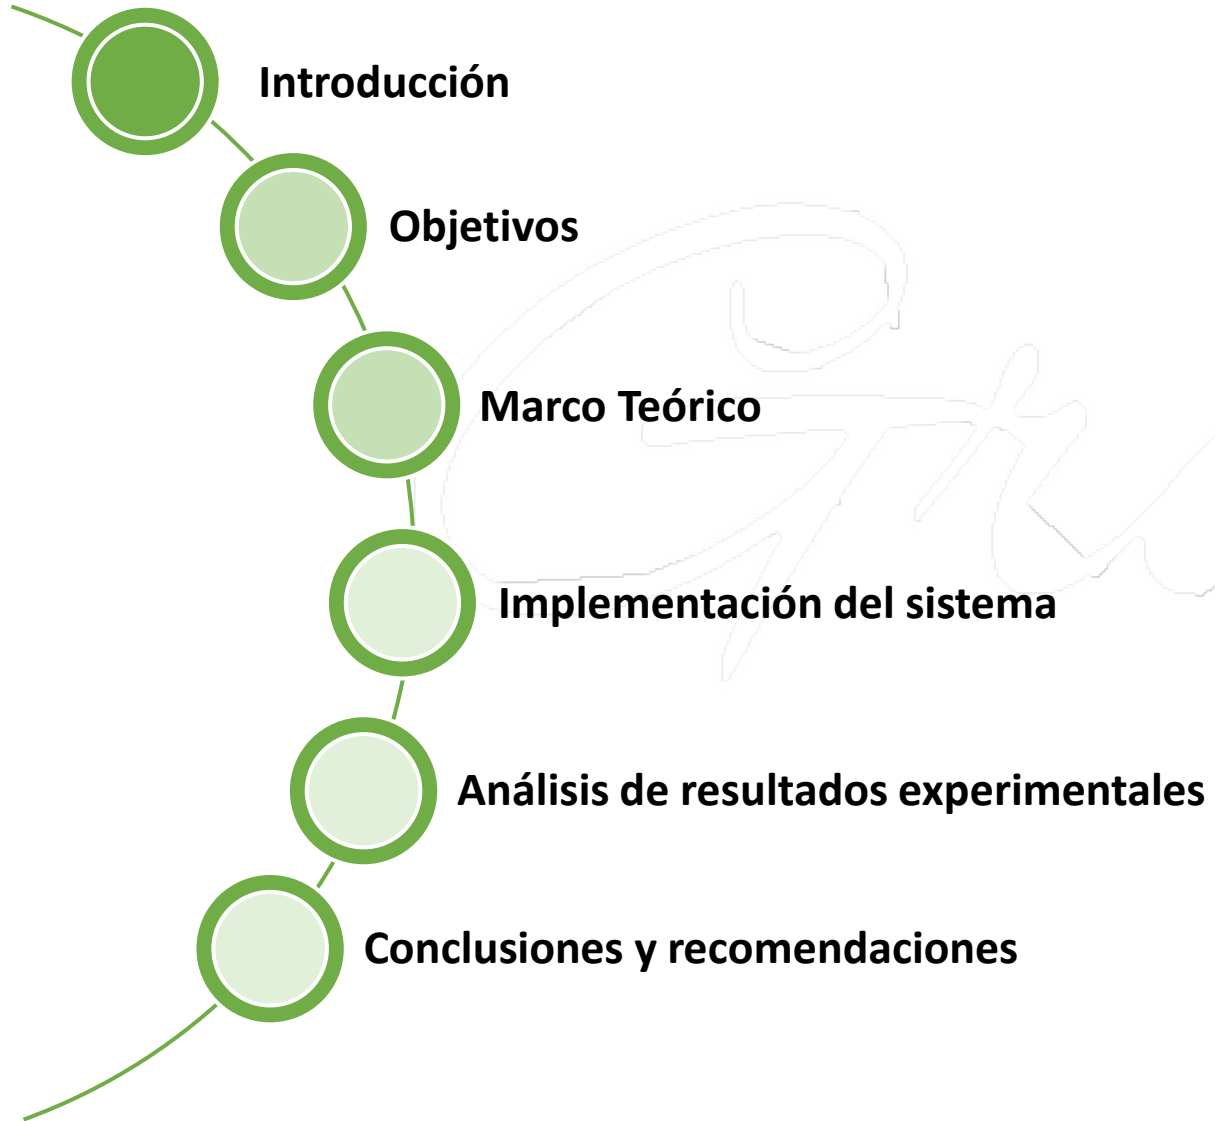
DIRECTOR:

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

**Latacunga
Agosto, 2023**



CONTENIDO



INTRODUCCIÓN

Problema

Se necesita un análisis comparativo de métodos basados en visión por computadora y aprendizaje automático, usando características biométricas en arquitecturas potentes como CPU y GPU.



INTRODUCCIÓN

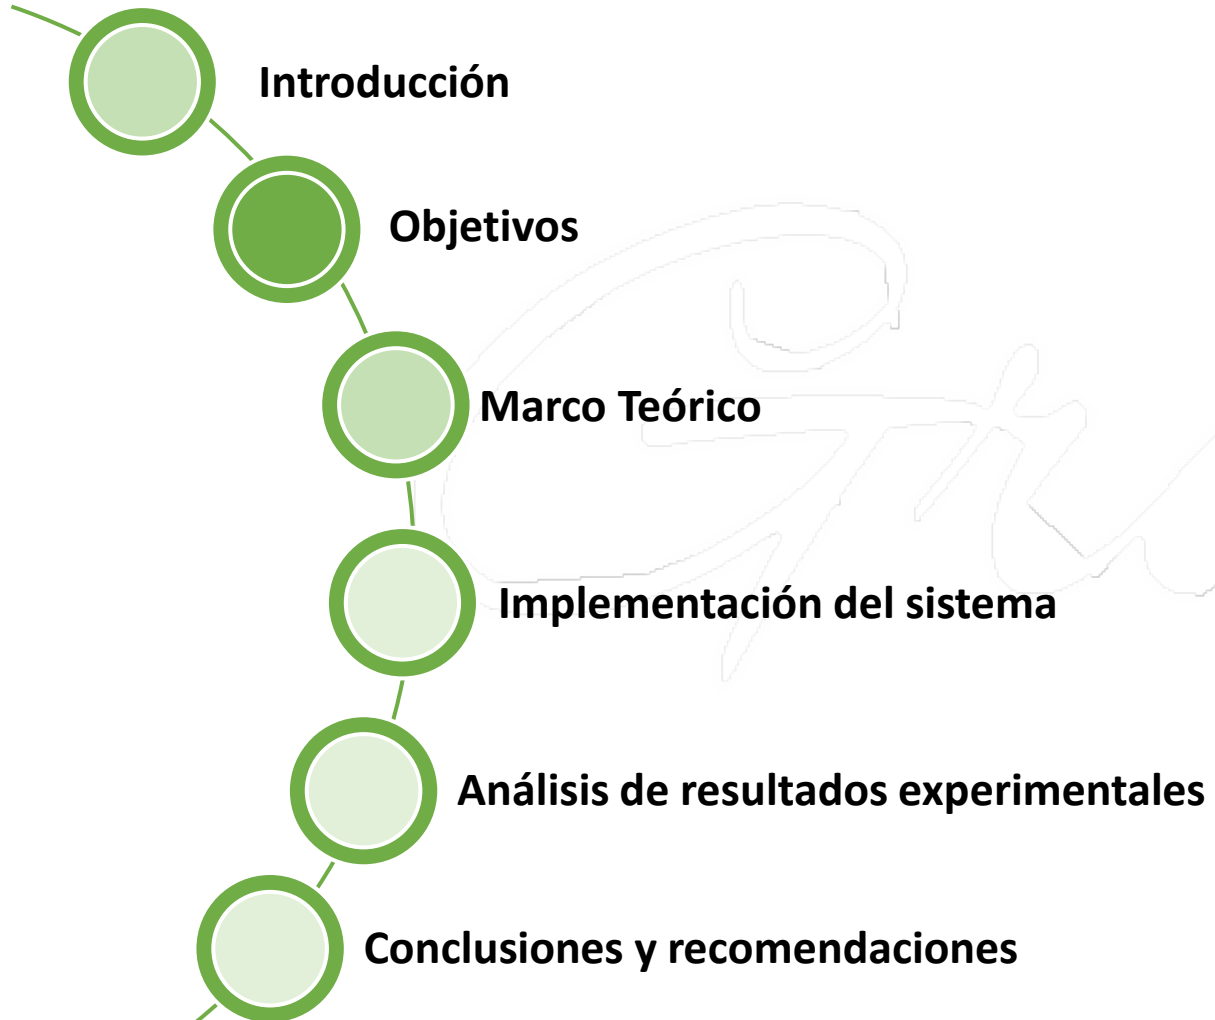


Solución

Es necesario evaluar el rendimiento de diferentes modelos y algoritmos utilizando arquitecturas de altas prestaciones.



CONTENIDO



OBJETIVOS 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.



OBJETIVOS ESPECÍFICOS

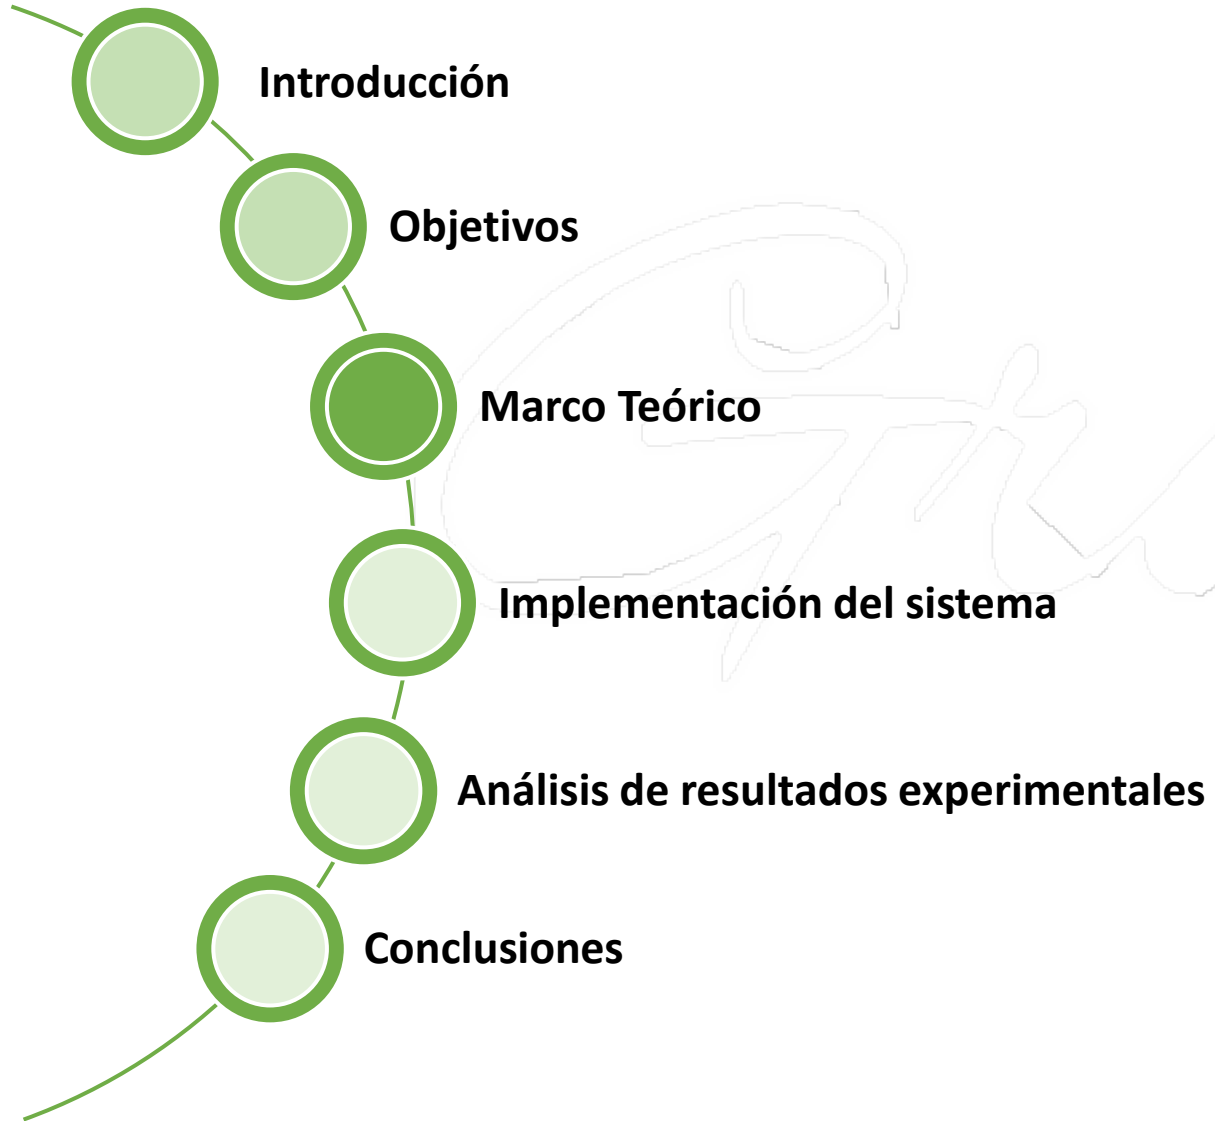
Conocer y estudiar las características biométricas: facial y soft-biométricas: silueta corporal, textura y color de la ropa, aplicando técnicas LBP y HoG de Visión por Computadora y modelos de SVM, CNN y DNN de Machine o Deep Learning, que son utilizadas en la Re-Identificación de personas.

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.



CONTENIDO




Re-Identificación de personas

Identificar y dar seguimiento a una persona por medio de cámaras




Características biométricas

Son rasgos específicos de un individuo que se utilizan con fines de identificación y autenticación.




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



Características soft-biométricas

También conocidas como cualidades sociales o de comportamiento, para complementar la información biométrica tradicional.

Basan su análisis en atributos como la silueta corporal, el color y textura de la ropa



Técnicas de Visión por Computador y modelos de Machine Learning

Técnicas de Visión por computadora

- LBP(Local Binary Pattern)
- HoG (Histogram of Orient Gradient)

Técnicas modelos y/o algoritmos

- SVM (Support Vector Machine)
- CNN (Convolutional Neural Network)
- DNN (Deep Neural Network)

Modelos de Machine Learning


YOLOv8 (You Only Look Once)



Arquitecturas de altas prestaciones CPU y GPU


CPU

Son procesadores diseñados específicamente para realizar tareas que van desde el cálculo matemático a la gestión de dato

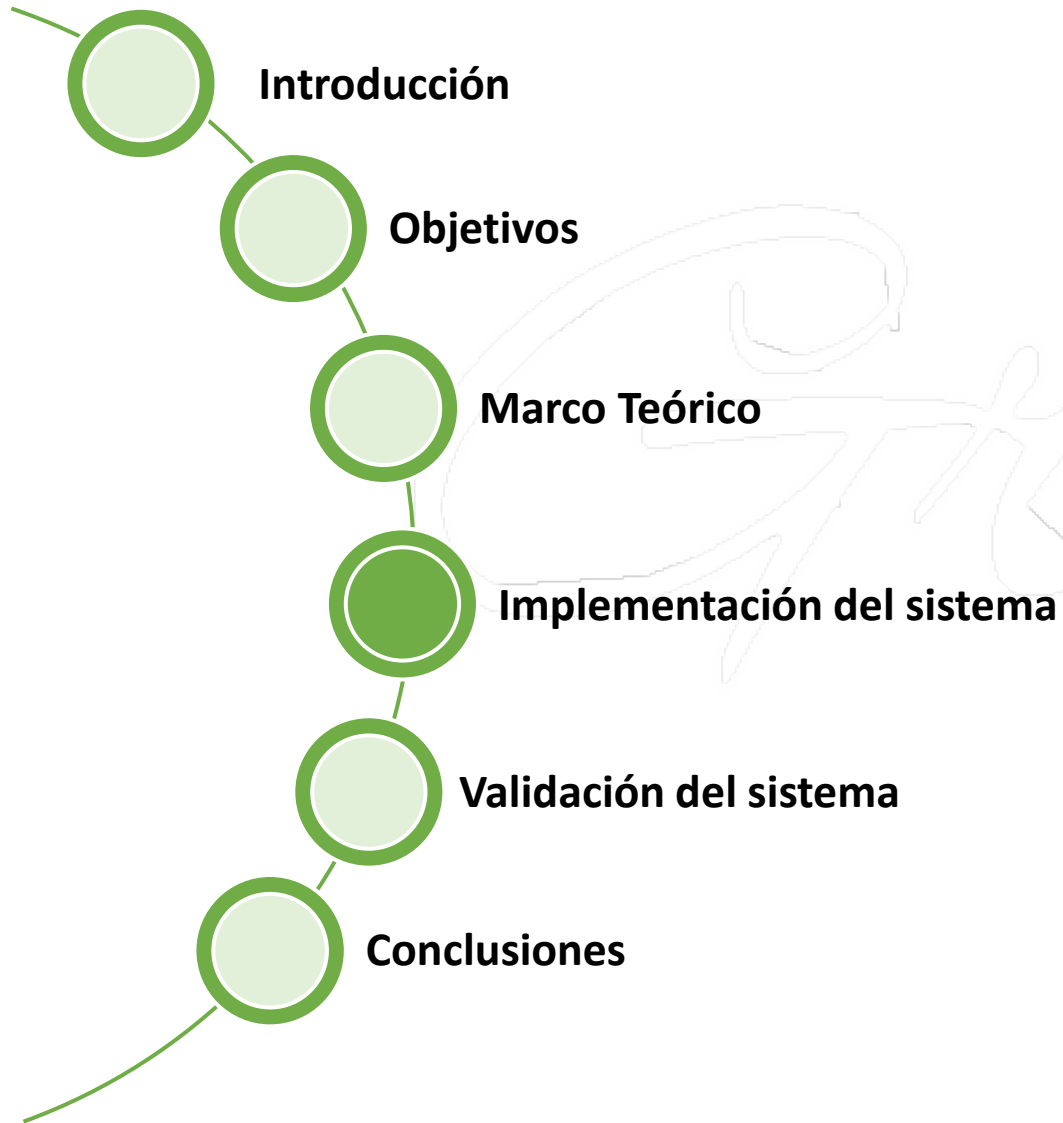


GPU

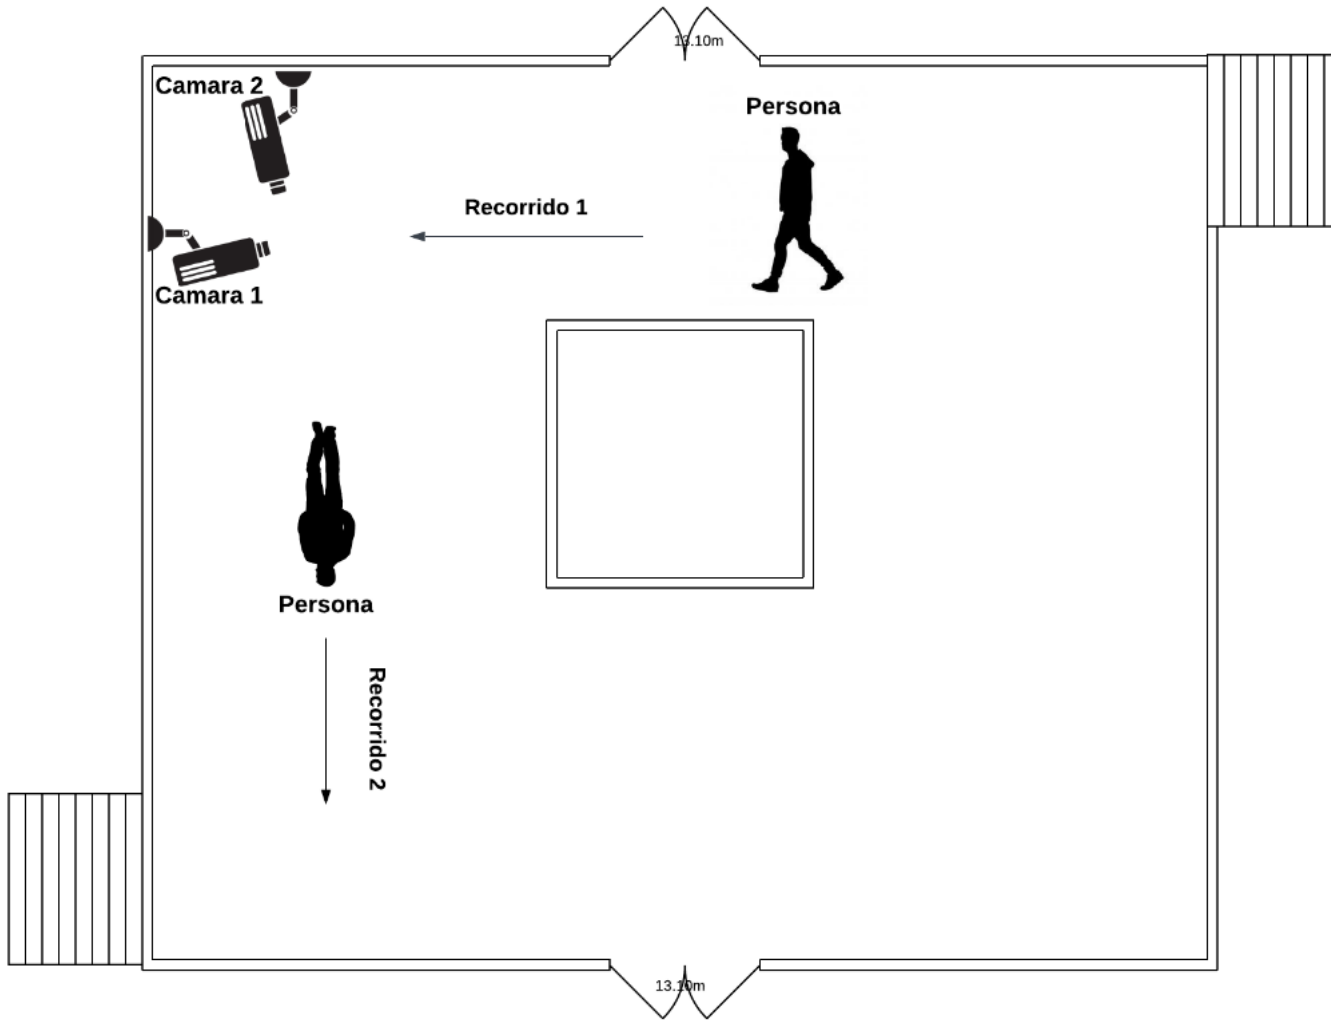
Es una unidad de procesamiento especializada diseñada para realizar cálculos gráficos y matemáticos intensivos de manera altamente paralela



Contenido



ARQUITECTURA LÓGICA DEL SISTEMA



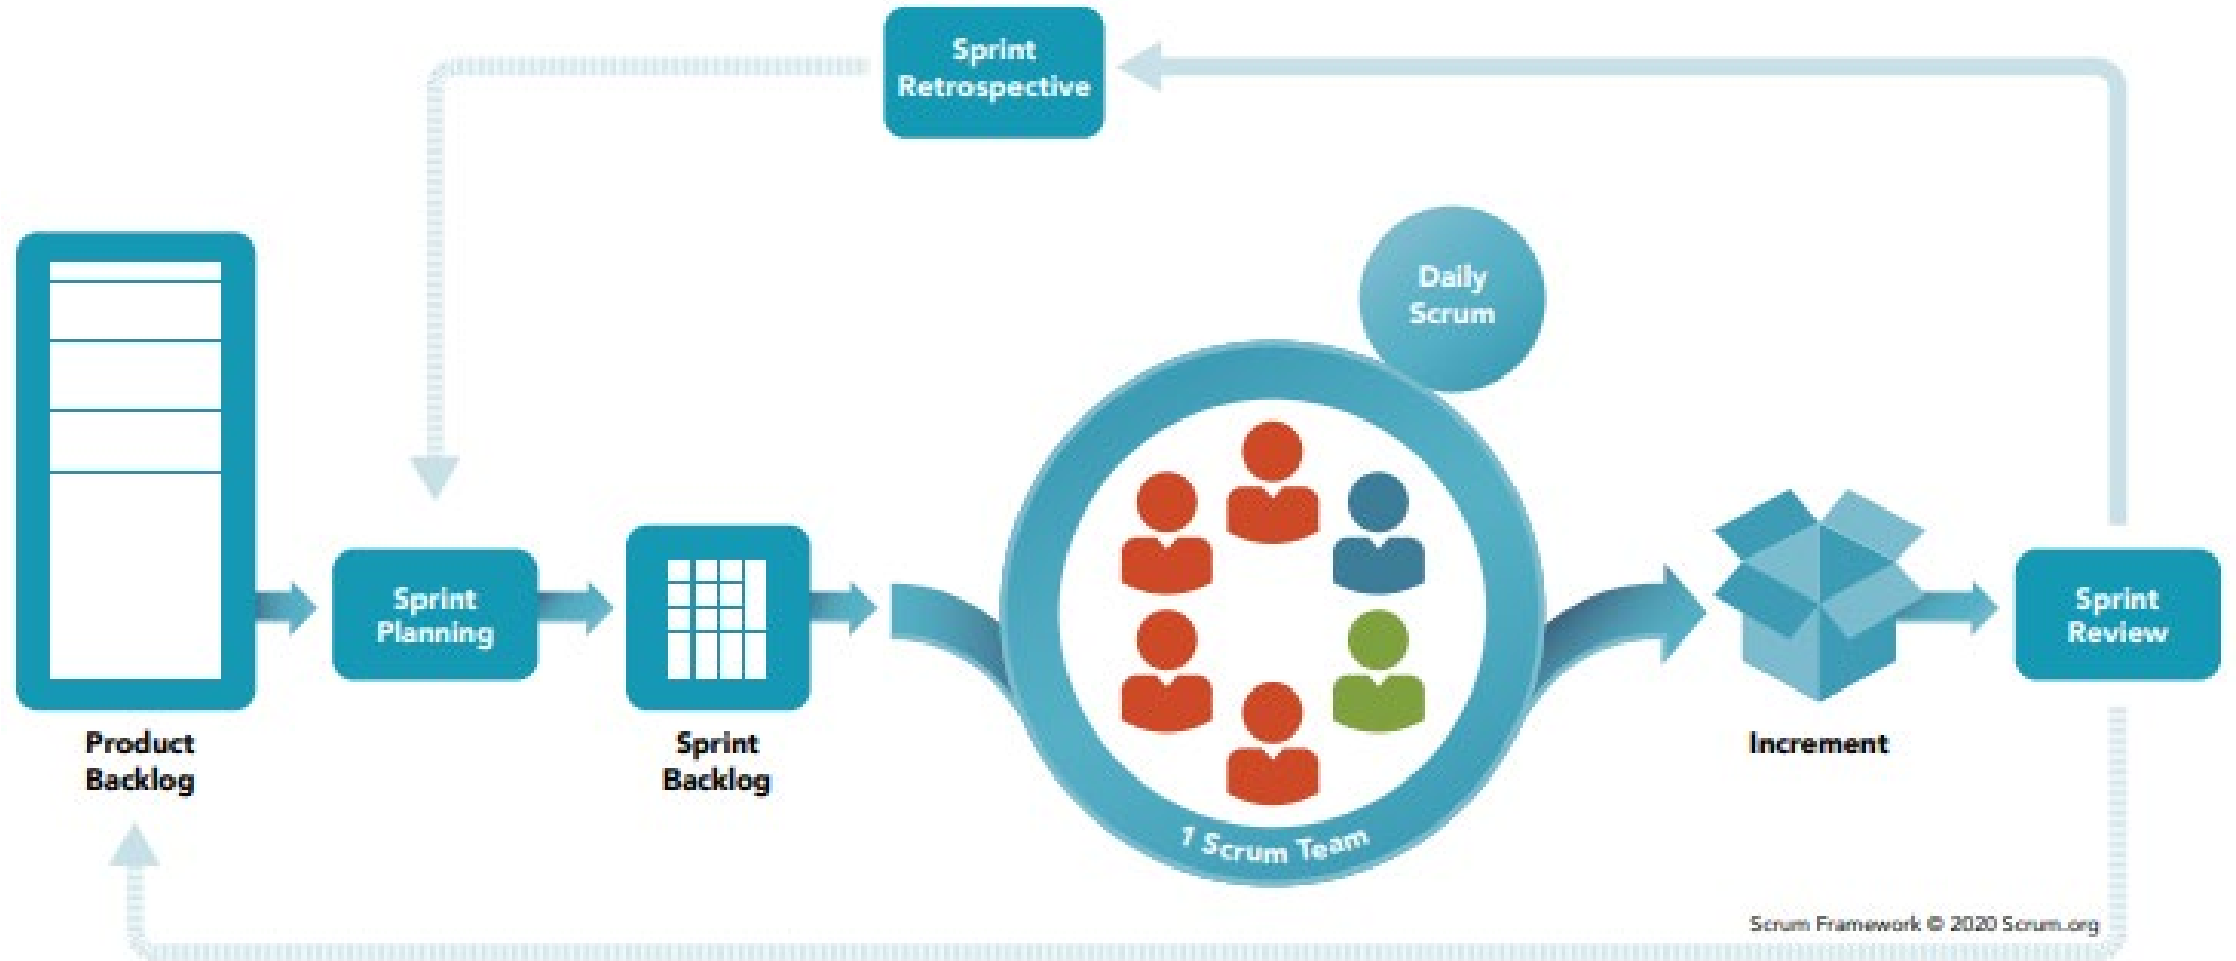
**Pasillos de la
Universidad de las
Fuerzas Armadas
ESPE Sede Latacunga**



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA

Metodología de desarrollo

Esquema de la metodología Scrum



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.

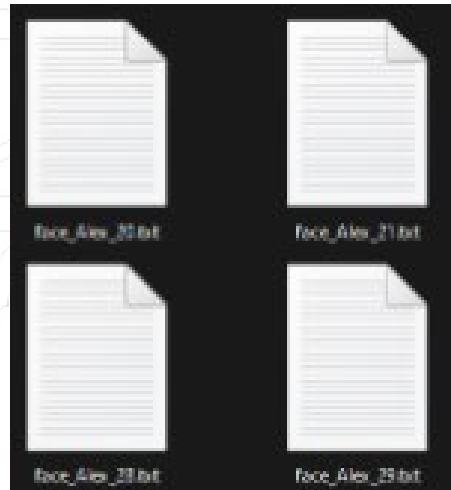


Sprint 1


Obtención de dataset de rostros



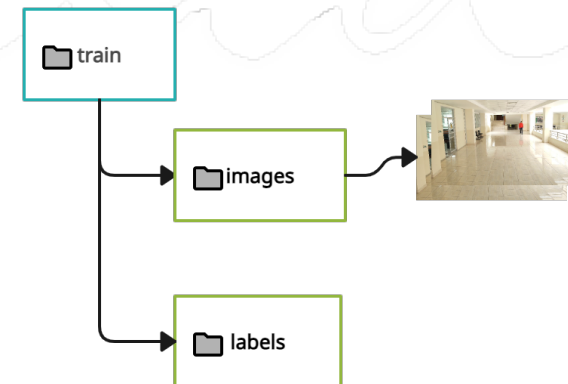
Entrenamiento



Etiquetado



Etiqueta

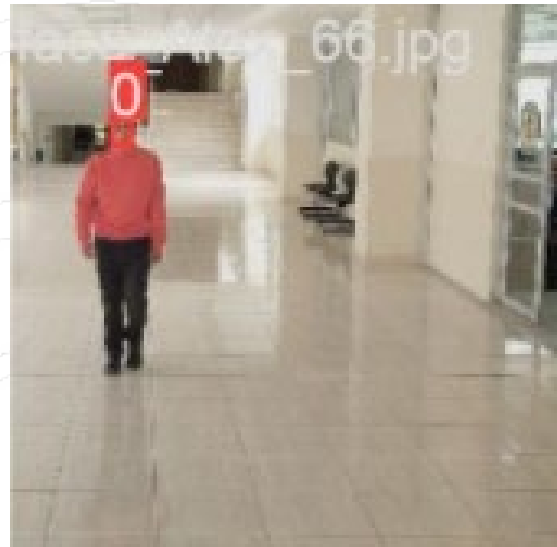



Carpetas



Sprint 1

Implementación de modelos de identificación facial




Entrenamiento

Identificación

Sprint 1

Comparación de modelos de identificación facial – Precision

Descriptor		Identificación Facial					
		LBP			HOG		
Clasificador	SVM	DNN	CNN	SVM	DNN	CNN	
	Positivos	Negativos	Positivos	Negativos	Positivos	Negativos	
Positivos	155	4	182	0	174	3	
Negativos	2	5	0	0	0	0	



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




Sprint 2

Creación de datasets de silueta corporal, textura y color de la ropa



Sprint 2


Implementación de modelos de Re-identificación de personas (combinación de características soft-biométricas: silueta corporal, textura y color de la ropa)



Sprint 2

Implementación de modelos de Re-identificación de personas

Descriptor Clasificador	Re-Identificación Silueta				Re-Identificación Textura						Re-Identificación Color									
	LBP				LBP			HOG			LBP		HOG							
	DNN		CNN		DNN	CNN	SVM	DNN	CNN	SVM	DNN	CNN	DNN	CNN						
	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



Características soft-biométricas	Silueta Corporal		Textura de la Ropa					Color de la Ropa		
	LBP		LBP		HoG			LBP	HoG	
	DNN	CNN	DNN	CNN	SVM	DNN	CNN	SVM	DNN	CNN
Métricas	DNN	CNN	DNN	CNN	SVM	DNN	CNN	SVM	DNN	CNN
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



Sprint 2

Implementación de modelos capaces de Re-identificar personas al combinar características soft-biométricas: 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 <u>HoG</u> Color <u>HoG</u>	Silueta LBP Textura <u>HoG</u> Color <u>HoG</u>	Silueta LBP Textura <u>HoG</u> Color <u>HoG</u>
Descriptor	SVM	CNN	DNN
Precisión	0,59	0,76	0,79



Sprint 3

Comparación de procesamiento CPU y GPU – Tiempos de entrenamiento

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

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



Sprint 3

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

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



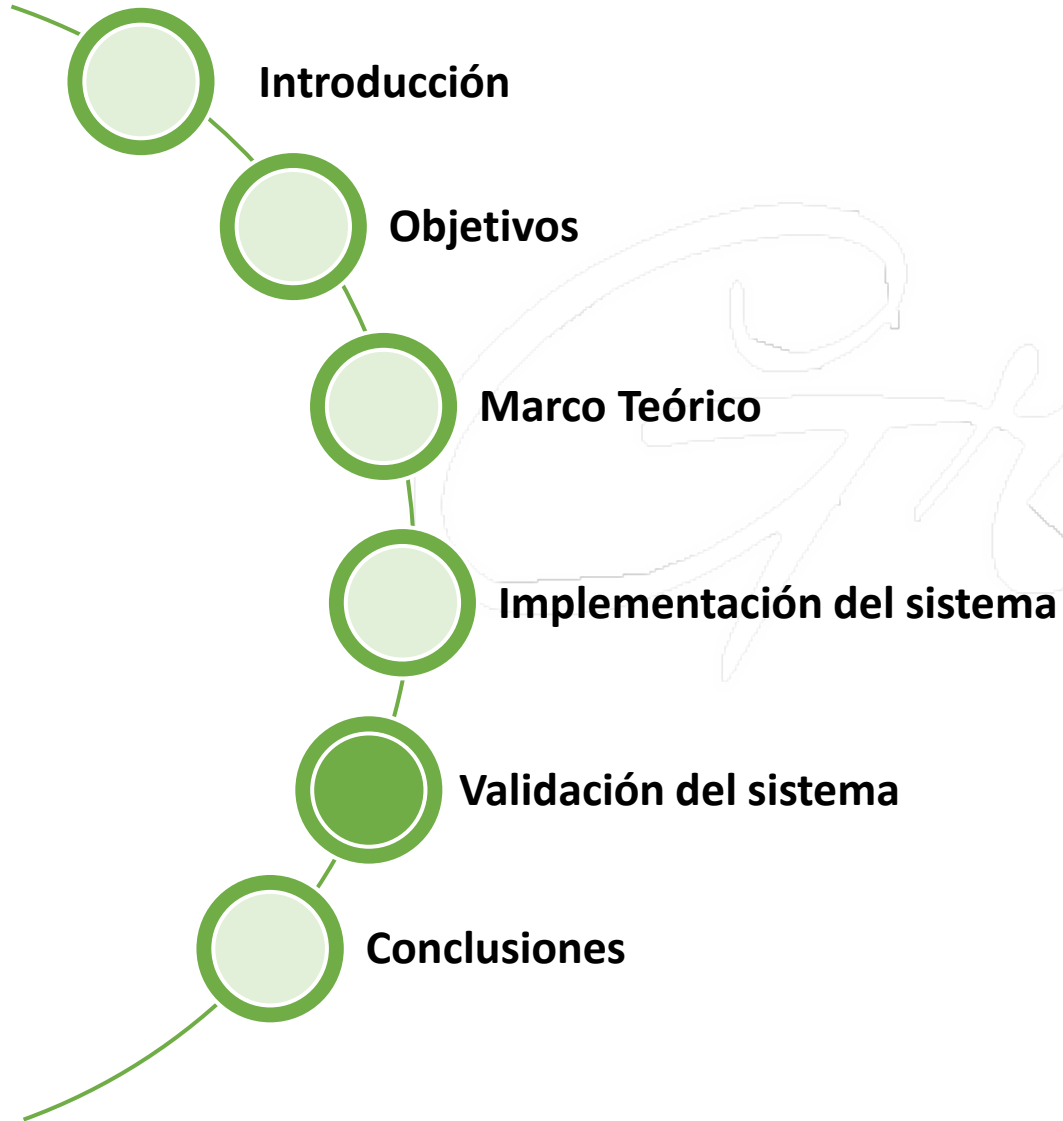
Sprint 3

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

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%



Contenido



Validación

Pruebas del algoritmo de identificación facial



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



Validación

Pruebas del algoritmo de Re-Identificación de personas a través de los descriptores de silueta corporal, textura y color de la ropa y de los clasificadores SVM, CNN y DNN



Escenario		Cámara 2, segundo pasillo, hora: 11:30 am								
Descriptor	Re-Identificación Silueta			Re-Identificación Textura			Re-Identificación Color			
	LBP		LBP	HOG		HOG		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




Validación

Pruebas del algoritmo de Re-Identificación de personas a través de la combinación de los descriptores de silueta corporal, textura y color de la ropa y de los clasificadores SVM, CNN y DNN

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



Validación

Comparación de procesamiento CPU y GPU – Precisión

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



Descriptor	Clasificador	CPU	GPU	Literatura Científica	
		Precisión	Precisión	Precisión mínima	Precisión máxima
Silueta LBP	SVM	62,04±2,51	62,04±2,51	33,30%	86,53%
Textura					
HoG					
Color HoG					
Silueta LBP	DNN	70,04±1,51	70,04±1,51	33,30%	86,53%
Textura					
HoG					
Color HoG					
Silueta LBP	CNN	66,01±1,41	66,01±1,41	33,30%	86,53%
Textura					
HoG					
Color HoG					




Validación

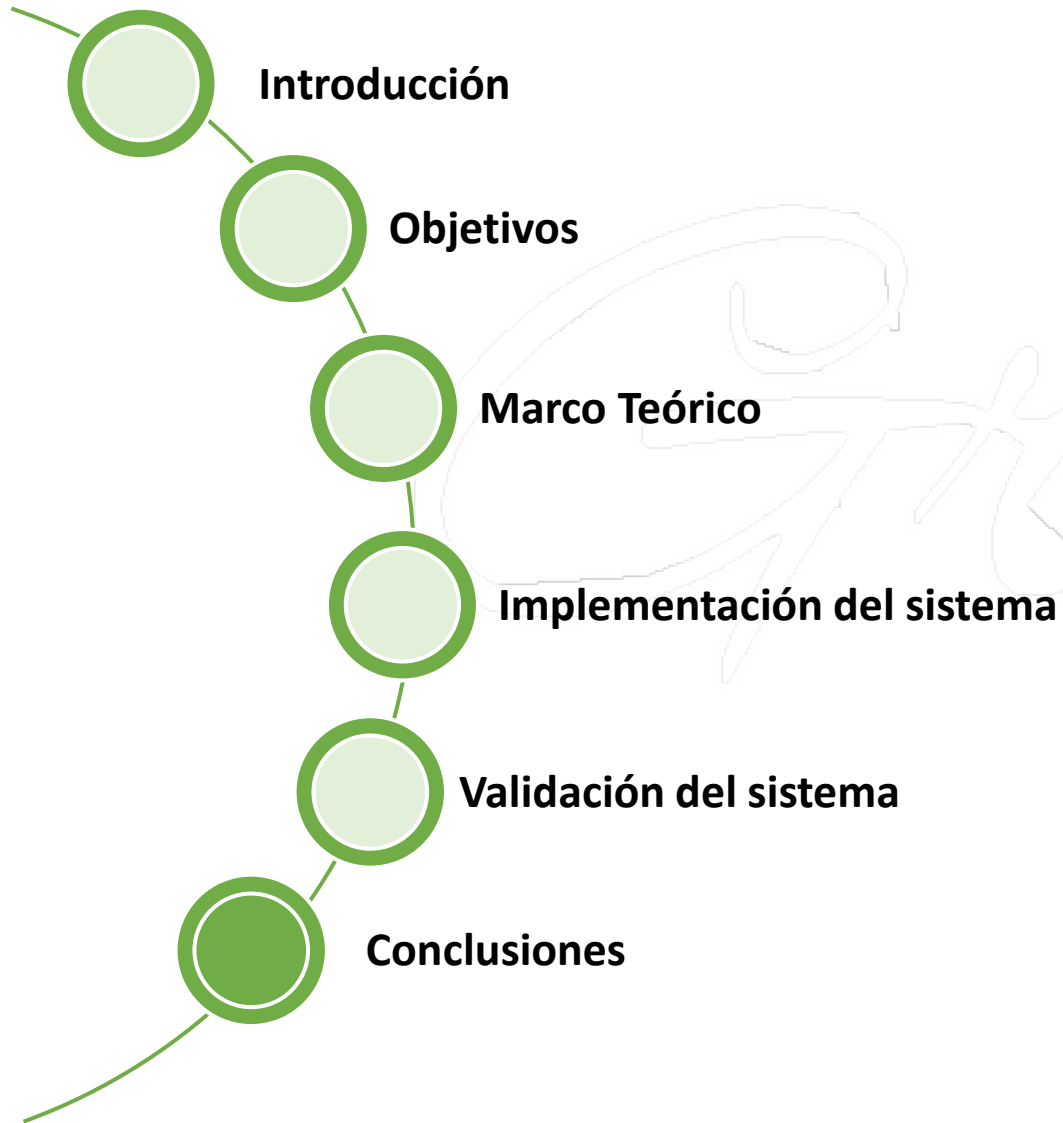
Comparación de procesamiento CPU y GPU – Tiempos de entrenamiento

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

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



Contenido



CONCLUSIONES

Se obtuvo información acerca de diversas técnicas avanzadas computacionales que fueron esenciales para la implementación del sistema de Re-Identificación de personas.

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.



CONCLUSIONES

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.

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



CONCLUSIONES

Se logró la combinación más efectiva de descriptores, como la silueta (LBP), textura y color (HoG), junto con el clasificador DNN, resultando en una precisión de alrededor del $0,86 \pm 0,1$. Esta cifra se sitúa en el rango de precisiones encontrado en la literatura investigada, que abarca desde un mínimo de 33,3% (Nodehi & Shahbahrami, 2021) hasta un máximo del 86,53% de re-identificación (Greeshma & Gripsy, 2020).

La GPU es más eficiente que la CPU para tareas gráficas. En el entrenamiento de identificación facial, la CPU necesita $9,61 \pm 0,27$ segundos, mientras que la GPU solo emplea $4,53 \pm 0,01$ segundos, siendo 5,08 segundos más rápida. En el entrenamiento con características soft-biométricas y el uso de DNN, la GPU tarda $1,19 \pm 0,13$ segundos, en comparación con los $2,09 \pm 0,4$ segundos de la CPU. La GPU destaca por su velocidad y eficiencia.



¡Gracias!



ESPE
UNIVERSIDAD DE LAS FUERZAS ARMADAS
INNOVACIÓN PARA LA EXCELENCIA