Universidad Europea VALENCIA

GRADO EN CIENCIA DE DATOS

Implementación de un Sistema de Monitoreo para la detección de actividad en videos con Aplicaciones de Seguridad

Presentado por:

PABLO CAMPOS CHOLBI

Dirigido por:

JAVIER PEREZ PEREZ

CURSO ACADÉMICO 2024-2025

ÍNDICE

ÍNDICE DE FIGURAS

1.RESUMEN

Este trabajo fin de grado contiene el diseño y la implementación de un sistema automático para la detección de actividad de vídeo, con aplicaciones vinculadas a la seguridad. Para obtener el sistema se han seguido las técnicas más actuales de visión por computador, término que hace referencia a la utilización del modelo YOLOv8 para la detección objetos, y el algoritmo ORB para la detención de puntos clave en fotogramas diferentes. Se ha desarrollado una arquitectura modular, la opción más apropiada para procesar vídeos en tiempo real, permitiendo detectar sucesos de un cierto interés como podría ser la detención del movimiento de personas o de objetos que pueden producirse en las condiciones ambiéntales que el sistema necesita. A través de las pruebas ejecutadas por medio de vídeos se demostró la viabilidad técnica del sistema junto con sus limitaciones principales a las que se enfrenta, especialmente en el caso de escenarios con situaciones de escasa luz. El desarrollo del proyecto ha permitido confirmar que es posible llegar a la realización de sistemas de monitoreo para alcanzar un futuro desarrollo de mejoras en cuanto a la fiabilidad, eficiencia y adaptabilidad a diferentes entornos.

PALABRAS CLAVE: Aplicaciones de seguridad, ORB (ORIENTED Fast and ROTATED Brief)**,** Visión por computadora**,** YOLO**,** Detección de actividad.

ABSTRACT

This final degree work contains the design and implementation of an automatic system for the detection of video activity, with applications related to security. To obtain the system we have followed the most current techniques of computer vision, a term that refers to the use of the YOLOv8 model for object detection, and the ORB algorithm for stopping key points in different frames. A modular architecture has been developed, it seems to be the most appropriate architecture to process videos in real time, allowing to detect events of a certain interest as it could be the stop of the movement of people or objects that can occur in the environmental conditions that the system needs. The technical feasibility of the system was demonstrated through video tests, together with the main limitations it faces, especially in the case of low-light scenarios. The development of the project has confirmed that it is possible to reach the realization of monitoring systems to reach a future development of improvements in terms of reliability, efficiency and adaptability to different environments.

KEYWORDS: Security Applications, ORB (ORIENTED Fast and ROTATED Brief), Computer Vision, YOLO, Video Activity Detection

2. INTRODUCCIÓN

La seguridad se ha convertido en un tema muy importante en los últimos años, debido a la creciente preocupación por la seguridad y el incremento de actos delictivos. Para intentar combatir esto se han aplicado los sistemas de videovigilancia, facilitando el monitoreo en tiempo real o directo de áreas críticas en videos o imágenes. Debido a la gran cantidad de datos a estudiar en los videos para poder detectar y vigilar correctamente, hay muchos casos en los que entra el factor humano, lo que conlleva errores y fallos en la vigilancia. Para luchar contra esto se han aplicado inteligencia artificial, redes neuronales y detectores como ORB o YOLO para detectar automáticamente sin el error humano.

El uso de estas aplicaciones ha mejorado el uso de la visión computacional y la automatización de los procesos en la videovigilancia. Las redes convolucionales (CNN) han demostrado su eficacia en la identificación y categorización de objetos en tiempo real. Además, se utilizan modelos como YOLO o ORB para la identificación rápida de objetos en videos o imágenes. el modelo empleado es el algoritmo ORB (Oriented FAST and Rotated BRIEF), que resulta eficaz y veloz para identificar y detallar características fundamentales en las imágenes. ORB no necesita entrenamiento previo y funciona correctamente con objetos que muestran rotaciones y variaciones de escala. Es perfecto para estas aplicaciones, ya que se ajusta a la detección de movimiento sin requerir entrenamiento en un gran conjunto de datos.

3. MOTIVACIÓN

La principal motivación de este trabajo es intentar automatizar los procesos de monitoreo para detectar actividad en videos o imágenes a través de las herramientas ya mencionadas. El objetivo es mejorar en aplicaciones de seguridad ya que para que un ser humano vigile correctamente se necesita mucho tiempo lo que provocará fallos humanos en una cuestión tan importante como la seguridad. Con la ayuda de los modelos se evitarán los errores humanos y por lo tanto se mejorará la detección de actividad en los campos de seguridad.

El propósito principal de este trabajo es crear un sistema de alerta de movimiento en videos que resulte eficaz y seguro. La motivación surge de la necesidad de automatizar la identificación de sucesos en videos de seguridad o seguimiento sin la necesidad de examinar cada frame de manera manual. Mediante el estudio de características fundamentales y el cálculo de desplazamientos, se aspira a ofrecer un sistema que pueda identificar modificaciones relevantes de manera exacta. Esto se podría utilizar en una gran variedad de situaciones, por ejemplo, seguridad o supervisión en zonas urbanas o protección de bienes privados.

4. OBJETIVOS

El propósito de este Trabajo de Fin de Grado es crear e instalar un sistema de monitoreo automático que comprende el nivel de actividad visible en un video. Actualizado para estar a la vanguardia del campo basado en cámara, el sistema tiene que ser apto para analizar secuencias en vivo de la cámara enfocándose en buscar objetos específicos, o una persona.

Partiendo del objetivo general, se pueden definir los siguientes objetivos específicos con los cuales se estructura el desarrollo del proyecto:

Investigar y seleccionar técnicas de visión por computador aplicables a la detección de actividad: Con este objetivo se busca explorar y comparar distintos enfoques que existen en la actualidad para detectar movimiento y objetos en los videos, y seleccionar una combinación eficiente de estas en función de la precisión y el rendimiento computacional.

Implementación de un sistema modular para análisis de video en Python. Un video debe ser cargado en un sistema, un modelo de detección de objetos debe ser aplicado al video, el movimiento debe ser analizado usando puntos clave del movimiento ORB, y el sistema debe producir una visualización para el usuario y calcular métricas cuantitativas para la posterior evaluación. Asimismo, valorar y estudiar el rendimiento en diferentes escenarios. Por último, proponer mejoras futuras y posibles extensiones del sistema.

Además de los objetivos técnicos y funcionales, este proyecto pretende contribuir a los Objetivos de Desarrollo Sostenible (ODS), especialmente en lo relativo a la seguridad, sostenibilidad urbana y uso responsable de tecnologías. En particular, se alinea con los ODS 9 (industria, innovación e infraestructura), ODS 11 (ciudades y comunidades sostenibles) y ODS 16 (paz, justicia e instituciones sólidas), tal y como se detalla en una sección posterior.

5. MARCO TEÓRICO

La inteligencia artificial ha transformado totalmente el sector de la seguridad, ayudando con herramientas avanzadas para la detección de eventos sospechosos y para la videovigilancia. Los sistemas de seguridad solían basarse en la supervisión humana y en detección de movimiento, pero esto contaba con varias restricciones, como el gran número de alarmas falsas debido a el error humano. Esto ha provocado que se apliquen la Inteligencia Artificial y redes neuronales para mejorar estos sistemas de vigilancia y por lo tanto que sean más exactos y eficaces. Las Redes Neuronales Convolucionales (CNN) han sido utilizadas ampliamente en el tratamiento de imágenes y en la identificación de objetos en estas imágenes. Las CNN intentan copiar el comportamiento visual humano utilizando diferentes capas para obtener las características de las imágenes. Las CNN cuentan con varias capas fundamentales para tener en cuenta como son;

Convolución: Aplica un conjunto de filtros convolucionales a las imágenes de entrada; cada filtro activa diferentes características de las imágenes.

Unidad lineal rectificada (ReLU): Mantiene los valores positivos y establece los valores negativos en cero, lo que permite un entrenamiento más rápido y eficaz. También se lo conoce como *activación*, ya que solo las características activadas prosiguen a la siguiente capa. (MathWorks, s. f.).

Agrupación: Simplifica la salida mediante reducción no lineal de la tasa de muestreo, lo que disminuye el número de parámetros que la red debe aprender. (MathWorks, s. f.).

YOLO es un modelo CNN que se basa en la detección de objetos en imágenes, se caracteriza por detectar los objetos en una única pasada lo que lo convierte en un procedimiento muy veloz. Este modelo cuenta con muchos beneficios como son la velocidad, precisión y eficiencia computacional. Este modelo es capaz de identificar a una gran velocidad, lo que facilita la identificación en tiempo real. Además, cuenta con pocos fallos en la identificación de objetos y por lo tanto minimiza la repetición en la detección de objetos. YOLO simplifica la aplicación en sistemas en tiempo real ya que cuenta con exactitud y optimización en la utilización de recursos. El algoritmo ORB se basa en la detección y descripción de las características en imágenes, este algoritmo cuenta con dos métodos clave. FAST (Se encarga de detectar puntos clave en las imágenes analizando los contrastes) y BRIEF (Genera descriptores de esos puntos

clave para para poder compararlos a cambios de iluminación y escala.) ORB se centra en identificar cambios en la escena a través del análisis de características locales, lo que permite detectar movimiento, aunque el objeto no sea reconocido. El proceso de ORB se basa en la extracción de puntos clave en cada frame utilizando el detector FAST, que se encarga de identificar zonas como bordes o esquinas. Además, los puntos clave se asocian con un descriptor utilizando BRIEF, que resume la información visual. Al extraer los puntos clave de dos frames consecutivos, el sistema compara los descriptores utilizando un emparejador para encontrar coincidencias. El numero de emparejamientos representa el nivel de actividad/movimiento entre los dos frames consecutivos. Es decir, si hay muchos puntos clave coincidentes en posiciones distintas, ha habido un cambio en la escena. Por lo tanto, si no hay coincidencias nuevas la escena estará estática. Este recuento de coincidencias permite detectar movimiento incluso cuando YOLO no detecta nuevos objetos, por ejemplo, escenas con baja iluminación u oclusiones parciales. Este algoritmo es utilizado para aplicaciones en tiempo real ya que es un algoritmo muy rápido y eficiente. Por lo tanto, cuenta con varias aplicaciones en seguridad como son la detección de actividad inusual en videos comparando las variaciones en los fotogramas de las imágenes. Además de monitoreo de objetos en videos con la identificación de puntos de referencia y la coincidencia de características.

YOLO tiene muchas aplicaciones en seguridad, pero algunas de las más utilizadas son la vigilancia en transporte público y en aeropuertos. Otra aplicación común es la identificación de conductas inusuales en eventos de gran escala además del control de infraestructuras vitales. Por último, un uso común de YOLO en aplicaciones de seguridad es la regulación del acceso en lugares restringidos. La eficiencia del modelo para identificar el movimiento en aplicaciones de seguridad e identificación de objetos se evaluará con diferentes métricas como son el Promedio de Precisión Media, el recall y exactitud y por el último los FPS.

Promedio de Precisión Media (mAP): Analiza la precisión del modelo.

Recall y exactitud: Examinan la habilidad para identificar sin producir falsos positivos.

FPS (Frames Cada Segundo): Establece la rapidez de procesamiento.

6. METODOLOGÍA

Para entrenar el modelo del proyecto, se utilizarán distintas bases de datos de videovigilancia. Por lo tanto, se llevará a cabo varias operaciones para el procesamiento y filtrado de la información. Para esto se utilizará YOLO para identificar los objetos en los videos, OpenCV para manejar los videos e imágenes y por último ORB para encontrar descriptores relevantes y monitorear los cambios en la escena. El modelo YOLO empleado se basa en la versión yolov8n preentrenada, proporcionada por la librería Ultralytics. Dicho modelo ha sido entrenado originalmente sobre el dataset COCO (Common Objects in Context), un conjunto de más de 300.000 imágenes anotadas que contiene 80 clases de objetos comunes. Esta base permite al modelo reconocer de forma precisa elementos como personas, vehículos, bolsos y otros objetos cotidianos. Para evaluar el modelo se utilizarán varias medidas como las detecciones YOLO o coincidencias ORB para proporcionar una medida de la precisión del modelo, la tasa de falsos positivos y falsos negativos y una serie de prueba con videos reales para comprobar el correcto funcionamiento del modelo. Para llevar a cabo las pruebas con videos reales, se realizará una interfaz capaz de utilizar y cargar videos en directo y además que salten alertas automáticas para alertar de la detección de movimiento y actividad sospechosa. Para el entrenamiento se tomará en cuenta varios factores como; el Batch size que tiene en cuenta las dimensiones del conjunto de datos por iteración y el número de épocas que cuenta la cantidad de veces que el modelo examinara los datos. Para estudiar los resultados se realizará un estudio exhaustivo considerando posibles mejoras como la mejora del modelo para identificar mejor los objetos e implementar el incremento de datos para optimizar el modelo.

7. IMPLEMENTACION DEL SISTEMA

El sistema desarrollado para el monitoreo de la actividad en vídeo está realizado sobre una arquitectura modular con la que se integran varias técnicas actuales de detección de objetos mediante redes neuronales profundas (YOLOv8) y técnicas tradicionales de visión por computador (ORB); la incorporación de dicha combinación permite el refuerzo del análisis y seguimiento de la actividad en escenas dinámicas, así como también mejorar, cuando se da la oportunidad, la precisión y la robustez a ciertos cambios que se pueden dar en las escenas observadas.

7.1 Entorno de desarrollo

Para llevar a cabo el desarrollo del sistema, se utilizará el lenguaje de programación Python, dado que resulta ser flexible, sintácticamente sencillo y cuenta con una muy buena oferta de librerías especializadas orientadas a la visión por computador e inteligencia artificial. Las principales características de Python son:

- Un lenguaje interpretado

- Un lenguaje fácil de utilizar

  Python utiliza palabras similares a las del inglés. A diferencia de otros lenguajes de programación, Python no utiliza llaves. En su lugar, utiliza sangría.

- Un lenguaje tipeado dinámicamente

  Los programadores no tienen que anunciar tipos de variables cuando escriben código porque Python los determina en el tiempo de ejecución. Debido a esto, es posible escribir programas de Python con mayor rapidez.

- Un lenguaje de alto nivel

  Python es más cercano a los idiomas humanos que otros lenguajes de programación. Por lo tanto, los programadores no deben preocuparse de sus funcionalidades subyacentes, como la arquitectura y la administración de la memoria.

- Un lenguaje orientado a los objetos

Python considera todo como un objeto, pero también admite otros tipos de programación, como la programación estructurada y la funcional. (Amazon Web Services, s. f.).

Python cuenta con diversas herramientas que se utilizarán para llevar a cabo el sistema, entre las que destacan las bibliotecas. Una biblioteca es una colección de códigos usados con frecuencia que los desarrolladores pueden incluir en sus programas de Python para evitar tener que escribir el código desde cero. De forma predeterminada, Python incluye la biblioteca estándar, que contiene una gran cantidad de funciones reutilizables. Además, más de 137 000 bibliotecas de Python están disponibles para diversas aplicaciones, incluidos el desarrollo web, la ciencia de datos y el machine learning (ML). Las herramientas utilizadas en el sistema serán:

- OpenCV-Python

OpenCV-Python es una biblioteca que los desarrolladores utilizan para procesar imágenes para las aplicaciones de visión artificial. Proporciona muchas funciones para las tareas de procesamiento de imágenes, como la lectura y la escritura simultáneas de imágenes, la creación de un entorno 3D a partir de uno 2D y la captura y el análisis de las imágenes de video.

- NumPy

NumPy es una conocida biblioteca que utilizan los desarrolladores para crear y administrar matrices, manipular formas lógicas y efectuar operaciones de álgebra lineal con facilidad. NumPy admite la integración a muchos lenguajes, como C y C++.

- Matplotlib

Los desarrolladores utilizan Matplotlib para trazar los datos en gráficos de dos y tres dimensiones (2D y 3D) de alta calidad. Por lo general, se utiliza en las aplicaciones

científicas. Con Matplotlib, puede visualizar los datos mostrándolos en diferentes gráficos, como los gráficos de barras y los de líneas. También puede trazar varios gráficos de una sola vez, y estos se pueden trasladar a todas las plataformas. (Amazon Web Services, s. f.).

7.2 Funcionamiento del sistema

El sistema se basa en diferentes pasos para entender su funcionamiento, consta de una interfaz para poder detectar la actividad en un video. Los pasos principales de esta interfaz son:

1. Carga un vídeo desde un directorio o fuente en tiempo real.
2. Procesa los fotogramas con YOLO para detectar objetos.
3. Utiliza ORB para encontrar descriptores relevantes y monitorear los cambios en la escena.
4. Si se detecta actividad, se marca una advertencia visual en el frame.
5. Guarda el vídeo con las advertencias y un archivo de registro textual.

A continuación, se muestra un ejemplo de la interfaz que sale al ejecutar el sistema, se aprecia como detecta los objetos y su movimiento. Además, se aprecia los ORB en pantalla de cada frame.

Se puede observar como el sistema genera un video de salida en el que cada objeto identificado se representa con un recuadro, un identificador único (ID) y una puntuación de confianza. El ID es un identificador único asignado por el sistema de seguimiento para diferenciar cada objeto o persona detectada, que permite seguir a cada objeto individual a lo largo de los distintos frames. La puntuación representa la confianza de la detección YOLO, es decir, la probabilidad (entre 0 y 1) de que el objeto detectado sea correcto.

Figura 1. Funcionamiento del sistema.

Fuente: Elaboración propia

7.2.1 Funcionamiento del sistema detallado

El sistema cuenta con varios archivos principales a ejecutar, cada uno con su objetivo para conseguir el rendimiento óptimo:

- Load_video.py: carga el video de entrada mediante la librería OpenCV

```python
import cv2

def load_video(video_path):
    cap = cv2.VideoCapture(video_path)
    if not cap.isOpened():
        raise IOError(f"Error al abrir el vídeo: {video_path}")
    return cap
```

- Detect_activity.py: se encarga de detectar objetos, con la clase YOLOv8Detector, la cual aplica el modelo YOLOv8.

```python
from ultralytics import YOLO

class YOLOv8Detector:
    def __init__(self, model_path='yolov8n.pt', device='cpu'):
        self.model = YOLO(model_path)
        self.device = device

    def detect(self, frame):
        results = self.model.predict(frame, imgsz=640, device=self.device, verbose=False)
        detections = results[0].boxes.xyxy.cpu().numpy()
        confidences = results[0].boxes.conf.cpu().numpy()
        class_ids = results[0].boxes.cls.cpu().numpy()
        return detections, confidences, class_ids
```

- Orb_analysis.py: aplica el seguimiento de puntos clave con el algoritmo ORB

```python
import cv2

class ORBTracker:
    def __init__(self):
        self.orb = cv2.ORB_create()
        self.bf = cv2.BFMatcher(cv2.NORM_HAMMING, crossCheck=True)

    def get_keypoints_descriptors(self, frame):
        gray = cv2.cvtColor(frame, cv2.COLOR_BGR2GRAY)
        keypoints, descriptors = self.orb.detectAndCompute(gray, None)
        return keypoints, descriptors

    def match_descriptors(self, desc1, desc2):
        if desc1 is None or desc2 is None:
            return []
        matches = self.bf.match(desc1, desc2)
        matches = sorted(matches, key=lambda x: x.distance)
        return matches
```

- Visualize_results.py: se encarga de dibujar los resultados sobre los frames

```python
import cv2

def draw_detections(frame, detections, confidences, class_ids, threshold=0.5):
    for (bbox, score, cls_id) in zip(detections, confidences, class_ids):
        if score > threshold:
            x1, y1, x2, y2 = map(int, bbox)
            cv2.rectangle(frame, (x1, y1), (x2, y2), (0,255,0), 2)
            cv2.putText(frame, f"ID {int(cls_id)} {score:.2f}", (x1, y1-10),
                        cv2.FONT_HERSHEY_SIMPLEX, 0.5, (0,255,0), 2)
    return frame
```

- Metrics_logger.py: registra las métricas en un archivo csv

```python
import csv

class MetricsLogger:
    def __init__(self, csv_filename="resultados_metrica.csv"):
        self.csv_filename = csv_filename
        self.data = []
        self.frame_id = 0

    def log(self, yolo_detections, orb_matches, fps=None):
        self.data.append({
            "Frame": self.frame_id,
            "YOLO_Detecciones": yolo_detections,
            "ORB_Coincidencias": orb_matches,
            "FPS": fps if fps is not None else 0
        })
        self.frame_id += 1

    def save(self):
        keys = ["Frame", "YOLO_Detecciones", "ORB_Coincidencias", "FPS"]
        with open(self.csv_filename, "w", newline="") as f:
            writer = csv.DictWriter(f, fieldnames=keys)
            writer.writeheader()
            writer.writerows(self.data)
```

- Graficas_metricas.py: Lee el archivo .csv generado con las métricas y dibuja graficas de: número de detecciones YOLO por frame, número de coincidencias ORB por frame y comparación entre YOLO y ORB.

```python
csv_path = 'metricas_parcial3.csv'

# Leer datos
df = pd.read_csv(csv_path)

# Graficar detecciones YOLO
plt.figure(figsize=(10, 4))
plt.plot(df['YOLO_Detecciones'], label='Detecciones YOLO', color='green')
plt.xlabel('Frame')
plt.ylabel('Número de detecciones')
plt.title('Detecciones YOLO por frame')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.savefig(f'grafica_yolo_{os.path.splitext(csv_path)[0]}.png')
plt.show()
```

```python
# Graficar coincidencias ORB
plt.figure(figsize=(10, 4))
plt.plot(df['ORB_Coincidencias'], label='Coincidencias ORB', color='blue')
plt.xlabel('Frame')
plt.ylabel('Número de coincidencias')
plt.title('Coincidencias ORB por frame')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.savefig(f'grafica_orb_{os.path.splitext(csv_path)[0]}.png')
plt.show()
```

```python
# Comparación de ambas métricas
plt.figure(figsize=(10, 4))
plt.plot(df['YOLO_Detecciones'], label='YOLO', color='green')
plt.plot(df['ORB_Coincidencias'], label='ORB', color='blue')
plt.xlabel('Frame')
plt.ylabel('Cantidad')
plt.title('Comparación YOLO vs ORB')
plt.legend()
plt.grid(True)
plt.tight_layout()
plt.savefig(f'grafica_comparativa_{os.path.splitext(csv_path)[0]}.png')
plt.show()
```

- Main.py: se encarga de toda la ejecución del sistema

```python
import cv2
from load_video import load_video
from detect_activity import YOLOv8Detector
from orb_analysis import ORBTracker
from visualize_results import draw_detections
from metrics_logger import MetricsLogger

# Configuración inicial
video_path = 'tu_video.mp4'
save_path = 'output_resultado.avi'
device = 'cpu'

# Inicialización de componentes
cap = load_video(video_path)
detector = YOLOv8Detector(device=device)
orb_tracker = ORBTracker()
logger = MetricsLogger("metricas_sistema.csv")

# Parámetros de salida
fourcc = cv2.VideoWriter_fourcc(*'XVID')
frame_width = int(cap.get(3))
frame_height = int(cap.get(4))
fps = cap.get(cv2.CAP_PROP_FPS)

out = cv2.VideoWriter(save_path, fourcc, fps, (frame_width, frame_height))
prev_descriptors = None
```

```python
# Bucle de procesamiento frame a frame
while True:
    ret, frame = cap.read()
    if not ret:
        break

    # ——— PREPROCESAMIENTO ———
    frame = cv2.resize(frame, (640, 480))
    frame = cv2.GaussianBlur(frame, (5, 5), 0)

    # Mejora de contraste (opcional, útil en baja luz)
    yuv = cv2.cvtColor(frame, cv2.COLOR_BGR2YUV)
    yuv[:, :, 0] = cv2.equalizeHist(yuv[:, :, 0])
    frame = cv2.cvtColor(yuv, cv2.COLOR_YUV2BGR)

    # ——— DETECCIÓN CON YOLOV8 ———
    detections, confidences, class_ids = detector.detect(frame)

    # ——— ANÁLISIS ORB ———
    keypoints, descriptors = orb_tracker.get_keypoints_descriptors(frame)

    num_matches = 0
    if prev_descriptors is not None and descriptors is not None:
        matches = orb_tracker.match_descriptors(prev_descriptors, descriptors)
        num_matches = len(matches)

    prev_descriptors = descriptors
```

```python
    prev_descriptors = descriptors

    # ——— VISUALIZACIÓN ———
    frame = draw_detections(frame, detections, confidences, class_ids)
    cv2.putText(frame, f"Matches ORB: {num_matches}", (10, 30),
                cv2.FONT_HERSHEY_SIMPLEX, 1, (255, 0, 0), 2)

    out.write(frame)  # Guarda en el vídeo
    logger.log(len(detections), num_matches)  # Guarda métricas

    cv2.imshow('Actividad detectada', frame)  # Muestra en tiempo real

    if cv2.waitKey(1) & 0xFF == ord('q'):
        break

# Cierre y limpieza
cap.release()
out.release()
cv2.destroyAllWindows()
logger.save()
```

7.2.2 Main.py

El flujo principal del sistema sigue los siguientes pasos:

1. Carga del vídeo.
2. Redimensionado y preprocesamiento del frame.
3. Aplicación de detección con YOLOv8.
4. Obtención de puntos clave ORB y comparación con el frame anterior.
5. Visualización y escritura del frame en un archivo .avi.
6. Registro de métricas en un archivo .csv.

Este procedimiento se repite para cada frame del vídeo hasta que se alcanza el final del archivo o se pulsa la tecla de salida ‘q’.

1. Importaciones necesarias

Importa todos los módulos necesarios. Cada uno se encarga de una parte del sistema:

- Cargar vídeo (load_video)
- Detección de objetos con YOLOv8 (YOLOv8Detector)
- Seguimiento de actividad con ORB (ORBTracker)
- Dibujar resultados en el frame (draw_detections)
- Registrar métricas (MetricsLogger)

```
import cv2
from load_video import load_video
from detect_activity import YOLOv8Detector
from orb_analysis import ORBTracker
from visualize_results import draw_detections
from metrics_logger import MetricsLogger
```

2. Configuración del video

Define la ruta del vídeo a procesar, el archivo de salida, y el dispositivo de ejecución

```
# Configuración inicial
video_path = 'tu_video.mp4'
save_path = 'output_resultado.avi'
device = 'cpu'
```

3. Iniciar componentes

- cap: abre el vídeo con OpenCV.
- detector: instancia de YOLOv8.
- orb_tracker: prepara ORB para detectar movimiento.
- logger: inicializa el registro de métricas.

```
cap = load_video(video_path)
detector = YOLOv8Detector(device=device)
orb_tracker = ORBTracker()
logger = MetricsLogger("metricas_sistema.csv")
```

4. Configuración video de salida

- Define el formato de compresión.
- Obtiene dimensiones y FPS del vídeo original.
- Crea el archivo .avi donde se guardarán los resultados.

```
fourcc = cv2.VideoWriter_fourcc(*'XVID')
frame_width = int(cap.get(3))
frame_height = int(cap.get(4))
fps = cap.get(cv2.CAP_PROP_FPS)

out = cv2.VideoWriter(save_path, fourcc, fps, (frame_width, frame_height))
```

5. Inicializar variable de ORB

Guarda los descriptores del frame anterior para comparar con el siguiente.

```
prev_descriptors = None
```

6. Bucle de procesamiento frame a frame

Lee el vídeo frame a frame. Si no hay más frames, termina el bucle.

```
while True:
    ret, frame = cap.read()
    if not ret:
        break
```

7. Preprocesamiento del frame

- Redimensiona el frame.
- Reduce el ruido con desenfoque gaussiano.
- Mejora el contraste (útil en escenas oscuras).

```
frame = cv2.resize(frame, (640, 480))
frame = cv2.GaussianBlur(frame, (5, 5), 0)

# Mejora de contraste (útil en baja luz)
yuv = cv2.cvtColor(frame, cv2.COLOR_BGR2YUV)
yuv[:, :, 0] = cv2.equalizeHist(yuv[:, :, 0])
frame = cv2.cvtColor(yuv, cv2.COLOR_YUV2BGR)
```

8. Detección con YOLOv8

Detecta objetos como personas u otros elementos.

Devuelve:

- Coordenadas de las cajas

- Confianza de cada detección

- Tipo de objeto detectado

```
detections, confidences, class_ids = detector.detect(frame)
```

9. Análisis de movimiento con ORB

- Detecta puntos clave en el frame actual.
- Los compara con el frame anterior para saber si hay movimiento.
- Guarda el número de coincidencias (más = más actividad).

```
keypoints, descriptors = orb_tracker.get_keypoints_descriptors(frame)

num_matches = 0
if prev_descriptors is not None and descriptors is not None:
    matches = orb_tracker.match_descriptors(prev_descriptors, descriptors)
    num_matches = len(matches)

prev_descriptors = descriptors
```

10. Dibujar resultados sobre el video

Dibuja las cajas de detección de YOLO. Añade el número de coincidencias ORB como texto.

```
frame = draw_detections(frame, detections, confidences, class_ids)
cv2.putText(frame, f"Matches ORB: {num_matches}", (10, 30),
            cv2.FONT_HERSHEY_SIMPLEX, 1, (255, 0, 0), 2)
```

11. Guardar y mostrar el frame

- Guarda el frame en el vídeo de salida.
- Registra las métricas de ese frame en el CSV.
- Muestra el resultado en tiempo real.
- Sale del bucle si se pulsa la tecla ‘q’.

```
out.write(frame)  # Guarda en el vídeo
logger.log(len(detections), num_matches)  # Guarda métricas

cv2.imshow('Actividad detectada', frame)  # Muestra en tiempo real

if cv2.waitKey(1) & 0xFF == ord('q'):
    break
```

12. Liberar recursos al finalizar

- Libera la memoria ocupada por el vídeo.
- Cierra la ventana de visualización.
- Guarda el archivo .csv con las métricas finales.

```
cap.release()
out.release()
cv2.destroyAllWindows()
logger.save()
```

7.3 Preprocesamiento de video

Para analizar los videos, se realiza un preprocesamiento para facilitar el análisis y rendimiento optimo del modelo de detección. El objetivo de este preprocesamiento es mejorar la calidad de la imagen y homogeneizar las entradas para el modelo. Para conseguir esto se realizarán las siguientes operaciones:

- Redimensionado
- Conversión de color
- Reducción de ruido
- Normalización

```
frame = cv2.resize(frame, (640, 480))
frame = cv2.GaussianBlur(frame, (5, 5), 0)

# Mejora de contraste (útil en baja luz)
yuv = cv2.cvtColor(frame, cv2.COLOR_BGR2YUV)
yuv[:, :, 0] = cv2.equalizeHist(yuv[:, :, 0])
frame = cv2.cvtColor(yuv, cv2.COLOR_YUV2BGR)
```

7.4 Detección de objetos

La detección principal se realizará con YOLO, utilizado para la detección precisa y rápida de los objetos en el video. La detección consiste en:

- Carga del modelo
- Procesamiento de los frames
- Filtrar resultados
- Visualizar resultados

El modelo YOLOv8 fue utilizado a través de la librería ultralytics. El detector se inicializa y se aplica sobre cada frame:

```
detector = YOLOv8Detector(device=device)
detections, confidences, class_ids = detector.detect(frame)
```

7.5 Seguimiento de actividad

Para analizar el movimiento entre frames se utilizará el algoritmo ORB que se basa en la detección y descripción de las características en imágenes, este algoritmo cuenta con dos métodos clave. FAST (Se encarga de detectar puntos clave en las imágenes analizando los contrastes) y BRIEF (Genera descriptores de esos puntos clave para

para poder compararlos a cambios de iluminación y escala.) Este permite detectar cambios visuales relevantes:

```
keypoints, descriptors = orb_tracker.get_keypoints_descriptors(frame)

num_matches = 0
if prev_descriptors is not None and descriptors is not None:
    matches = orb_tracker.match_descriptors(prev_descriptors, descriptors)
    num_matches = len(matches)

prev_descriptors = descriptors
```

7.6 Resultados

Los resultados se mostrarán en un video por pantalla, en el que se podrá observar las detecciones en cada frame y las zonas donde se ha detectado la actividad. Además de las cajas de detección, cada objeto detectado contiene un numero identificador (ID) que permanece constante durante los frames y una puntuación de confianza proporcionada por YOLO. También saldrán en pantalla las coincidencias ORB por frame.

```
frame = draw_detections(frame, detections, confidences, class_ids)
cv2.putText(frame, f"Matches ORB: {num_matches}", (10, 30),
            cv2.FONT_HERSHEY_SIMPLEX, 1, (255, 0, 0), 2)

out.write(frame)  # Guarda en el vídeo
```

7.7 Métricas

El archivo metricas_sistema.csv incluye el número de detecciones YOLO, coincidencias ORB y FPS por cada fotograma procesado. Esta información será utilizada en la sección de Resultados para generar gráficas y análisis comparativos.

```
logger.log(len(detections), num_matches)  # Guarda métricas
```

8. RESULTADOS Y EVALUACION

8.1 Pruebas realizadas

Para comprobar y evaluar el funcionamiento del sistema se utilizaron videos de vigilancia para realizar las diversas pruebas. Los videos utilizados contaban con diversas características como son:

- Resolución: Los videos se ajustaron para que todos tuviesen características comunes. La resolución de estos videos era de 640x480
- Frames: 30 frames por segundo
- Lugares: Para comprobar la efectividad del sistema se comprobaron con diferentes condiciones de iluminación además de espacios tanto interiores como exteriores.
- Objetos: Se comprobó con una o varias personas en movimiento o estático.

Al realizar estas pruebas se pudo analizar los aspectos esenciales del sistema. YOLO para la detección de los objetos en los videos y ORB en frames consecutivos para identificar puntos críticos.

Estas pruebas han sido esenciales para poder medir la eficacia del sistema en diferentes situaciones que podrían afectar los resultados. Para comprobar esto se estudió la precisión, los cambios de iluminación y los escenarios tanto estáticos como dinámicos. Además, para simular el sistema a condiciones reales se utilizaron videos con situaciones distintas, como edificios o calles.

8.2. Métricas utilizadas

Las métricas utilizadas para medir el rendimiento del sistema y la actividad detectada son:

FPS (Frames por segundo): El número de fotogramas procesados por segundo es un indicador del rendimiento del sistema en tiempo real. Una tasa alta de FPS refleja una mayor capacidad de respuesta del sistema.

ORB (Oriented FAST and Rotated BRIEF): Puntos de interés en fotogramas consecutivos.

Estas métricas permiten analizar tanto la eficiencia computacional como la respuesta visual del sistema ante diferentes situaciones y escenarios.

8.3. Resumen resultados visuales obtenidos en cada situación

En las pruebas se pudo ver reflejado como el sistema se ha visto afectado por los cambios de iluminación y los diferentes tipos de escena. Los principales resultados han sido:

- Escenarios bien iluminados: El sistema ha demostrado un alto nivel de precisión en la detección de personas en este tipo de escenario, en especial en los escenarios bien iluminados y con un movimiento claro. A pesar de esto, el sistema ha sido sensible a los objetos estáticos con forma humana (maniquís) y a sombras causadas por la iluminación. La orientación vertical afecto a la visualización, pero en ningún momento al funcionamiento.

- Escenarios exteriores concurridos: El rendimiento fue estable incluso en situaciones dinámicas, con múltiples objetos y personas en movimiento. Algunos elementos fueron omitidos en algunas ocasiones debido a la saturación de información visual en pantalla. El sistema también fue capaz de recuperar detecciones tras oclusiones parciales, lo que demuestra la capacidad de integrarlo en entornos reales.

- Escenarios con baja iluminación: A pesar de las condiciones de iluminación adversas, el sistema demostró ser eficaz, detectando correctamente a individuos en grupo, con elementos en el rostro que lo dificultan. En estos casos ORB contribuyo a la detección, aunque en algunos casos las coincidencias disminuyeron.

- Escenarios con personas parcialmente ocultas: En los casos en la que las personas están parcialmente ocultas, el sistema es capaz de identificar parcialmente a los individuos, ya que en algunos instantes no reconoce al individuo cuando no sale completamente en el frame. Esto representa una ligera disminución en la confianza y un área de mejora futura

8.4 Resultados visuales de cada prueba

Para estudiar y comprobar el funcionamiento del sistema de monitoreo en distintos contextos, se han realizado pruebas en 10 diferentes videos en distintos tipos de escenarios. A partir de estas pruebas, se han obtenido la salida en video en formato .avi y las capturas de frames significativos, lo que permite valorar la eficacia del sistema tanto en condiciones favorables como en escenarios adversos. Además de las cajas de detección, cada objeto detectado contiene un numero identificador (ID) que permanece constante durante los frames y una puntuación de confianza proporcionada por YOLO, lo que facilita la evaluación y fiabilidad de cada detección en los distintos escenarios. A continuación, se describen los resultados extraídos de cada prueba:

- Escenario iluminado 1: Tienda de ropa

En este escenario iluminado, el sistema es capaz de identificar perfectamente a las personas presentes en la escena. A pesar de esto, algunos maniquís fueron identificados erróneamente como personas reales, debido a la iluminación constante y la rigidez de algunos elementos.

Figura 2. Detección correcta en tienda.

Fuente: Elaboración propia

Figura 3.Detección errónea de maniquís en escena iluminada

Fuente: Elaboración propia

- Escenario iluminado 2: Entrada a casa

La detección en esta prueba fue precisa ya que se han reconocido todos los sujetos en movimiento. A pesar de esto, se puede apreciar como el sistema es sensible a variaciones de contraste ya que se aprecian algunos falsos positivos en las sombras humanas que se proyectan en la pared.

Figura 4.Detección correcta en entrada de casa

Fuente: Elaboración propia

Figura 5.Falso positivo en sombra proyectada

Fuente: Elaboración propia

- Escenario iluminado 3: Video dos mujeres caminando

En este caso el sistema fue capaz de detectar a las personas en movimiento sin dificultad. La visualización del .avi resulta menos claro debido al formato vertical (9:16), pero en ningún momento afecta a la detección del sistema.

Figura 6.Detección correcta en formato vertical

Fuente: Elaboración propia

- Escenario múltiples 1: Calle concurrida con peatones y vehículos

En este video se aprecia un buen funcionamiento general del sistema ya que es capaz de identificar a todos los objetos en movimiento a pesar del alto volumen de elementos, ya que aparecen trenes, mobiliario urbano y varios individuos. Debido al gran tráfico de elementos, el sistema no fue capaz de detectar a algunos individuos aislados.

Figura 7.Escena urbana con detecciones múltiples y omisiones

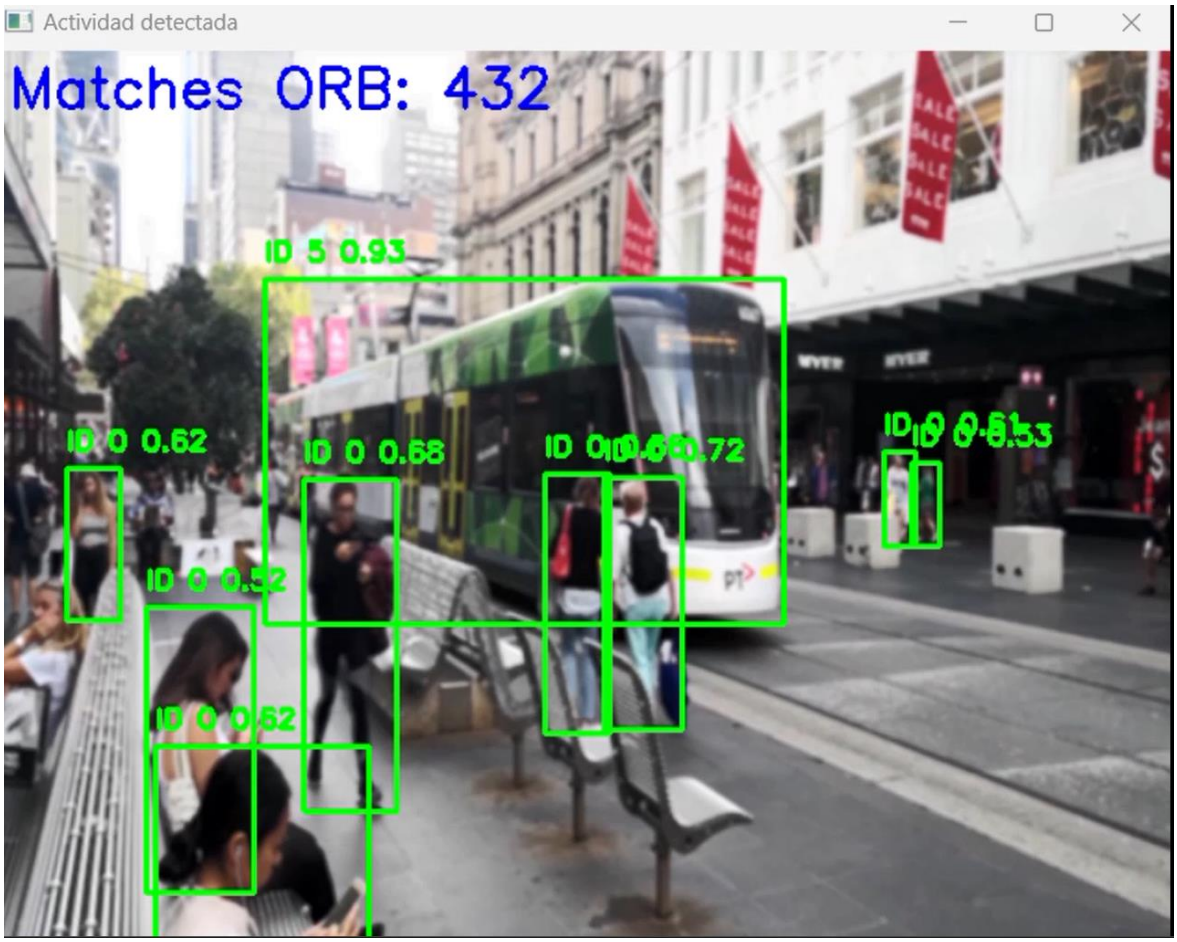

Fuente: Elaboración propia

- Escenario múltiples 2: Entorno urbano

En este caso se aprecia la capacidad del sistema de identificar a un individuo tras desparecer de la escena. El sistema detecta correctamente a todas las personas en escena, y además es capaz de identificar nuevamente a un individuo que desaparecía detrás de una columna.

Figura 8.Re-identificación tras oclusión parcial I

Fuente: Elaboración propia

Figura 9.Re-identificación tras oclusión parcial II

Fuente: Elaboración propia

Figura 10.Re-identificación tras oclusión parcial III

Fuente: Elaboración propia

- Escenario baja iluminación 1: Grupo de personas

A pesar de las condiciones adversas en el video en la que hay muchos individuos agrupados con rostros cubiertos, el sistema es capaz de detectar con éxito a todos los individuos del video. En este caso, el rendimiento ORB también fue estable, facilitando el seguimiento visual.

Figura 11.Alta detección en situación de baja iluminación con rostros cubiertos

Fuente: Elaboración propia

- Escenario baja iluminación 2: Policía en zona oscura

En este caso, el sistema mantuvo una alta precisión, identificando correctamente al individuo armado en movimiento. La baja visibilidad no impidió al modelo realizar detecciones consistentes.

Figura 12.Detección clara en ambiente nocturno

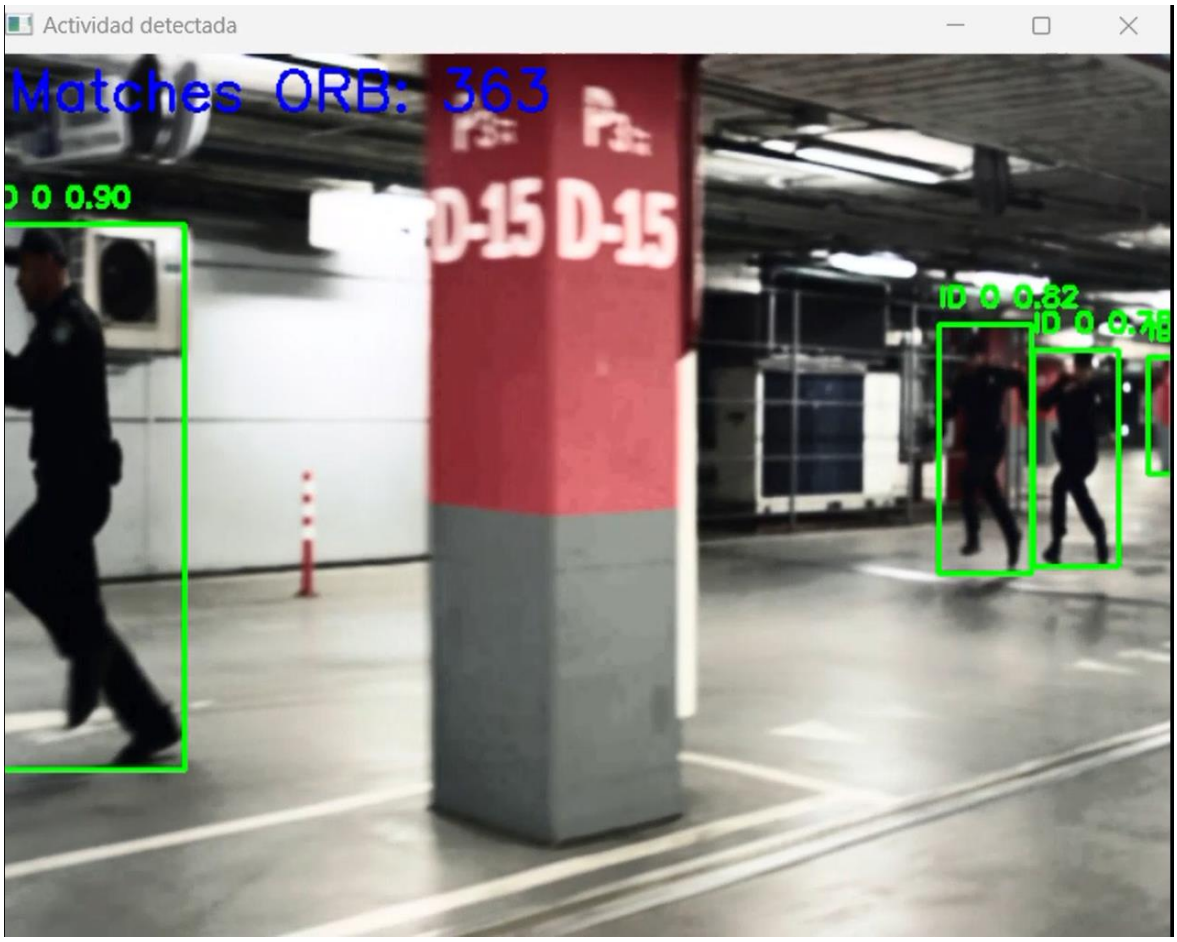

Fuente: Elaboración propia

- Escenario parcial 1: Persona parcialmente visible

En este caso hay varios individuos que aparecen a medias, lo que dificulta que el sistema lo identifique inicialmente, pero consigue detectarlos tras unos frames. En este caso ORB contribuye para mantener el seguimiento correcto.

Figura 13.Recuperación de detección tras aparición parcial I

Fuente: Elaboración propia

Figura 14.Recuperación de detección tras aparición parcial II

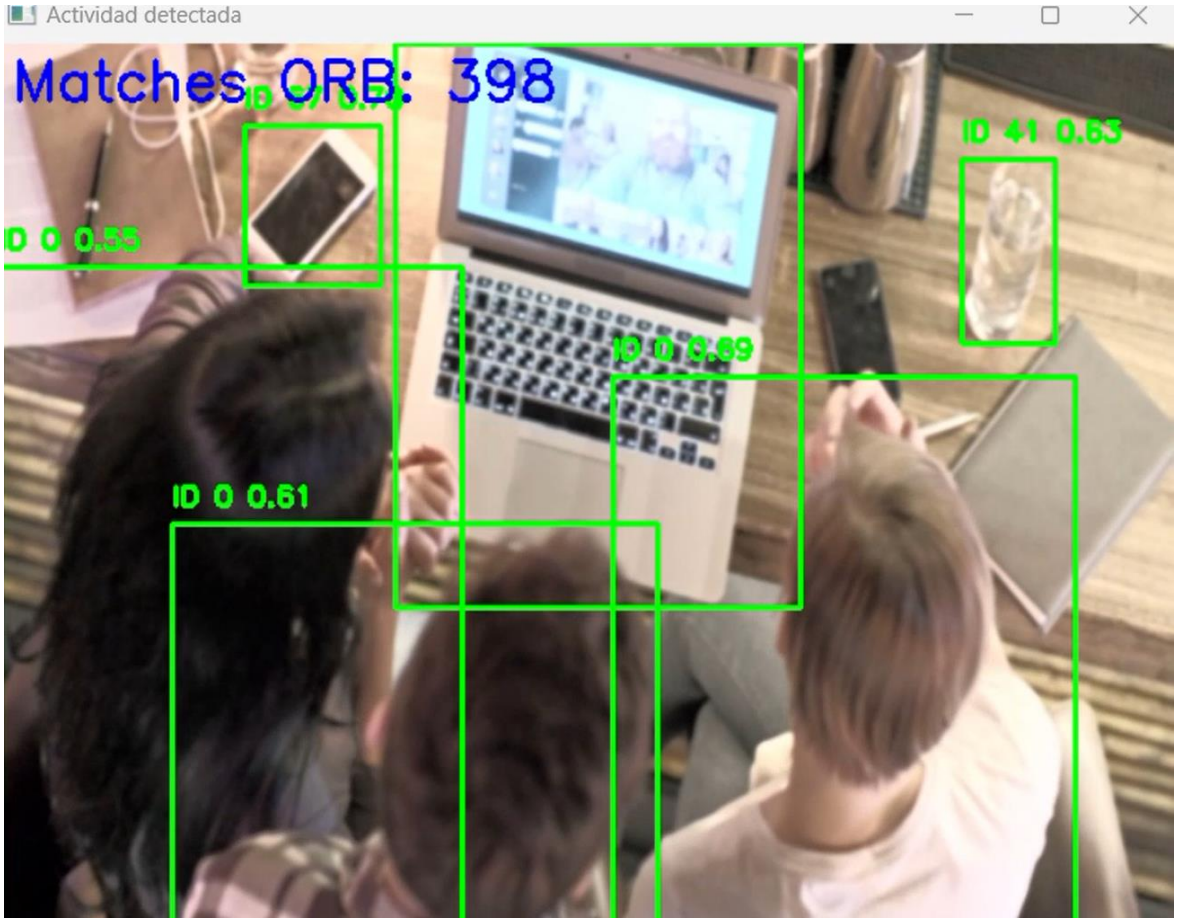

Fuente: Elaboración propia

- Escenario parcial 2: Persona medio oculta detrás de barra de cafetería

El sistema logra identificar al individuo que esta parcialmente visible al fondo de la escena, pero la confianza de detección es más baja ya que ORB precisa de más tiempo para encontrar coincidencias.

Figura 15.Identificación con coincidencias limitadas en cafetería

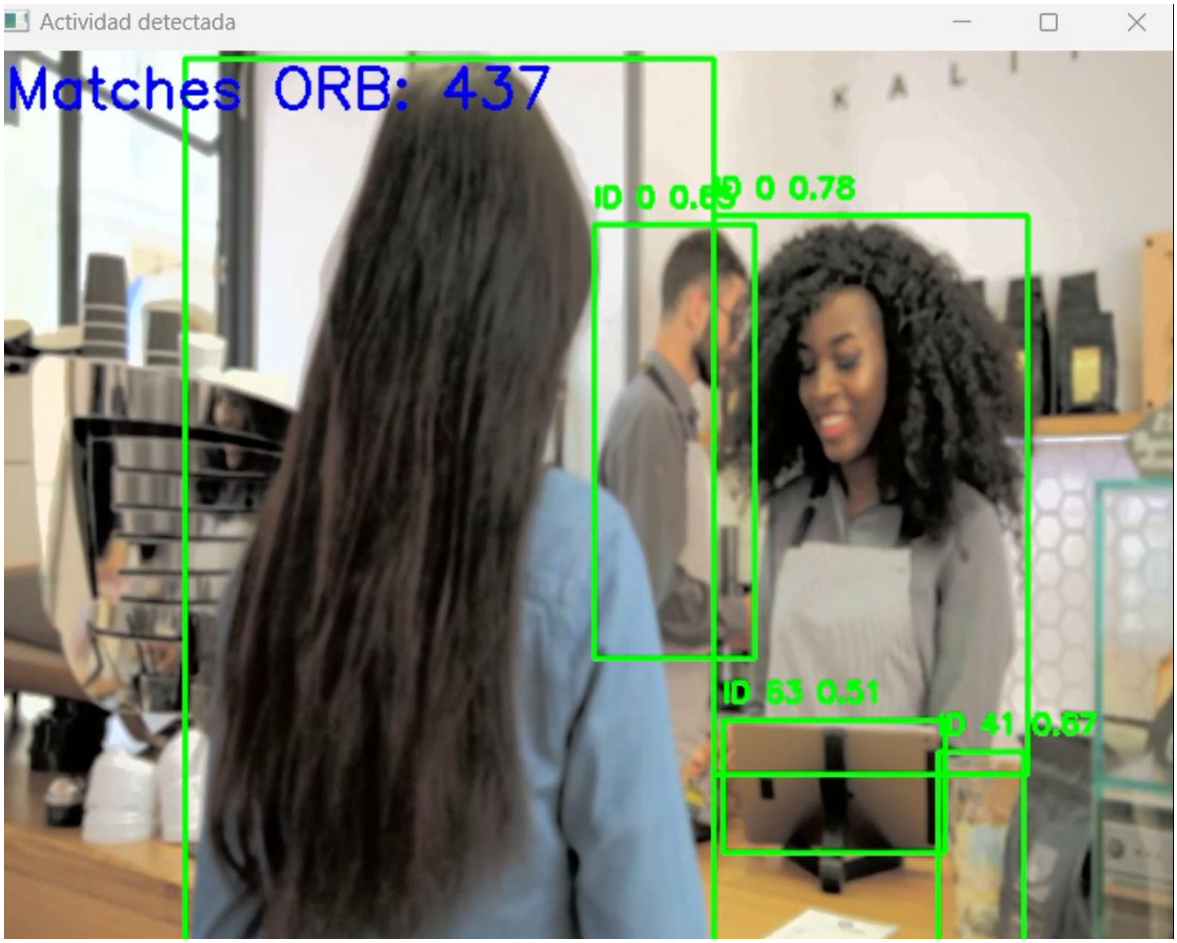

Fuente: Elaboración propia

8.5 Resultados cuantitativos (graficas, métricas) obtenidos

Aparte del análisis visual, se han registrado métricas de cada prueba en formato .csv durante la ejecución del sistema para analizar el comportamiento del modelo. A partir de los archivos se generan graficas que permiten mostrar la evolución de las detecciones YOLO y las coincidencias ORB a lo largo de los frames.

Al ejecutar el sistema saldrán las gráficas de los videos en cada escenario. Los resultados constan de tres graficas:

- Detecciones YOLO por frame
- Coincidencias ORB por frame
- Comparativa YOLO vs ORB

Las métricas permiten estudiar la estabilidad del sistema en el seguimiento visual entre frames permitiendo sacar conclusiones y evaluaciones más técnicas. Además, permiten analizar la presencia de actividad detectada en cada frame. A continuación, se describen las observaciones extraídas de cada gráfico.

- Grafica 1: Detecciones YOLO por frame

Esta grafica se basa en representar cuantos objetos/personas fueron detectados en cada frame. En los videos con actividad constante, se refleja una línea estable, mientras que, en escenas con interrupciones u oclusiones, se verán caídas o picos reflejados en la gráfica.

En los videos con actividad constante a lo largo de los frames, las gráficas de detecciones YOLO muestran una línea estable, lo que refleja que el sistema es capaz de mantener un rendimiento constante en la identificación de objetos o individuos en movimiento. Esto demuestra el buen funcionamiento del modelo en escenas con actividad visual continua.

Figura 16.Detecciones YOLO por frame en videos iluminados

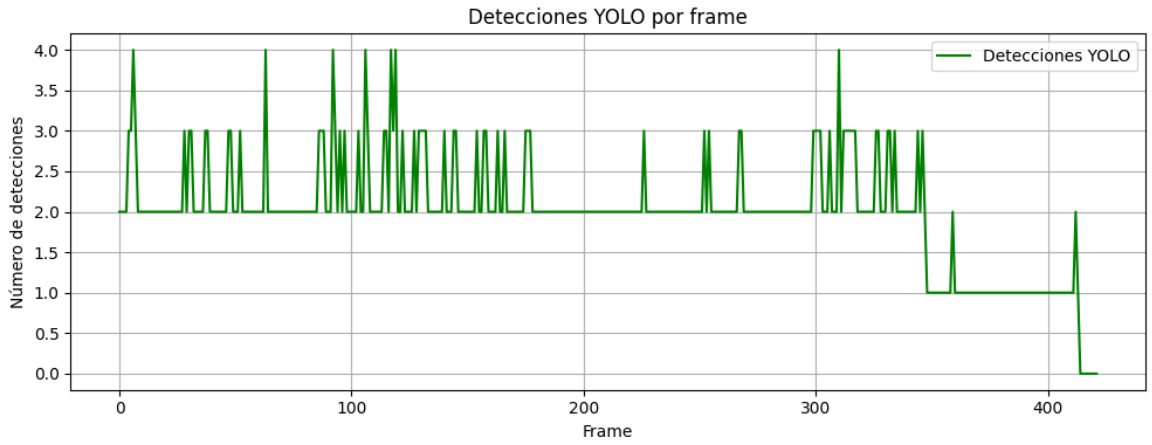

Fuente: Elaboración propia

En videos con alta densidad de movimiento y múltiples individuos presentes en la escena, se pueden observar picos altos y estables en la graficas de detecciones YOLO. Esto surge debido a un alto porcentaje de detección durante el tiempo, lo que demuestra la capacidad del sistema para detectar a múltiples individuos en entornes activos y con un nivel visual complejo.

Figura 17.Detecciones YOLO por frame en videos con mucha actividad

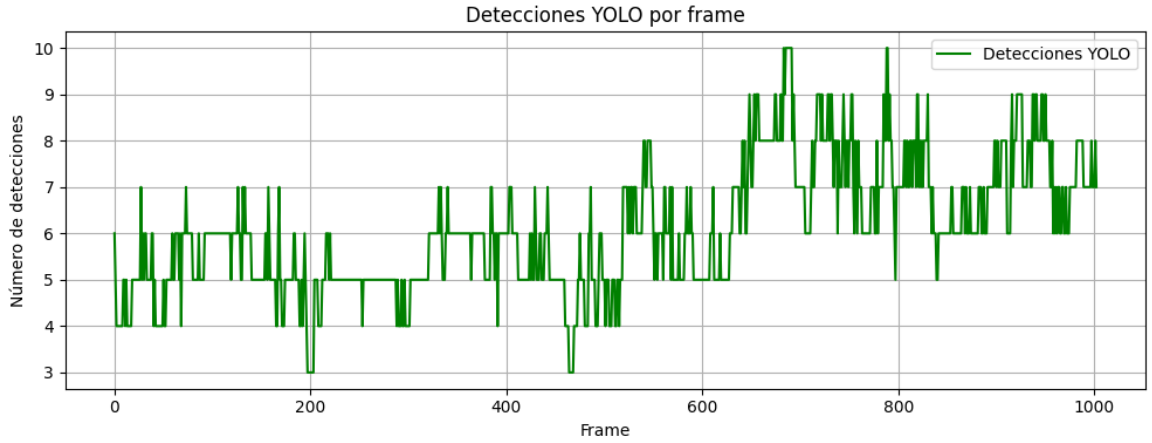

Fuente: Elaboración propia

En videos en los que el sujeto aparece parcialmente oculto o fuera del encuadre se registraron caídas puntuales en el número de detecciones YOLO ya que coinciden con el momento en el que el sujeto aparece parcialmente o fuera del frame. Estos bajones puntuales pueden provocar falsos negativos o detecciones con baja confianza, lo que reflejan una limitación del sistema cuando el objeto de interés no está completamente visible. A pesar de esto, el sistema es capaz de recuperar la detección tras unos frames, gracias al refuerzo en el seguimiento visual mediante ORB.

Figura 18.Detecciones YOLO por frame en videos con objetos parcialmente visibles

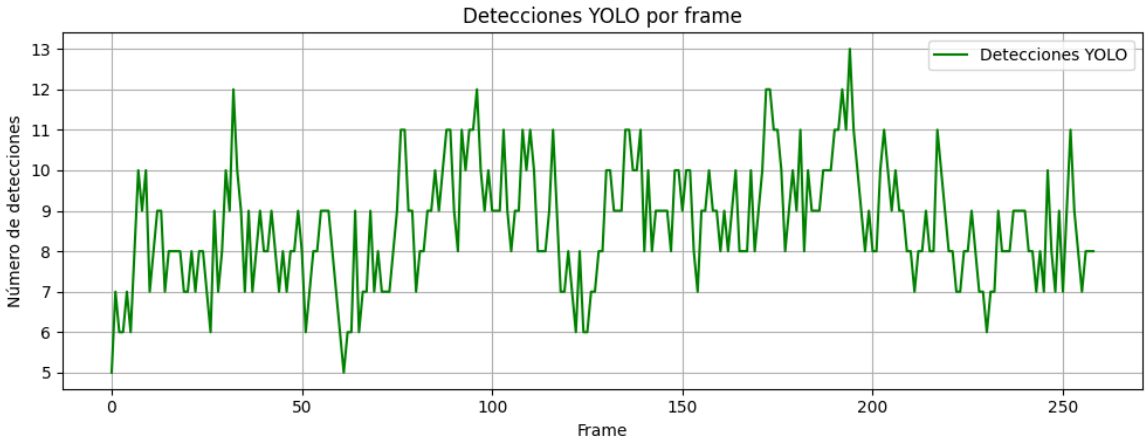

Fuente: Elaboración propia

- Grafica 2: Coincidencias ORB por frame

Esta grafica refleja cuántos puntos clave se repiten entre un frame y el siguiente. Esta métrica es útil para detectar movimiento, incluso cuando YOLO no identifica nuevos objetos.

Figura 19.Coincidencias ORB en video con objetos parcialmente visibles

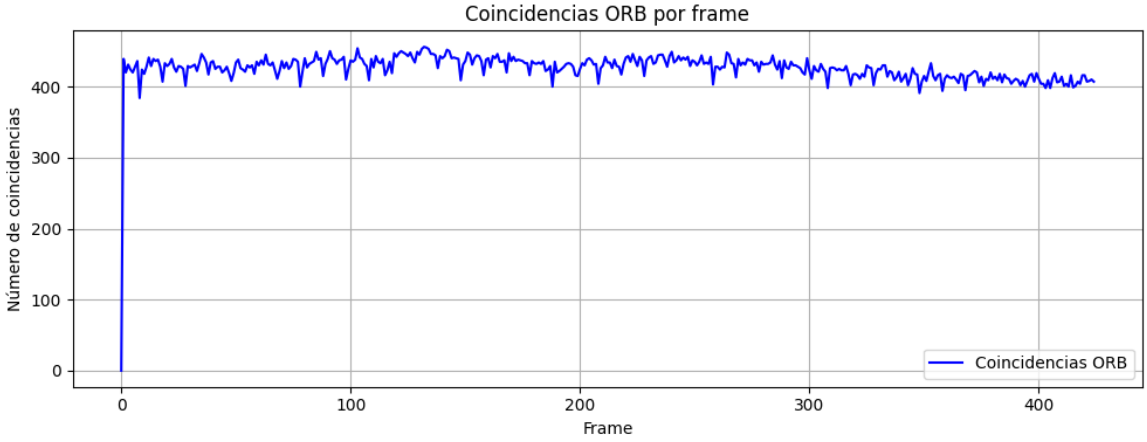

Fuente: Elaboración propia

En videos sin actividad o que no se produce movimiento relevante entre frames, la gráfica que refleja las coincidencias ORB muestra una caída a valores mínimos, debido a la falta de variaciones visuales que puedan generar puntos clave entre los frames. Esto demuestra que el sistema refleja correctamente la falta de actividad visual en estos casos.

En contextos con baja iluminación, ORB consigue mantener un numero estable de coincidencia entre frames, aunque con una mayor variabilidad con respecto a escenarios bien iluminados. Esta inestabilidad es a causa de la reducción del detalle visual debido a las malas condiciones de iluminación, lo que dificulta la identificación de puntos clave en estos frames. A pesar de las condiciones adversas el sistema es capaz de conservar una estabilidad en el seguimiento.

Figura 20.Coincidencias ORB en videos con baja iluminación

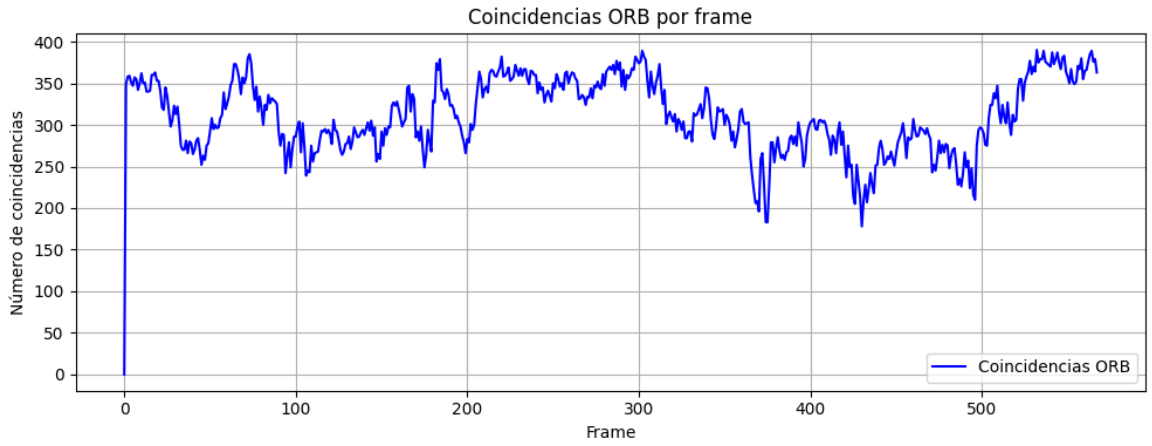

Fuente: Elaboración propia

- Grafica 3: Comparativa YOLO vs ORB

Esta grafica compara las detecciones YOLO y las coincidencias ORB para estudiar y comparar su correlación. Debido a esto, se ha podido llegar a varias conclusiones, una

relación fuerte entre ambas indica que los métodos se refuerzan mutuamente y si varían, pueden existir errores o limitaciones en alguno de los dos métodos.

Figura 21.Comparativa YOLO y ORB en videos con mucha actividad

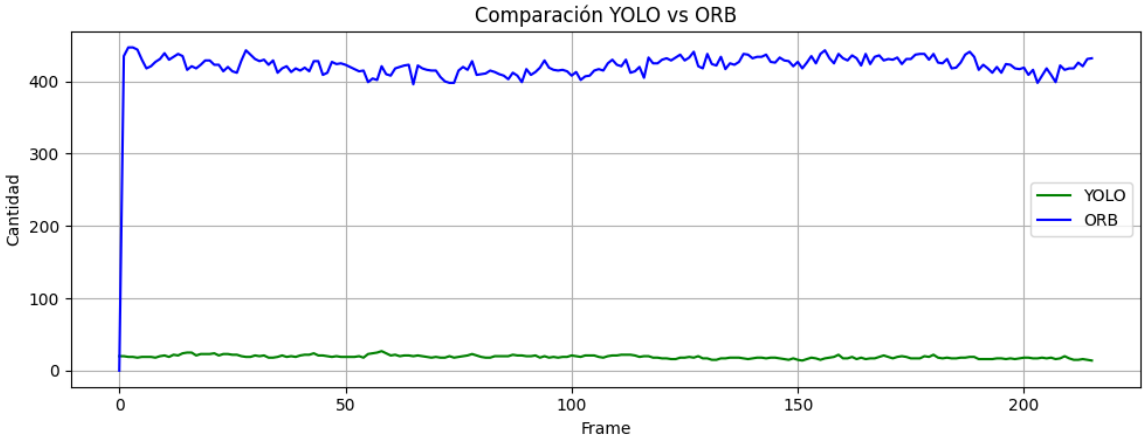

Fuente: Elaboración propia

En videos con obstrucción parcial, se aprecia que el número de coincidencias ORB se mantiene estable incluso cuando las detecciones YOLO experimentaban caídas. Esto demuestra que ORB es capaz de identificar los puntos clave a pesar de que el objeto no esté completamente visible o no esté siendo detectado por el modelo. Por lo tanto, ORB aporta continuidad al seguimiento de actividad en contextos en los que la detección no resulta suficiente, convirtiéndolo en un complemento de gran utilidad para el sistema.

Figura 22.Comparativa YOLO y ORB en videos con objetos parcialmente visibles

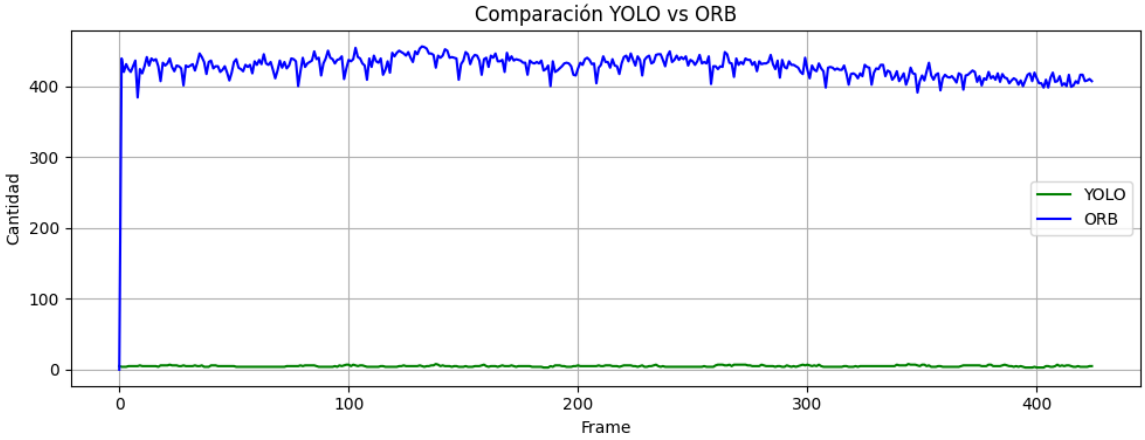

Fuente: Elaboración propia

En condiciones de baja iluminación, se puede observar cómo tanto las detecciones YOLO como las coincidencias ORB descienden. Esto pone en manifiesto como ambos métodos son sensibles a la calidad visual, YOLO reduce la tasa de detección debido a la falta de contraste y ORB encuentra menos puntos clave valido entre frames. Esta correlación negativa podría suponer la necesidad de incorporar técnicas de mejora de imagen para mantener un buen rendimiento en condiciones visuales adversas.

Figura 23.Comparativa YOLO y ORB en videos con baja iluminación

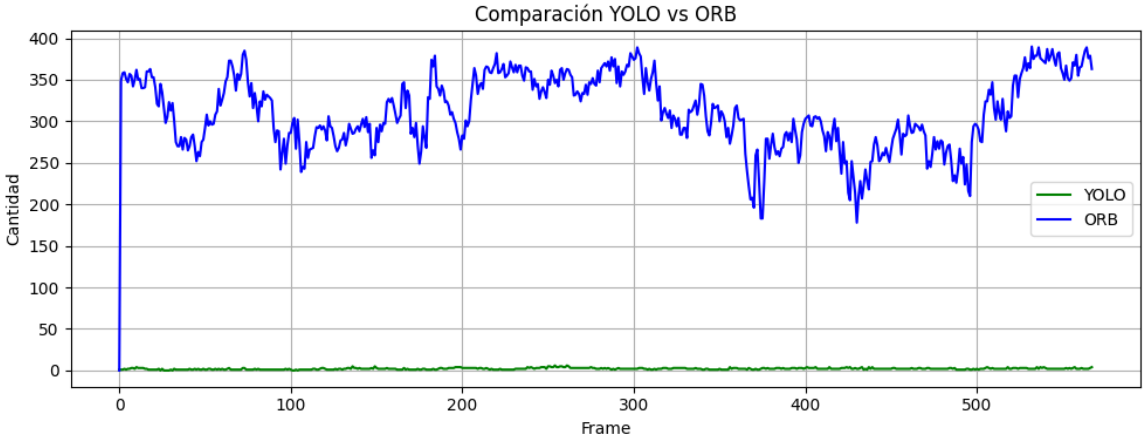

Fuente: Elaboración propia

8.6 Resultados sistema general

En todas las pruebas de video, el sistema ha sido capaz de generar salidas relevantes y coherentes. Se observo un buen funcionamiento en diversos escenarios y algunas limitaciones en escenarios con oclusión o abundancia de elementos en movimiento.

Las gráficas generadas a partir de las detecciones YOLO y las coincidencias ORB permiten visualizar con claridad cómo responde el sistema ante diferentes condiciones de escena. Se observa una fuerte correlación entre ambas métricas en escenarios bien iluminados o con múltiples personas en movimiento, mientras que en situaciones de baja visibilidad o con sujetos parcialmente ocultos, el número de coincidencias tiende a disminuir, aunque en muchos casos logra mantener la continuidad del seguimiento. Estas gráficas, además de ofrecer respaldo cuantitativo, permiten identificar picos, caídas o inconsistencias que resultan útiles para evaluar la robustez del sistema y plantear mejoras futuras.

Con las pruebas realizadas en diferentes situaciones se han podido llegar a varias conclusiones. Para el monitoreo en seguridad ha resultado ser efectivo la combinación entre ORB y YOLO. Para mejorar la precisión del sistema en situaciones de baja iluminación se podrían aplicar otras técnicas de mejora de imagen y, por último, al poder adaptar el sistema a nuevas condiciones se podría aplicar a situación reales como sistemas de videovigilancia o alarma en tiempo real.

9. DISCUSION

A lo largo de este trabajo se ha demostrado que el sistema es totalmente funcional y eficaz para detectar actividad en video en distintas condiciones de entorno. Las pruebas realizadas han manifestado que la combinación del modelo YOLO para la detección de

objetos con el algoritmo ORB para el seguimiento de puntos clave resulta una estrategia idónea para el sistema.

El sistema ha sido capaz de adaptarse a distintos escenarios, pero el rendimiento optimo se ha observado en escenarios con una buena iluminación en el que las detecciones han sido rápidas y precisas. Además, el sistema se ha adaptado a escenas con múltiples personas en movimiento, logrando incluso mantener el seguimiento en escenarios en los que los sujetos sufrían oclusiones parciales.

Un aspecto que destacar del sistema, ha sido la capacidad para operar e identificar los objetos en condiciones adversas, por ejemplo, en escenarios nocturnos o con iluminación baja. En estos casos, tanto YOLO como ORB vieron reducido su rendimiento, pero el sistema consiguió mantener un buen nivel de detección y seguimiento. Esto evidencia que el sistema es apto para su aplicabilidad en contextos reales de videovigilancia.

A pesar del buen rendimiento del sistema, se han identificado algunas limitaciones importantes:

- Condiciones de iluminación: En escenas con baja iluminación, las detecciones fueron menos fiables y las coincidencias disminuyeron.
- Detecciones incompletas: En situaciones en las que el sujeto aparece parcialmente o están parcialmente ocultos, el sistema tarda unos segundos más de lo normal en detectar correctamente su presencia.
- Rendimiento según el hardware: A pesar de que el sistema es totalmente funcional en CPU, el rendimiento en tiempo real se ve afectado, por lo que la ejecución ideal podría ser en entornos con GPU.

Pese a estas limitaciones, los objetivos planteados al comienzo se han cumplido con éxito. Se ha implementado un sistema de monitorea capaz de detectar actividad en video, demostrando ser capaz de identificar y seguir objetos en movimiento en distintos contextos. Además, se ha comprado que el sistema podría ser adaptado y utilizado en entornos reales de seguridad y videovigilancia.

En resumen, los resultados obtenidos demuestran el correcto funcionamiento del sistema y su futura aplicación práctica en condiciones reales. Asimismo, la evaluación de los distintos casos ha permitido entender y evaluar en que situaciones el sistema destaca y en cuales podría mejorar.

10. CONCLUSIONES Y MEJORAS FUTURAS

10.1 Conclusiones

Este Trabajo de Fin de Grado ha permitido desarrollar e implementar un sistema automático de monitoreo capaz de detectar actividad en videos, aplicando técnicas modernas de computer vision. Se ha logrado un sistema funcional, flexible y con potencial para ser aplicado en contextos de videovigilancia y seguridad a través de la combinación del modelo de detección de objetos YOLO y el algoritmo ORB para el seguimiento visual entre frames.

Las pruebas realizadas han demostrado que el sistema es eficaz en escenarios con buena visibilidad y mantiene un rendimiento más que aceptable en condiciones más complejas, como en escenarios con baja iluminación o presencia de oclusiones parciales. Además, el diseño modular y la implementación en Python han facilitado su comprensión y ejecución.

El análisis visual de las detecciones y la visualización de las coincidencias ORB, junto con la evaluación cuantitativa mediante las métricas extraídas de los videos procesados, han permitido validar tanto la precisión del sistema como su capacidad de adaptación a diferentes situaciones y escenarios.

A partir de esto, los logros más destacados de este proyecto son la correcta integración de modelos de inteligencia artificial y algoritmos clásicos en un sistema funcional de monitoreo, la capacidad del sistema para detectar y seguir personas en movimiento en videos con distintos niveles de complejidad. Además de la posibilidad de generar información útil tanto visual (videos con las anotaciones) como cuantitativa (gráficas y métricas) para el análisis.

En resumen, el sistema cumple con los objetivos iniciales y representa una base sobre la que implementar soluciones más avanzadas y específicas para aplicaciones reales en seguridad y videovigilancia.

10.2 Mejoras futuras

Aunque los resultados obtenidos han sido positivos, existen algunas mejoras que podrían perfeccionar el sistema o extender su funcionalidad:

- Clasificación inteligente de eventos: Integrar diseños que puedan distinguir clases de eventos (actividad sospechosa, caídas, robos) daría al sistema más utilidad en escenarios reales de seguridad.
- Técnicas de mejora de imagen: Usar estrategias de detección de bordes o aumento del contraste para mejorar los resultados en escenas de baja iluminación.

Estas mejoras suponen un horizonte interesante para futuras investigaciones o desarrollos, orientados a construir soluciones de videovigilancia inteligentes, autónomas y confiables.

11.IMPACTO SOCIOECONOMICO Y SOSTENIBILIDAD (ODS)

La implementación de sistemas automáticos de monitoreo y detección de actividad en video tiene un impacto directo en la mejora de la seguridad en entornos públicos y privados. Este sistema contribuye a generar espacios mas seguros, eficientes y controlados, lo que repercute directamente en la prevención de delitos o situaciones de riesgo.

Por lo tanto, el sistema desarrollado se alinea con varios Objetivos de Desarrollo Sostenible (ODS):

- ODS 9: Industria, Innovación e Infraestructura

El proyecto promueve el desarrollo de soluciones tecnológicas innovadoras basadas en inteligencia artificial computer vision, contribuyendo a la transformación digital de infraestructuras como el transporte, edificios públicos o sistemas de vigilancia.

- ODS 11: Ciudades y comunidades sostenibles

La incorporación de sistemas de videovigilancia inteligente contribuye a construir ciudades mas seguras y sostenibles. Debido a que permite mejorar la gestión de la seguridad urbana, facilitar la detección de anomalías y mejorar la respuesta ante incidentes.

- ODS 16: Paz, justicia e instituciones solidas

Promueve entornos mas seguros y pacíficos mediante una supervisión inteligente, ya que este sistema puede ser utilizado por cuerpos de seguridad para reforzar la vigilancia y anticipar conflictos.

Además, este sistema reduce la necesidad de supervisión humana constante, lo que permite optimizar recursos y mejorar la eficiencia y capacidad de respuesta ante incidentes.

12. REFERENCIAS

Amazon Web Services. (s. f.). ¿Qué es Python? - Explicación del lenguaje Python - AWS. https://aws.amazon.com/es/what-is/python/

Bochkovskiy, A., Wang, C. Y., & Liao, H. Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. https://arxiv.org/abs/2004.10934

Bradski, G. (2000). The OpenCV library. Dr. Dobb's Journal of Software Tools. https://opencv.org/

Brownlee, J. (2020). Deep learning for computer vision: Image classification, object detection, and face recognition in Python. Machine Learning Mastery.

Clasificación: Exactitud, recuperación, precisión y métricas relacionadas. (s. f.). Google For Developers. https://developers.google.com/machine-learning/crash-course/classification/accuracy-precision-recall?hl=es-419

Forsyth, D. A., & Ponce, J. (2011). Computer vision: A modern approach (2nd ed.). Pearson.

Freepik. (s. f.). Bourke Street, Melbourne [Vídeo]. https://www.freepik.com/free-video/bourke-street-melbourne_30414

Freepik. (s. f.). Coworkers talking break [Vídeo]. https://www.freepik.com/free-video/coworkers-talking-break_2870188

Freepik. (s. f.). Female realtor entering house with senior couple [Vídeo]. https://www.freepik.com/free-video/female-realtor-entering-house-with-senior-couple_473299

Freepik. (s. f.). Multiethnic young armed people running and attacking in slums [Vídeo]. https://www.freepik.com/free-video/multiethnic-young-armed-people-with-scarfs-their-faces-running-attacking-slums_477845

Freepik. (s. f.). Police officers following criminal man with modern rifle [Vídeo]. https://www.freepik.com/free-video/police-officers-following-criminal-man-with-modern-rifle-urban-building_2791993

Freepik. (s. f.). Rear view of woman paying for coffee with credit card [Vídeo]. https://www.freepik.com/free-video/rear-view-young-caucasian-woman-paying-coffe-with-credit-card-coffee-shop_475398

Freepik. (s. f.). Top view of coworkers at online meeting [Vídeo]. https://www.freepik.com/free-video/top-view-coworkers-sitting-table-online-meeting-with-red-haired-businessman_170611

Freepik. (s. f.). Two happy female friends coming to fashion store together [Vídeo]. https://www.freepik.com/free-video/two-happy-female-friends-coming-fashion-store-together_472525

Freepik. (s. f.). Two muslim businesswomen walking to work past city office buildings [Vídeo]. https://www.freepik.com/free-video/vertical-video-two-muslim-businesswomen-wearing-hijabs-with-modern-business-suits-walking-work-past-city-office-buildings_3445162

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press. https://www.deeplearningbook.org/

González, R. C., & Woods, R. E. (2018). Digital image processing (4th ed.). Pearson.

Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. Computing in Science & Engineering, 9(3), 90–95. https://doi.org/10.1109/MCSE.2007.55

JetBrains. (s. f.). PyCharm: Python IDE for professional developers. https://www.jetbrains.com/pycharm/

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single shot multibox detector. In European Conference on Computer Vision (ECCV). https://arxiv.org/abs/1512.02325

Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P., & Zitnick, C. L. (2014). *Microsoft COCO: Common Objects in Context*. In Proceedings of the European Conference on Computer Vision (ECCV). https://arxiv.org/abs/1405.0312

MathWorks. (s. f.). ¿Qué es una red neuronal convolucional? https://es.mathworks.com/discovery/convolutional-neural-network.html

NumPy Developers. (2023). NumPy: Fundamental package for scientific computing. https://numpy.org/

OpenAI. (2023). ChatGPT technical overview. https://openai.com/blog/chatgpt

Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., et al. (2019). PyTorch: An imperative style, high-performance deep learning library. In Advances in Neural Information Processing Systems (NeurIPS). https://papers.nips.cc/paper_files/paper/2019/file/bdbca288fee7f92f2bfa9f7012727740-Paper.pdf

Python Software Foundation. (2023). Python language reference, version 3.10. https://www.python.org/

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE Conference on

Computer Vision and Pattern Recognition (CVPR). https://arxiv.org/abs/1506.02640

Rublee, E., Rabaud, V., Konolige, K., & Bradski, G. (2011). ORB: An efficient alternative to SIFT or SURF. In Proceedings of the 2011 International Conference on Computer Vision (ICCV). https://doi.org/10.1109/ICCV.2011.6126544

Russell, S. J., & Norvig, P. (2021). Artificial intelligence: A modern approach (4th ed.). Pearson.

Sierra, E. A. (2024, 24 noviembre). Tutorial: Como normalizar datos con Python - Edgar Arnoldo Sierra - Medium. Medium. https://medium.com/@noyomedicen/como-normalizar-datos-con-python-4a967f3a04f8

Szeliski, R. (2022). Computer vision: Algorithms and applications (2nd ed.). Springer. https://szeliski.org/Book/

Ultralytics. (2023). YOLOv8 documentation. https://docs.ultralytics.com/

Viola, P., & Jones, M. (2001). Rapid object detection using a boosted cascade of simple features. In Proceedings of the IEEE Conference on Computer Vision

and Pattern Recognition (CVPR).

https://www.cs.cmu.edu/~efros/courses/LBMV07/Papers/viola-cvpr-01.pdf

https://github.com/PabloCampos1110/TFG-MONITOREO-ACTIVIDAD-VIDEO