



UNIVERSITAT  
POLITÈCNICA  
DE VALÈNCIA



UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Informática

Mejora de rendimiento deportivo mediante la detección de posturas por visión artificial

Trabajo Fin de Grado

Grado en Ciencia de Datos

AUTOR/A: Mira Abad, Ángela

Tutor/a: Ferri Ramírez, César

Cotutor/a: Monserrat Aranda, Carlos

Director/a Experimental: PALENCIA SANLEON, GLORIA

CURSO ACADÉMICO: 2022/2023





# Resumen

---

El uso de la tecnología de visión artificial para analizar y evaluar las posturas y los movimientos de los atletas durante la práctica deportiva está a la orden del día. El objetivo principal es aplicar estas técnicas al ejercicio de las sentadillas, una actividad fundamental en muchos programas de entrenamiento y deportes.

Para lograrlo, se empleará un enfoque basado en el aprendizaje automático supervisado. Se recopilará un conjunto de datos que constará de vídeos clasificados como ejecuciones correctas o incorrectas del ejercicio de sentadillas. Estos vídeos servirán como muestra para entrenar modelos de clasificación, como Máquinas de Vectores de Soporte (SVM), árboles de decisión y regresión logística.

Una vez que los modelos estén entrenados, se utilizarán para analizar nuevos vídeos de personas realizando sentadillas. El objetivo será determinar si la ejecución del ejercicio es correcta o si se cometen errores. En caso de detectar una ejecución incorrecta, se utilizarán los datos de las ejecuciones correctas como referencia para ofrecer recomendaciones específicas sobre cómo corregir la técnica y mejorar el rendimiento deportivo.

Además de la clasificación de las ejecuciones, se explorará la posibilidad de extraer y analizar características específicas de los vídeos, como la postura, la alineación de las articulaciones, la estabilidad y otros aspectos relevantes para el rendimiento deportivo. Esto permitirá obtener información adicional sobre los errores comunes y las áreas que requieren más atención en la técnica de las sentadillas.

**Palabras clave:** rendimiento deportivo, visión artificial, aprendizaje automático, clasificación de vídeos, *SVM*, árboles de decisión, regresión logística, análisis de postura, *MediaPipe*.



# Abstract

---

The use of computer vision technology to analyze and evaluate the postures and movements of athletes during sports practice is commonplace. The main objective is to apply these techniques to the squat exercise, which is a fundamental activity in many training programs and sports.

To achieve this, a supervised machine learning approach will be employed. A dataset will be collected, consisting of videos classified as either correct or incorrect executions of the squat exercise. These videos will serve as training samples for classification models, such as Support Vector Machines (SVM), decision trees, and logistic regression.

Once the models are trained, they will be used to analyze new videos of individuals performing squats. The goal will be to determine whether the exercise execution is correct or if any errors are being made. In case an incorrect execution is detected, the data from correct executions will be used as a reference to provide specific recommendations on how to correct the technique and improve sports performance.

In addition to the classification of executions, the possibility of extracting and analyzing specific features from the videos, such as posture, joint alignment, stability, and other relevant aspects to sports performance, will be explored. This will provide additional insights into common errors and areas that require more attention in squat technique.

**Keywords :** sports performance, computer vision, machine learning, video classification, SVM, decision trees, logistic regression, posture analysis, MediaPipe.



# Índice de contenidos

---

1.	Introducción .....	12
1.1.	Motivación.....	12
1.2.	Objetivos .....	13
1.3.	Estructura del TFG .....	14
2.	Marco Contextual .....	15
2.1.	Inteligencia artificial.....	15
2.2.	Visión por computador .....	15
2.3.	Modelos de estimación de pose humana.....	16
2.3.1.	Diferencia entre estimación de pose 2D y 3D .....	16
2.3.2.	Tipos de modelos de estimación de poses humanas.....	18
2.3.3.	Bibliotecas para la estimación de la pose humana .....	18
2.4.	Machine learning.....	20
2.4.1.	¿Qué es el machine learning? .....	20
2.4.2.	Procedimiento para realizar un proyecto de Machine learning .....	21
2.4.3.	Principales algoritmos de machine learning.....	22
2.5.	Crítica y propuesta al marco contextual.....	27
2.5.1.	Trabajos previos relacionados .....	27
2.5.2.	Propuesta.....	28
3.	Metodología .....	29
3.1.	Datos.....	29
3.1.1.	Vídeos.....	29
3.1.2.	Librería <i>MediaPipe</i> .....	30
3.1.3.	Cálculo de ángulos de interés .....	31
3.1.4.	Limpieza de datos .....	35
3.1.5.	Extracción de características significativas.....	35
3.1.6.	Análisis de las características significativas.....	36
3.2.	Modelos de clasificación.....	44
3.2.1.	Máquina de Vector Soporte (SVM) .....	45
3.2.2.	Árbol de decisión .....	46
3.2.3.	Regresión logística .....	47
3.3.	Normalización de los datos .....	47
3.4.	Métricas de validación .....	48

4.	Resultados.....	51
4.1.	Resultados de los modelos de clasificación.....	51
4.1.1.	Resultados modelo SVM .....	51
4.1.2.	Resultados modelo Árbol de decisión .....	56
4.1.3.	Resultados Regresión logística .....	57
4.1.4.	Comparación de los tres modelos.....	57
5.	Conclusiones .....	59
5.1.	Conclusiones del estudio.....	59
5.1.1.	Clasificar un nuevo vídeo .....	59
5.1.2.	Caso clasificado como “bien” .....	60
5.1.3.	Caso clasificado como “mal” .....	61
5.2.	Conclusiones personales .....	63
5.3.	Legado .....	64
5.4.	Trabajos futuros .....	64
5.5.	Relación del trabajo desarrollado con los estudios cursados .....	65
	Referencias .....	66
	Anexo I: Objetivos de desarrollo sostenible.....	69
	Anexo 2: Gráficos de los modelos .....	71



# Índice de figuras

Figure 1: Estimación de pose 2D. ....	17
Figure 2: Estimación de pose 3D.....	17
Figure 3: Ejemplo arquitectura método de estimación de pose humana mediante OpenPose.....	19
Figure 4: Puntos clave MediaPipe. ....	20
Figure 5: Ejemplo gráfico de Hould method. ....	22
Figure 6: Ejemplo de árbol de decisión forma genérica.....	24
Figure 7: Ejemplos de hiperplanos en 2D y 3D. ....	25
Figure 8: Posible hiperplano .....	25
Figure 9: Hiperplano óptimo. ....	25
Figure 10: Ejemplos visuales de margen suave y margen duro. ....	26
Figure 11: Ejemplo regresión logística. ....	27
Figure 12: Ejemplo de frames de un vídeo extraído de internet. ....	29
Figure 13: Ejemplo de frames de un vídeo particular. ....	29
Figure 14: Puntos clave mediante MediaPipe .....	32
Figure 15: Triángulo formado por los puntos clave mediante MediaPipe. ....	33
Figure 16: Ángulos calculados. ....	34
Figure 17: Ejemplo de datos de un vídeo clasificado como "bien".....	34
Figure 18: Ejemplo de datos de un vídeo clasificado como "mal".....	35
Figure 19: Ejemplo de datos con las características significativas por vídeo (aquí solo se muestran las características significativas del ángulo de la rodilla). ....	36
Figure 20: Boxplot Medias ángulo de la cadera. Fuente: Elaboración propia.....	37
Figure 21: Boxplot Medianas ángulo de la cadera. Fuente: Elaboración propia.....	37
Figure 22: Boxplot Máximos ángulo de la cadera. Fuente: Elaboración propia.....	38
Figure 23: Boxplot Mínimos ángulo de la cadera. Fuente: Elaboración propia. ....	38
Figure 24: Boxplot Desviación estándar ángulo de la cadera. Fuente: Elaboración propia.....	38
Figure 25: Boxplot Medias ángulo del hombro. Fuente: Elaboración propia.....	39
Figure 26: Boxplot Medianas ángulo del hombro. Fuente: Elaboración propia.....	39
Figure 27: Boxplot Máximos ángulo del hombro. Fuente: Elaboración propia.....	40
Figure 28: Boxplot Mínimos ángulo del hombro. Fuente: Elaboración propia.....	40
Figure 29: Boxplot Desviación estándar ángulo del hombro. Fuente: Elaboración propia.....	40
Figure 30: Boxplot Medias ángulo del codo. Fuente: Elaboración propia.....	41
Figure 31: Boxplot Medianas ángulo del codo. Fuente: Elaboración propia. ....	42
Figure 32: Boxplot Máximos ángulo del codo. Fuente: Elaboración propia.....	42
Figure 33: Boxplot Mínimos ángulo del codo. Fuente: Elaboración propia. ....	42
Figure 34: Boxplot Desviación estándar ángulo del codo. Fuente: Elaboración propia.....	42
Figure 35: Boxplot Medias ángulo de la rodilla. Fuente: Elaboración propia. ....	43
Figure 36: Boxplot Mediana ángulo de la rodilla. Fuente: Elaboración propia.....	43
Figure 37: Boxplot Máximos ángulo de la rodilla. Fuente: Elaboración propia. ....	43
Figure 38: Boxplot Mínimos ángulo de la rodilla. Fuente: Elaboración propia. ....	43
Figure 39: Boxplot Desviación Estándar ángulo de la rodilla. Fuente: Elaboración propia.....	44
Figure 40: Ejemplo de matriz de confusión.....	48

Figure 41: Matriz de confusión modelo 1 SVM sin normalizar. ....	52
Figure 42: Precisión medida VS Valor de k. Fuente: Elaboración propia.....	53
Figure 43: Matriz de confusión modelo 2 SVM sin normalizar. ....	53
Figure 44: Matriz de confusión modelo 2 SVM normalizando. ....	54
Figure 45: Matriz de confusión modelo 2 SVM sin normalización. ....	55
Figure 46: Excel con los datos por cada frame de un vídeo nuevo. ....	60
Figure 47: Excel con las características de los ángulos (solo se ven las de la rodilla)....	60
Figure 48:Ejemplo de superposición visual cuando se clasifica como “bien”. ....	61
Figure 49: Matriz de confusión Modelo 1 árbol de decisión sin normalizar. Fuente: Elaboración propia. ....	71
Figure 50: Matriz de confusión Modelo 1 árbol de decisión con normalización. Fuente: Elaboración propia. ....	71
Figure 51:Matriz de confusión Modelo 2 árbol de decisión sin normalizar. Fuente:Elaboración propia.....	72
Figure 52:Gráfico precisión media VS valor de k Modelo 2 árbol de decisión sin normalizar. Fuente: Elaboración propia. ....	72
Figure 53: Matriz de confusión Modelo 2 árbol de decisión con normalización. Fuente: Elaboración propia. ....	72
Figure 54:Gráfico precisión media VS valor de k Modelo 2 árbol de decisión con normalización. Fuente: Elaboración propia.....	73
Figure 55: Matriz de confusión Modelo 3 árbol de decisión sin normalización. Fuente: Elaboración propia. ....	73
Figure 56: Matriz de confusión Modelo 3 árbol de decisión con normalización. Fuente: Elaboración propia. ....	74
Figure 57:Matriz de confusión Modelo 1 regresión logística sin normalización. Fuente: Elaboración propia. ....	74
Figure 58:Matriz de confusión Modelo 1 regresión logística con normalización. Fuente: Elaboración propia. ....	75
Figure 59:Matriz de confusión Modelo 2 regresión logística sin normalización. Fuente: Elaboración propia. ....	75
Figure 60: Precisión media VS valor de k Modelo 2 regresión logística. Fuente:Elaboración propia.....	75
Figure 61:Matriz de confusión Modelo 2 regresión logística con normalización. Fuente: Elaboración propia. ....	76
Figure 62: Precisión media VS valor de k Modelo 2 regresión logístitca. Fuente: Elaboración propia. ....	76
Figure 63: Matriz de confusión Modelo 3 regresión logística sin normalización. Fuente: Elaboración propia. ....	76
Figure 64: Matriz de confusión Modelo 3 regresión logística con normalización. Fuente: Elaboración propia. ....	77



## Índice de siglas

---

DAG	Grafo Acíclico Dirigido
FN	Falso Negativo o <i>False Negative</i>
FP	Falso Positivo o <i>False Positive</i>
IA	Inteligencia Artificial
SVM	Máquinas de Vectores de Soporte o <i>Support-Vector Machines</i>
TIC	Tecnologías de la Información y las Comunicaciones
TN	Verdadero Negativo o <i>True Negative</i>
TP	Verdadero Positivo o <i>True Positive</i>



# 1. Introducción

---

Para que los deportistas se integren plenamente en la Sociedad Inteligente, es fundamental aprovechar de manera eficiente las tecnologías avanzadas basadas en las TIC (Tecnologías de la Información y la Comunicación). En los últimos años, la visión artificial ha revolucionado diversos campos, y el deporte no ha sido la excepción. Esta tecnología se ha convertido en una herramienta para evaluar el análisis y la mejora del rendimiento deportivo, permitiendo el seguimiento y análisis en tiempo real de los movimientos de los atletas. Mediante el uso de cámaras, sensores y algoritmos de procesamiento de imágenes, se pueden recopilar datos precisos sobre la técnica y el movimiento de los deportistas durante el entrenamiento y la competición.

La aplicación de este análisis visual abarca una amplia gama de deportes, como el fútbol, baloncesto, tenis y atletismo, entre otros. Los datos recopilados resultan fundamentales para evaluar el rendimiento de los atletas, identificar errores técnicos y proporcionar *feedback* en tiempo real para mejorar su desempeño.

Además, la visión artificial también se puede emplear para monitorear el estado físico de los atletas, lo que posibilita la detección temprana de lesiones y la prevención de posibles daños a largo plazo.

En adición, la visión artificial en el deporte no solo se limita al análisis del rendimiento y la prevención de lesiones, sino que también está revolucionando la forma en que los espectadores disfrutan y se involucran en los eventos deportivos. Mediante la aplicación de tecnologías innovadoras, como la realidad aumentada y la transmisión en vivo con información en tiempo real, los aficionados pueden experimentar una nueva dimensión de inmersión en los partidos y competiciones. Todo esto abre la puerta a la creación de experiencias interactivas, en las que los seguidores pueden acceder a las estadísticas, repeticiones instantáneas y análisis detallados de jugadas clave.

Por tanto, la visión artificial aplicada a deporte es una herramienta sumamente valiosa que no solo contribuye a optimizar el rendimiento deportivo, sino que también ayuda a la prevención de lesiones y proporciona otros beneficios. En este trabajo se explorará los diversos usos de la visión artificial en el ámbito deportivo y su potencial para mejorar el desempeño de los atletas.

## 1.1. Motivación

Desde que se descubrió el potencial de la tecnología de la visión artificial en el análisis deportivo, ha surgido un entusiasmo creciente por su aplicación en este ámbito. Si bien la visión artificial ofrece un gran potencial para mejorar el rendimiento deportivo, también desempeña un papel crucial en la prevención de lesiones.

Gracias a su capacidad para analizar grandes volúmenes de datos en tiempo real, la visión artificial puede detectar patrones y anomalías en los movimientos y la postura de los deportistas. Esto resulta especialmente relevante al abordar la corrección de la técnica de ejercicios específicos, como las sentadillas. Al utilizar algoritmos de procesamiento de imágenes, se pueden identificar desviaciones y errores en la ejecución de los movimientos, lo que permite a los entrenadores y atletas corregir y mejorar su postura, reduciendo así el riesgo de lesiones musculoesqueléticas.

Al prevenir las lesiones, la tecnología de la visión artificial puede tener un impacto significativo en términos de reducción de costes tanto para la seguridad social como para los equipos deportivos. Las lesiones deportivas pueden dar lugar a gastos médicos y de rehabilitación sustanciales, además de implicar periodos prolongados de inactividad y pérdida de rendimiento. Al utilizar esta tecnología como una herramienta de prevención de lesiones, se puede disminuir la incidencia de problemas musculares y una mayor disponibilidad de los deportistas para competir y entrenar.

Esto no solo beneficia la salud de los atletas, sino que también tiene un impacto económico positivo al disminuir los costes relacionados con las lesiones.

## 1.2. Objetivos

El objetivo general de este trabajo consiste en:

Mejorar el rendimiento deportivo utilizando técnicas de visión artificial, específicamente enfocándose en el ejercicio de las sentadillas. Se busca desarrollar un sistema que pueda analizar la ejecución de las sentadillas y proporcionar retroalimentación precisa sobre la técnica del ejercicio.

Los objetivos intermedios necesarios para poder cumplir el objetivo general son:

- Recopilar un conjunto de datos: Se requerirá recopilar un conjunto de vídeos que muestren ejecuciones de sentadillas, clasificados previamente como correctos o incorrectos. Estos vídeos servirán como base de entrenamiento para los modelos de clasificación.
- Analizar la postura del humano en los vídeos: Se utilizará la biblioteca de *MediaPipe* para analizar la postura del cuerpo humano en los vídeos de las ejecuciones de sentadillas. Esto permitirá extraer información sobre la alineación de las articulaciones, la estabilidad y otros aspectos relevantes para el rendimiento deportivo.
- Entrenar modelos de clasificación: Se utilizarán técnicas de aprendizaje automático, como SVM, árboles de decisión y regresión logística, para entrenar modelos capaces de clasificar las ejecuciones de las sentadillas como correctas o incorrectas.
- Proporcionar retroalimentación y recomendaciones: En caso de que se detecte una ejecución incorrecta, se utilizarán los datos de las ejecuciones correctas para ofrecer recomendaciones específicas sobre cómo corregir la técnica y mejorar el rendimiento.

Al cumplir estos objetivos intermedios, se logrará el objetivo general del TFG de mejorar el rendimiento deportivo mediante el uso de visión artificial en el ejercicio de las sentadillas. El sistema desarrollado podrá proporcionar a los usuarios una retroalimentación precisa sobre su ejecución y recomendaciones específicas para perfeccionar su técnica y obtener mejores resultados en términos de fuerza, estabilidad y prevención de lesiones.



### **1.3. Estructura del TFG**

A continuación, se describen la secuencia y el contenido básico de los cinco capítulos fundamentales que conforman este Trabajo Final de Grado (TFG).

El trabajo comienza con un capítulo introductorio que establece las intenciones y objetivos de la investigación.

En segundo lugar, se establece el contexto del tema mediante la definición detallada de conceptos relevantes como visión artificial, modelos de estimación de pose humana, aprendizaje automático, así como la explicación de los modelos que serán desarrollados. Adicionalmente, se presentan las investigaciones previas relacionadas, brindando así un marco teórico sólido para sustentar el trabajo.

Luego, se describe la metodología utilizada para la ejecución del proyecto, incluyendo detalles sobre los datos que se van a utilizar y los métodos de evaluación/validación de los modelos propuestos.

Después, se presentan y analizan los resultados obtenidos en el estudio.

El capítulo de conclusiones relaciona los objetivos establecidos en la introducción con las conclusiones del estudio y ofrece propuestas de mejora y discusión de las limitaciones encontradas.

También se identifica un posible legado beneficioso para los interesados y se proporcionan recomendaciones para futuros trabajos en esta línea de investigación.

## 2. Marco Contextual

---

En este capítulo, se exploran diversas opciones que se emplean actualmente para abordar los dos problemas fundamentales de nuestro proyecto: la captura de los puntos clave del cuerpo humano y la utilización de estos en modelos de aprendizaje automático para cumplir los objetivos.

### 2.1. Inteligencia artificial

La inteligencia artificial (IA) se refiere a la capacidad de una máquina para mostrar rasgos comunes a los humanos, como la creatividad, el aprendizaje y la capacidad de planificación.

La IA permite que los sistemas tecnológicos interactúen con su entorno, lo perciban, resuelvan problemas y actúen con un propósito. La máquina recibe datos, los procesa (ya sean datos preparados o se hayan recopilado usando uno de sus propios sensores, como una cámara) y luego reacciona ante ellos.

Los sistemas de inteligencia artificial pueden funcionar de forma independiente, analizar los resultados de acciones anteriores y adaptar su comportamiento hasta cierto punto (Noticias Parlamento Europeo, 2021)

### 2.2. Visión por computador

La visión artificial o *computer vision* hace referencia a un grupo de tecnologías o herramientas que permiten a los equipos capturar imágenes del mundo real, procesarlas y generar información (análisis) a partir de ellas. En otras palabras, la visión artificial es propiedad de ciertas tecnologías que permiten a los dispositivos informáticos “ver”. Esto permite el desarrollo de máquinas industriales y colaborativas altamente flexibles que pueden tomar decisiones inteligentes basadas en su entorno más allá del alcance del ojo humano.

Los sistemas de visión por computadora generalmente usan algoritmos matemáticos para decodificar imágenes y respaldar su operación con *software* de inteligencia artificial que reconoce formas y patrones en imágenes. Este *software* se puede utilizar para obtener respuestas como comparar, recuperar, mover o eliminar, entre otros. Dado que cada sistema es único, los métodos de aprendizaje varían, pero generalmente se pueden dividir en dos categorías:

- Instrucciones guiadas: Están preclasificadas, ordenadas e interpretadas. Significa que el sistema se acostumbra a los patrones de imágenes y reacciona de cierta manera.
- Enseñanza autónoma: Se utiliza normalmente en sistemas de alto rendimiento diseñados para entornos más complejos. La técnica consiste en asignar a la IA un conjunto de reglas básicas para reconocer patrones o interpretar imágenes. El proceso de aprendizaje es lento y complejo, pero el sistema puede reconocer nuevos patrones por sí mismo.

Dada la diversidad de dispositivos disponibles en el mercado que dependen de la visión por computadora para su funcionamiento, se presentan numerosos objetivos y capacidades potenciales para estos sistemas. En esencia, las características fundamentales de esta tecnología se pueden resumir en las siguientes funcionalidades:



- Reconocimiento de objetos: La idea de enseñar a una computadora a reconocer patrones en imágenes es distinguir, separar y clasificar objetos. De esta forma, puede utilizar los datos reales para controlar el comportamiento del *hardware*.
- Análisis de imágenes o vídeos: Analizar grandes cantidades de imágenes o vídeos es una tarea compleja para el ojo humano, pero los sistemas de inteligencia artificial pueden hacerlo en segundos. Esto lo convierte en un poderoso aliado para detectar patrones complejos.
- Comparación estadística: Los sistemas de visión por computadora pueden usar múltiples técnicas de imágenes no solo para reconocer un objeto, sino también para identificar instantáneamente múltiples características de este. De esta forma, se puede realizar un control detallado, comparación y análisis de objetos más allá de la localización en un nivel.

Percibir el entorno es uno de los pilares funcionales de los modernos sistemas industriales gracias a su eficiencia. Como resultado, la disponibilidad de esta tecnología se está generalizando cada vez más. Por ejemplo, en la industria productiva: equipos electrónicos, alimentaria, automoción, logística y seguridad (EDS Robotics, 2022)

### **2.3. Modelos de estimación de pose humana**

La estimación de la pose humana es una tarea de visión artificial que captura y representa de forma gráfica la postura y posición del cuerpo humano. Esta técnica se utiliza a menudo para predecir las posiciones de las partes y articulaciones del cuerpo humano.

Se trata de identificar y clasificar las poses de las partes y articulaciones del cuerpo humano en imágenes o vídeos. Las técnicas basadas en modelos se usan comúnmente para representar e inferir poses humanas en espacios 2D y 3D. Esencialmente, esta es una forma de obtener un conjunto de coordenadas definiendo las articulaciones del cuerpo humano. Las muñeca, hombro, rodillas, ojos, brazos y tobillos son puntos centrales en imágenes y vídeos que pueden representar la postura de una persona.

Luego, cuando se proporciona una imagen o video como entrada a un modelo de estimación de pose, las coordenadas de las partes del cuerpo y las articulaciones detectadas se identifican como salida, junto con un valor de confianza que indica la precisión de la estimación.

#### **2.3.1. Diferencia entre estimación de pose 2D y 3D**

Por una parte, está la estimación de pose 2D. Este tipo de estimación simplemente estima las posiciones de las articulaciones del cuerpo en el espacio D con respecto a los datos de entrada (como imágenes o cuadros de vídeo). La posición se muestra como las coordenadas X e Y de cada punto clave.

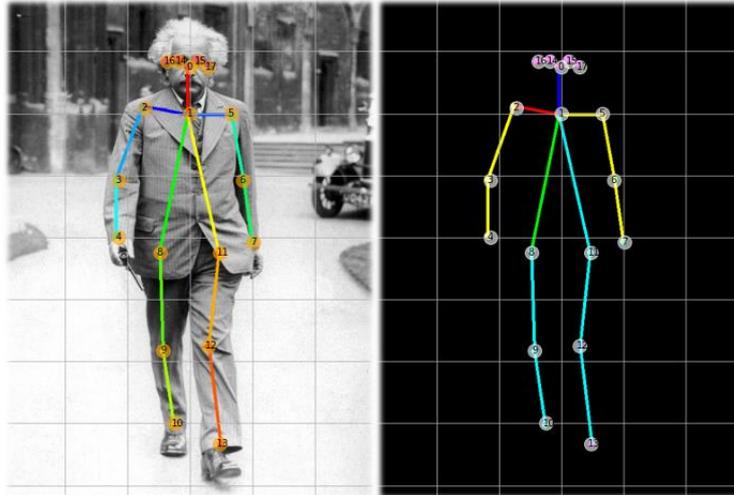


Figure 1: Estimación de pose 2D.  
 Fuente: Realtime Multiple Person 2D Pose Estimation using TensorFlow2.x (Rovai, 2020).

Por otro lado, la estimación de pose 3D transforma una imagen 2D en un objeto 3D mediante la estimación de una dimensión Z adicional para la predicción. La estimación de pose 3D le permite predecir la posición espacial exacta de una persona.

Image	Ground Truth	EpipolarPose (FS)	EpipolarPose (SS)

Figure 2: Estimación de pose 3D.  
 Fuente: Research Gate (Kocabas, 2019).

### 2.3.2. Tipos de modelos de estimación de poses humanas

Hay tres tipos principales de modelos que se utilizan para interpretar el cuerpo humano en planos 2D y 3D (Zephyrnet, 2023):

- Modelo basado en el esqueleto: También llamado modelo cinemático, este modelo representativo incluye un conjunto de puntos clave, es decir, las articulaciones. Este modelo simple e intuitivo se usa a menudo para comprender la estructura esquelética del cuerpo humano y capturar las relaciones entre las diferentes partes del cuerpo.
- Modelo basado en la forma: También conocido como modelo plano, utilizado para la estimación 2D, con una forma y anchos aproximados del cuerpo, las extremidades y el torso. Básicamente, se representa el contorno y la forma del cuerpo humano y las partes del cuerpo se representan con límites y rectángulos del contorno de una persona.
- Modelo basado en volumen: También llamado modelo volumétrico, se utiliza para la estimación 3D. Muchos modelos y formas populares del cuerpo humano en 3D se representan como mallas y geometrías humanas capturadas para una estimación profunda del cuerpo humano en 3D.

### 2.3.3. Bibliotecas para la estimación de la pose humana

#### 2.3.3.1. *OpenPose*

*OpenPose* es una biblioteca de visión por computadora y aprendizaje profundo desarrollada por CMU que se utiliza para estimar la pose humana. Es el primer sistema multiusuario en tiempo real. Reconoce conjuntamente 135 puntos clave en cada imagen individual, incluidos los puntos clave del cuerpo humano, la cara, la mano y el pie. Los creadores han lanzado en forma de código como *Python*, implementación de *C++* y complemento de *Unity*. El repositorio de (Hidalgo, y otros, s.f.) contiene estos recursos, que se pueden descargar.

La arquitectura de *OpenPose*, como se puede ver en la *Figure 3* se basa en una red neuronal convolucional profunda llamada “*Real-Time Multi-Person Pose Estimation*” (Estimación en tiempo real de poses de múltiples personas). Esta arquitectura consta de tres etapas principales:

1. Red convolucional para la extracción de características: En esta etapa inicial, una red convolucional, como *VGGNet* o *ResNet*, se utiliza para extraer características significativas de la imagen de entrada. Esta red convolucional se entrena previamente en grandes conjuntos de datos para aprender a reconocer características relevantes en las imágenes, como bordes, texturas y formas.
2. Red de detección de pose: Después de la extracción de características, se pasa la salida de la red convolucional a la red de detección de poses. Esta etapa se encarga de generar mapas de calor que indican la probabilidad de que una articulación específica esté presente en cada píxel de la imagen. Cada articulación tiene su propio mapa de calor asociado, lo que permite localizar las articulaciones clave en la imagen. Además de los mapas de calor, se generan también mapas adicionales para indicar la presencia de personas en diferentes escalas.
3. Red de asociación en partes: En la última etapa, la red de asociación en partes utiliza los mapas de calor generados anteriormente junto con los descriptores de características para inferir las conexiones entre las articulaciones y estimar las relaciones espaciales entre ellas. Estos descriptores de características se denominan “*Part Affinity Fields*” (Campos de afinidad de partes) y se utilizan para determinar cómo se relacionan las articulaciones

entre sí, como la conexión entre la muñeca y el codo o entre el hombro y la cadera. La red de asociación de partes utiliza técnicas de agrupación y filtrado para generar una representación completa y precisa de la pose humana.

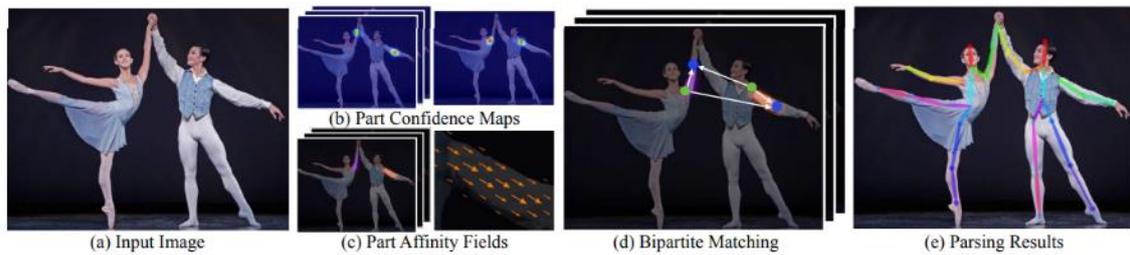


Figure 3: Ejemplo arquitectura método de estimación de pose humana mediante OpenPose.

Fuente: Barcenola Geeks (Greyrat, 2022).

En cada etapa de la arquitectura, se utilizan capas convolucionales, capas de agrupación y capas completamente conectadas para procesar y fusionar la información de manera efectiva. Esta arquitectura ha demostrado ser capaz de realizar estimaciones de pose en tiempo real y con precisión, incluso en escenarios con múltiples personas y solapamientos.

Esta arquitectura ha sido desarrollada y refinada a través de investigaciones y trabajos relacionados, como el trabajo de (Cao, Simon, Wei, & Sheikh, 2017) sobre la estimación en tiempo real de poses de múltiples personas utilizando campos de afinidad.

### 2.3.3.2. *MediaPipe*

*MediaPipe* es una plataforma de procesamiento de datos multimedia desarrollada por *Google Research* (Google, s.f.). Proporciona un conjunto de herramientas y bibliotecas de software que permiten el desarrollo de aplicaciones y sistemas de análisis de datos multimedia en tiempo real. *MediaPipe* se destaca por su capacidad de procesamiento eficiente, su flexibilidad y su capacidad para funcionar en una amplia variedad de plataformas, incluyendo dispositivos móviles, computadoras de escritorio y servidores en la nube.

La arquitectura de *MediaPipe* se basa en el enfoque de gráficos de flujo de datos. En esta arquitectura, las tareas de procesamiento se representan como nodos en un gráfico dirigido acíclico (DAG) donde los nodos representan los diferentes componentes de procesamiento y las aristas del gráfico representan el flujo de datos entre los componentes. Esto permite un diseño modular y escalable, donde los desarrolladores pueden combinar y conectar diferentes componentes de procesamiento de manera flexible.

*MediaPipe* proporciona una amplia gama de componentes predefinidos para el procesamiento de datos multimedia, incluyendo algoritmos de visión por computadora, detección y seguimiento de objetos, reconocimiento facial, detección de poses humanas, entre otros. Estos componentes se pueden utilizar y combinar de manera flexible para crear *pipelines* de procesamiento personalizados según las necesidades específicas de la aplicación.

Con una precisión impresionante, *MediaPipe* es capaz de identificar y seguir 33 puntos clave (podemos observarlos en la *Figure 4*) en el cuerpo humano, como las articulaciones de las manos, codos, rodillas y más. Estos puntos permiten un seguimiento desarrollado y preciso del



movimiento corporal, lo que facilita la creación de aplicaciones y sistemas interactivos basados en gestos y reconocimiento de posturas.

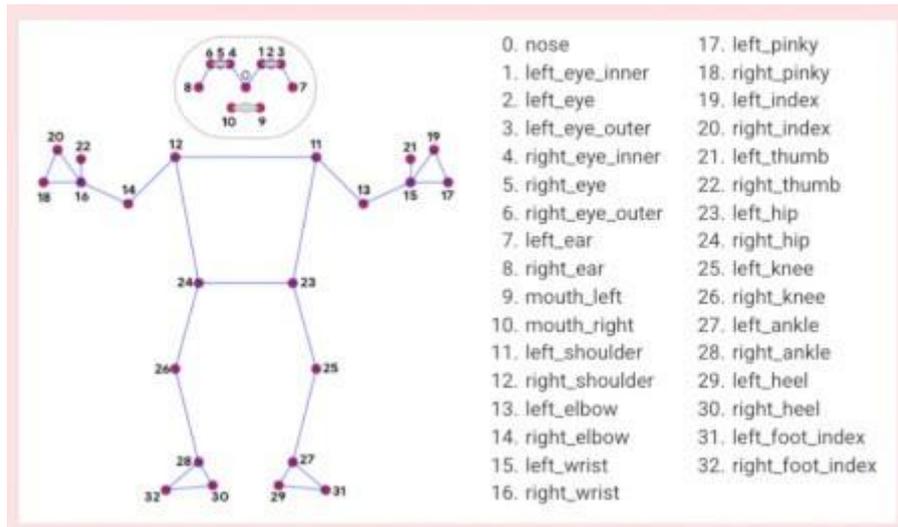


Figure 4: Puntos clave MediaPipe.  
Fuente: Omes (Omes, 2021).

El flujo de trabajo en esta biblioteca generalmente implica los siguientes pasos:

1. Captura de datos: *MediaPipe* proporciona interfaces para la adquisición de datos multimedia, como imágenes, vídeos o secuencias de imágenes. Estos datos pueden provenir de fuentes en tiempo real, como cámaras, o de archivos almacenados.
2. Procesamiento de datos: Los datos capturados se pasan a través del gráfico de flujo de datos de *MediaPipe*, donde se aplican diferentes componentes de procesamiento para realizar tareas específicas, como la detección de poses humanas, el reconocimiento facial o la segmentación de objetos.
3. Análisis y salida de datos: Una vez que los datos han sido procesados, los resultados se pueden analizar y utilizar para generar visualizaciones, tomar decisiones o realizar acciones específicas según la aplicación. Estos resultados también se pueden enviar a otras aplicaciones o sistemas para su posterior procesamiento o visualización.

## 2.4. Machine learning

### 2.4.1. ¿Qué es el machine learning?

El aprendizaje automático, también conocido como *machine learning*, es un subcampo de la inteligencia artificial que tiene como objetivo dotar a las máquinas de la capacidad de aprender de su experiencia sin necesidad de intervención humana. Las computadoras pueden aprender a completar tareas sin programación explícita gracias a los algoritmos de aprendizaje automático. Hacen uso de la información que se les proporciona para encontrar patrones que conduzcan al conocimiento y, en consecuencia, les ayudan a tomar mejores decisiones (Gupta M. , 2019).

Por lo tanto, el objetivo principal del *machine learning* es predecir resultados interesantes en función de los datos de entrada. Los algoritmos de aprendizaje automático utilizan técnicas que enriquecen y afinan a medida que se entrenan con nuevos datos. Como resultado, según los datos

disponibles, los algoritmos funcionan mejor. Cuando los datos son más representativos y abundantes, el aprendizaje es más sólido y los resultados son más precisos.

El reciente aumento de popularidad de este aprendizaje está directamente relacionado con la creciente accesibilidad de grandes volúmenes y diversidad de datos, el procesamiento computacional más asequible y potente, y la simplicidad del almacenamiento de los datos que es posible gracias a la computación en la nube (Xenopoulos, 2017). *Big Data* es una tecnología que ha surgido en los últimos años como resultado de la producción y acumulación de cantidades masivas de datos de varias fuentes por parte de muchas industrias diferentes. La necesidad de desarrollar herramientas que puedan procesarlas ha aumentado porque de esta información se puede extraer conocimiento útil para que las empresas y los gobiernos tomen mejores decisiones. El aprendizaje automático ha sido una de las herramientas más efectivas.

Los algoritmos de aprendizaje automático son responsables de muchos desarrollos y nuevos usos de la inteligencia artificial. Se utiliza, por ejemplo, en el automóvil autónomo de *Google*, los sistemas de recomendaciones de *Netflix* y *YouTube* y los asistentes de voz como *Siri* y *Alexa* (Keshari, 2023).

#### **2.4.2. Procedimiento para realizar un proyecto de Machine learning**

El procedimiento para realizar un proyecto de *machine learning* consta de cinco fases:

1. La primera etapa consiste en recopilar los datos necesarios para el proyecto. Podrían existir diferentes formatos para estos datos. Con más calidad, cantidad y variedad en los datos, los resultados finales serán más precisos. Estas características facilitan la identificación de patrones relevantes y la predicción de resultados.
2. A continuación, es conveniente la limpieza de los datos. En la mayoría de los casos, los datos recopilados son incompletos. Cuando son valores numéricos, dependiendo del tipo de variable o del objetivo del estudio, es útil compensar esos valores faltantes por el valor promedio o la moda del atributo, entre otros. Para los atributos categóricos, la mejor opción es la moda, que es el valor que se repite con más frecuencia. En ambos casos, se puede estimar a partir de otros valores de atributos. De manera similar, la información puede estar en un formato que el dispositivo no puede entender, como imágenes o vídeos. En este caso, debe convertirse en una lista o secuencia de números.
3. Posteriormente, se crean las particiones de entrenamiento y validación como subconjunto de datos de la base original. El modelo se crea utilizando datos de entrenamiento y su eficacia se evalúa utilizando datos de prueba. Para asegurar la independencia de los datos utilizados (Scikit Learn, s.f.), se utiliza la técnica de validación cruzada (*cross-validation*) para calcular el error de predicción en el modelo introducido. Los datos utilizados para entrenar el modelo y los datos utilizados para evaluarlo deben diferir. La precisión del modelo aumentará a medida que disminuya el error. La validación cruzada puede realizarse de varias formas:
  - 3.1. *Holdout method*: es el tipo más popular. Todos los datos se dividen en dos grupos al azar: datos de entrenamiento y datos de prueba (Kumar, 2020). Alrededor del 80% de los datos totales se componen de los datos de entrenamiento, que se utilizan para construir el modelo. Por otra parte, alrededor del 20% de los datos restantes son datos de prueba, que se utilizan para evaluar la eficacia del modelo. Los datos se dividen



aleatoriamente en este modelo, lo cual es un inconveniente, y como resultado, una de las dos categorías podría contener patrones no observados.

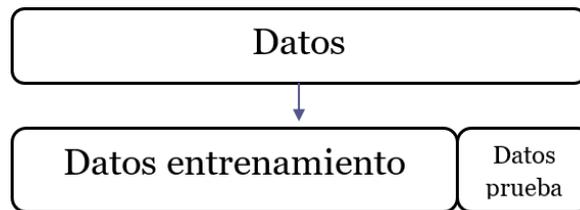


Figure 5: Ejemplo gráfico de Hould method.  
Fuente: Elaboración propia.

3.2. *K-fold cross validation*: el conjunto de datos se divide en  $k$  subconjuntos de tamaño aproximadamente igual. Cada subconjunto se denomina *k-fold*. Se realiza un ciclo de  $k$  iteraciones, en las que cada una de las *k-fold* se selecciona como conjunto de prueba y las restantes  $k-1$  folds se utilizan como conjunto de entrenamiento. En cada iteración, el modelo se entrena utilizando el conjunto de entrenamiento y luego se evalúa su rendimiento utilizando el conjunto de prueba. Se calcula una métrica de evaluación, como precisión, exactitud o *F1-score*. Después de completar las  $k$  iteraciones, se obtiene una medida de rendimiento promediando los resultados de evaluación obtenidos en cada iteración.

La ventaja de este tipo de validación cruzada es que permite utilizar todos los datos disponibles tanto para entrenar como para evaluar los modelos. Además, al realizar  $k$  iteraciones y promediar los resultados, se obtiene una estimación más robusta del rendimiento del modelo. La principal desventaja es el mayor requisito computacional del método con respecto al anterior (Kumar, 2020).

3.3. *Leave one out cross validation*: es una instancia del método de validación cruzada *k-fold* donde  $k$  es igual a la cantidad total de datos. Como resultado, el modelo genera la misma cantidad de errores que datos. La longitud de los cálculos requeridos es su principal inconveniente (Kumar, 2020).

### 2.4.3. Principales algoritmos de machine learning

#### 2.4.3.1. Aprendizaje supervisado

El aprendizaje supervisado es un enfoque del aprendizaje automático en el que se entrena un modelo utilizando un conjunto de datos de entrenamiento etiquetados. En este enfoque, se proporciona al modelo información explícita sobre las características (variables independientes) de los datos de entrada y la correspondiente etiqueta o resultado deseado (variable dependiente).

El objetivo del aprendizaje automático supervisado es que el modelo aprenda a realizar predicciones o clasificaciones precisas en nuevos datos no etiquetados. Durante el entrenamiento, el modelo examina los ejemplos de entrenamiento y busca patrones y relaciones entre las características y las etiquetas asociadas. A medida que se ajusta, el modelo aprende a generalizar estos patrones y puede aplicarlos para predecir o clasificar nuevas instancias.

Una vez que el modelo ha sido entrenado, se puede evaluar su rendimiento utilizando un conjunto de datos de prueba independiente. El modelo hará predicciones sobre las instancias de prueba y se compararán con las etiquetas reales para medir su precisión y rendimiento general.

El aprendizaje supervisado es ampliamente utilizado en una variedad de aplicaciones, como clasificación de texto, detección de fraudes, diagnóstico médico, entre otros, donde se dispone de datos etiquetados para entrenar y validar modelos predictivos.

### **Aprendizaje supervisado No Probabilístico**

En el aprendizaje supervisado no probabilístico, se asume que las relaciones entre las características de entrada y las salidas esperadas son deterministas y se busca encontrar una función o regla exacta que describa esta relación. Los modelos no probabilísticos suelen basarse en algoritmos de optimización y toman decisiones basadas en reglas rígidas y deterministas. Por ejemplo, los árboles de decisión y los *SVM* son ejemplos de modelos no probabilísticos que veremos a continuación.

#### *Árbol de decisión*

Los árboles de decisión son ampliamente utilizados en el campo del aprendizaje automático debido a su popularidad. Su atracción radica principalmente en su naturaliza intuitiva, simplicidad y capacidad visual para representar decisiones. Estos modelos son capaces de manejar grandes volúmenes de datos sin requerir una carga computacional excesiva, y su capacidad de proporcionar resultados precisos es notable. Sin embargo, también presentan algunas desventajas importantes. El sobreajuste ocurre cuando el modelo se ajusta demasiado a los detalles irrelevantes del conjunto de entrenamiento y no generaliza bien los datos. La alta varianza implica que pequeñas variaciones en los datos pueden afectar significativamente la estructura del árbol y las predicciones. El sesgo se refiere a una influencia desproporcionada de algunas clases en el modelo. Para evitar estas limitaciones, se pueden utilizar técnicas como la poda del árbol, el ensamblado de árboles y el muestreo balanceado. Estas estrategias ayudan a mejorar la precisión, la estabilidad y la capacidad de generalización de los árboles de decisión (Gupta P. , 2017).

En la *Figure 6* se puede apreciar la estructura básica de un árbol de decisión, compuesto por tres nodos (Thorn, 2020):

- **Nodo raíz:** Es el primer nodo en un árbol de decisión y se encuentra en la parte superior. Es en este nodo donde se realiza la primera división, por lo que solo tiene ramas de salida. Estas ramas se dividen en dos o más subnodos, que representan los posibles resultados de una función basada en un atributo. Estos resultados pueden ser una categoría, un valor o un rango de valores.
- **Nodo interno:** Son aquellos que tienen tanto ramas de entrada como de salida. Al igual que el nodo raíz, las ramas de salida de estos nodos representan soluciones basadas en un atributo.
- **Hojas:** Son los nodos ubicados en la parte inferior del árbol y solo tienen ramas de entrada. Estos nodos representan los posibles resultados finales del árbol y, por ende, del algoritmo en general, basados en las decisiones tomadas en los nodos anteriores y las ramas correspondientes.



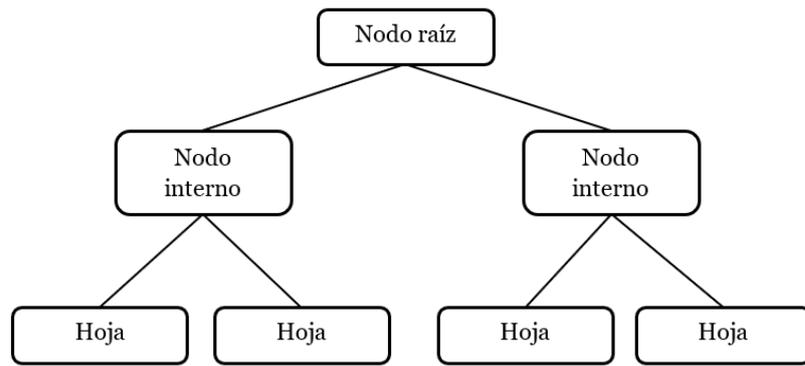


Figure 6: Ejemplo de árbol de decisión forma genérica.  
Fuente: Elaboración propia.

Partiendo del nodo raíz y recorriendo varios nodos internos hasta llegar a un nodo hoja, se establecen las etiquetas de los nuevos casos  $X$  a clasificar. Este camino depende de los resultados obtenidos por dicha variable en las distintas funciones. Los árboles de regresión y los árboles de clasificación son los dos tipos diferentes de árboles que existen.

Los valores discretos que normalmente representan varias clases forman los nodos de hoja de los árboles de clasificación. Mientras que los nodos hoja de los árboles de regresión son valores continuos (Pulipaka, 2016).

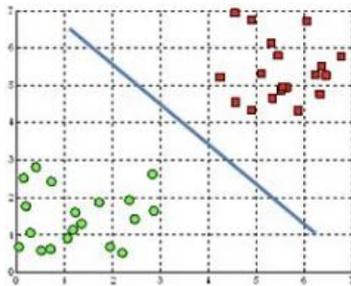
El *bagging* y el *boosting* son técnicas populares utilizadas en el aprendizaje automático, especialmente en el contexto de los árboles de decisión. El *bagging* (bootstrap aggregating) es una técnica que se basa en la combinación de múltiples modelos de aprendizaje para mejorar la precisión predictiva. Implica crear diferentes muestras de entrenamiento seleccionadas al azar con reemplazo a partir del conjunto de datos original. Luego, se entrena un árbol de decisión para cada muestra y se promedian las predicciones de todos los árboles para obtener una predicción final. El objetivo del *bagging* es reducir la varianza del modelo al promediar las predicciones de múltiples modelos independientes.

El *boosting* es otra técnica que también combina múltiples modelos de aprendizaje, pero a diferencia del *bagging*, se centra en mejorar el sesgo del modelo. En lugar de entrenar múltiples modelos de forma independiente, el *boosting* construye una secuencia de modelos en la que cada uno se enfoca en corregir los errores cometidos por los modelos anteriores. Se realiza mediante la construcción iterativa de árboles de decisión, donde cada árbol se entrena en un conjunto de datos ponderado, dando más peso a las muestras que fueron clasificadas incorrectamente por los árboles anteriores. Luego, se combinan las predicciones de todos los árboles mediante un esquema ponderado para obtener la predicción final (Rodrigo, 2020).

### *SVM*

El *Support Vector Machine (SVM)* es un algoritmo de aprendizaje supervisado que se utiliza principalmente para clasificación, pero también es adecuado para regresión. Su objetivo es encontrar un límite de decisión que pueda separar eficientemente diferentes conjuntos de datos. Este límite de decisión se representa mediante un hiperplano. En un espacio bidimensional con dos atributos, el límite de decisión será una línea, mientras que, en un espacio tridimensional con tres atributos, el límite de decisión será un plano. La *Figure 7* muestra hiperplanos en dos y tres dimensiones.

A hyperplane in  $\mathbb{R}^2$  is a line



A hyperplane in  $\mathbb{R}^3$  is a plane

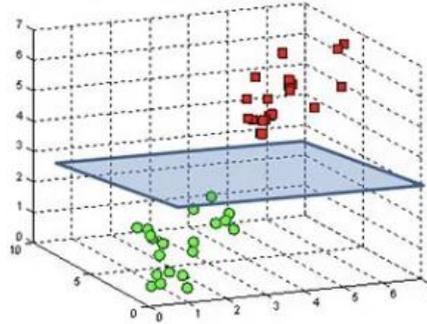


Figure 7: Ejemplos de hiperplanos en 2D y 3D.  
Fuente: Medium (Gandhi, 2018)

La determinación del límite de decisión es una parte crítica en los algoritmos SVM. La *Figure 8* muestra múltiples hiperplanos que separarán las dos clases. El objetivo del SVM es encontrar el hiperplano que maximice la distancia entre los puntos más cercanos de las diferentes clases, lo que se conoce como margen máximo (*Figure 9*). Los puntos más cercanos de cada clase al hiperplano son llamados vectores de soporte.

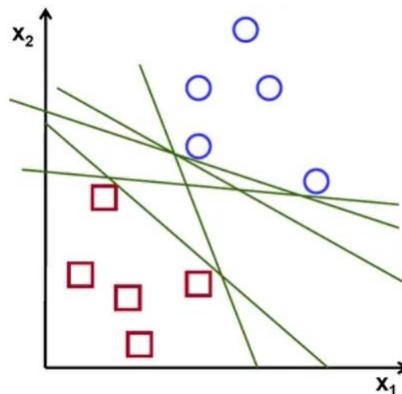


Figure 8: Posible hiperplano  
Fuente: Medium (Gandhi, 2018)

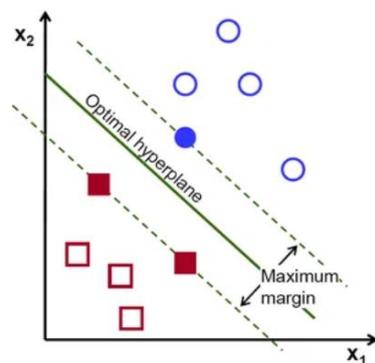
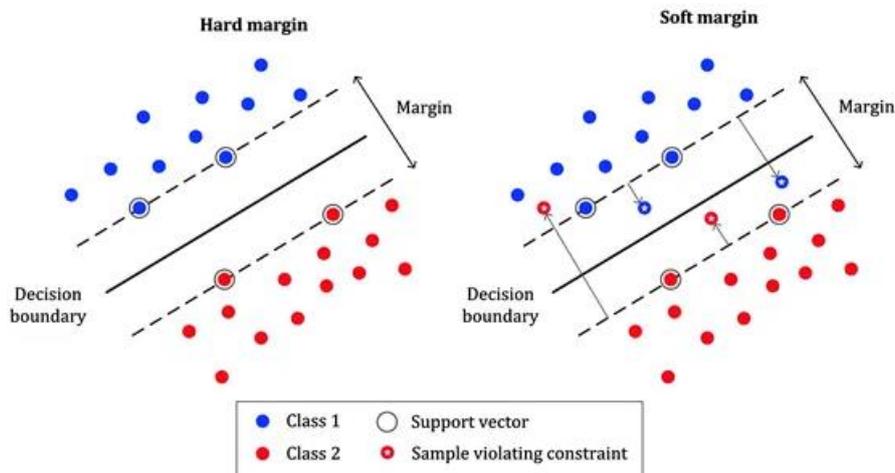


Figure 9: Hiperplano óptimo.  
Fuente: Medium (Gandhi, 2018)

En la mayoría de las situaciones, es poco común encontrar separaciones perfectas entre las clases debido a la presencia de valores atípicos. Por lo tanto, se utiliza un enfoque conocido como margen suave, que permite que algunos datos estén clasificados incorrectamente. Esta flexibilidad se visualiza en la *Figure 10*, donde se muestra la diferencia entre el margen duro y el margen suave (MLMath, 2019).



*Figure 10: Ejemplos visuales de margen suave y margen duro.  
Fuente: Medium (Gandhi, 2018)*

El uso del margen suave es popular debido a su capacidad para lidiar con valores atípicos de manera efectiva. A diferencia del enfoque de margen duro, el margen suave permite cierta tolerancia para clasificar correctamente la mayoría de los puntos de datos, incluso si esto implica permitir algunos errores de clasificación. Este método se considera robusto, ya que puede manejar eficientemente situaciones en las que los datos no son completamente separables.

Además de la robustez, los algoritmos basados en el margen suave requieren menos capacidad de cálculo en comparación con otros enfoques, lo que los hace computacionalmente eficientes. A pesar de esta eficiencia, los resultados obtenidos por los algoritmos SVM basados en el margen suave suelen ser precisos y confiables.

### **Aprendizaje supervisado Probabilístico**

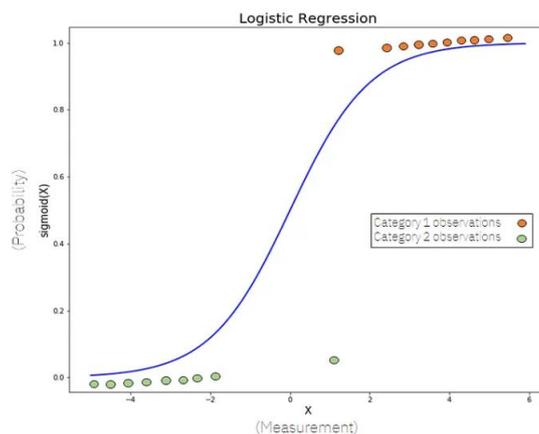
Por otro lado, en el aprendizaje supervisado probabilístico, se considera la incertidumbre inherente a los datos y se busca modelar y estimar distribuciones de probabilidad. Estos modelos asumen que existen relaciones probabilísticas entre las características de entrada y salida esperadas. En lugar de hacer predicciones deterministas, los modelos probabilísticos generan distribuciones de probabilidad sobre las posibles salidas. Esto permite tener en cuenta la incertidumbre y obtener medidas de confianza asociadas a las predicciones. Ejemplos de modelos probabilísticos son las redes neuronales probabilísticas y los modelos gráficos probabilísticos, como las redes Bayesianas.

### *Regresión logística*

La regresión logística es un método ampliamente utilizado en el análisis predictivo para la clasificación de datos. Su popularidad se debe a su eficacia para realizar clasificaciones utilizando tantos datos continuos (por ejemplo: edad, temperatura, peso...) como discretos (por ejemplo:

nacionalidad, tipos de cánceres...). La regresión logística establece la relación entre una variable categórica a predecir, y una o más variables predictoras. Normalmente, se utiliza para pronosticar el resultado de una variable binaria y proporciona la probabilidad de pertenencia a cada una de las clases.

La regresión logística se basa en el uso de una función sigmoide o función logística, representada en la *Figure 11*. Esta función limita los resultados entre 0 y 1, que representan los valores mínimo y máximo, respectivamente. Esta característica es fundamental para clasificar los datos en dos categorías. Los resultados obtenidos a través de la regresión logística representan la probabilidad de que el dato estudiado pertenezca a una de las dos clases.



*Figure 11: Ejemplo regresión logística.*  
*Fuente: Medium (Thorn, 2020).*

## 2.5. Crítica y propuesta al marco contextual

### 2.5.1. Trabajos previos relacionados

En la actualidad, la visión artificial ha demostrado ser una herramienta poderosa en diversas aplicaciones, incluida la mejora del rendimiento deportivo. Numerosos estudios han investigado el uso de técnicas de visión artificial para analizar y evaluar el desempeño de los atletas en diferentes disciplinas deportivas.

En el ámbito de la mejora del rendimiento deportivo mediante visión artificial, la recopilación de datos precisa sobre puntos y ángulos de las posturas humanas es fundamental. Para lograr esto, se han utilizado diversas técnicas, incluida la biblioteca *Mediapipe*, que ofrece una solución integral para la detección y seguimiento de puntos clave en las posturas humanas.

Estudios previos han investigado el uso de *Mediapipe* para la estimación de la pose y la recopilación de datos relevantes para el análisis del rendimiento deportivo. Wang y Gao (2021) utilizaron *Mediapipe* para realizar estimaciones en tiempo real de la pose humana a partir de datos de vídeo, lo que les permitió recopilar información detallada sobre las posturas y los ángulos del cuerpo durante el movimiento. Además, (Carreira, Agrawal, Fragkiadaki, & Malik, 2016) propusieron un enfoque basado en iteraciones de retroalimentación de errores utilizando esta biblioteca para la estimación precisa de la pose humana, lo que resultó fundamental para el análisis del rendimiento deportivo en disciplinas específicas. Otro enfoque interesante fue presentado por (Moon, Yong Chang, & Mu Lee, 2019) con su red *PoseFix*, que utilizó *Mediapipe* para el refinamiento de poses humanas, permitiendo la mejora de las estimaciones de pose

inicialmente obtenidas y una recopilación más precisa de datos sobre puntos y ángulos de las posturas humanas.

El estudio realizado por (Barbieri, V Chawla, Zaccagni, & Grgurinovic, 2020) se utilizó una metodología de minería de datos para evaluar el riesgo cardiovascular en atletas. Se recopilaron datos de 26.002 deportistas y se aplicaron técnicas de clasificación, como árboles de decisión y regresión logística, para identificar individuos en riesgos. La metodología mejoró la evaluación del riesgo cardiovascular y demostró ser útil para optimizar la toma de decisiones clínicas y reducir exámenes innecesarios.

Por último, hay un modelo de clasificación de vídeos de entrenamiento deportivo hecho por (Xu, 2021) basado en aprendizaje profundo. Se utiliza la tecnología de calibración de cámara para restaurar la posición del objetivo en el espacio tridimensional real y se aplican diversas técnicas de preprocesamiento al video. Las características extraídas se ingresan en una red neuronal convolucional para obtener una clasificación precisa. Los resultados experimentales demuestran que el modelo resuelve eficazmente los problemas de aleatoriedad en el movimiento del objetivo, logrando una precisión de clasificación superior al 99% y una velocidad de clasificación más rápida. Se utiliza el método de coincidencia de eventos para completar la clasificación de los videos de entrenamiento deportivo.

Basándonos en los trabajos previos mencionados, este Trabajo Final de Grado (TFG) tiene como objetivo investigar y desarrollar un sistema basado en la recolección de puntos y ángulos de la pose humana y modelos de clasificación para la mejora del rendimiento deportivo en una actividad específica, las sentadillas.

### **2.5.2. Propuesta**

La propuesta consiste en utilizar técnicas de visión artificial para capturar imágenes o secuencias de video de los atletas durante la práctica deportiva. A través de modelos de clasificación, se analizará la pose y los movimientos corporales con el fin de identificar patrones, detectar errores técnicos y proporcionar retroalimentación en tiempo real para corregir y mejorar el rendimiento.

Este estudio contribuirá al campo de la mejora de rendimiento deportivo mediante el uso de visión artificial, proporcionando conocimientos y herramientas prácticas para el análisis y entrenamiento de atletas. Se espera que los resultados obtenidos impulsen el desarrollo de tecnologías innovadoras y aplicaciones prácticas que beneficien tanto a los atletas como a los deportistas aficionados.

# 3. Metodología

## 3.1. Datos

### 3.1.1. Vídeos

En esta investigación, se emplearon una variedad de videos, los cuales se obtuvieron tanto de fuentes en línea como de grabaciones particulares. Aproximadamente el 20% de los videos utilizados fueron descargados de internet, provenientes de plataformas de alojamiento de videos (Videvo, s.f.) (iStock, s.f.), entre otros recursos disponibles al público. La selección de estos videos se llevó a cabo considerando su relevancia y su adecuación a los objetivos del estudio.



*Figure 12: Ejemplo de frames de un vídeo extraído de internet.  
Fuente: Videvo (Videvo, s.f.).*

Por otra parte, alrededor del 80% de los videos utilizados fueron grabados particularmente a diversas personas para esta investigación. Estas grabaciones brindaron una perspectiva auténtica y realista para el análisis.



*Figure 13: Ejemplo de frames de un vídeo particular.  
Fuente: elaboración propia*

Con el fin de hacer el análisis menos costoso, se ha garantizado que todos los vídeos sean desde la misma perspectiva, lo que implica una posición fija de la cámara en todos los casos. Esta estrategia reduce la complejidad y el costo computacional al evitar ajustes y alineaciones de imágenes. Sin embargo, desde esta perspectiva única, se limita la visión a la parte derecha del

cuerpo humano. En el futuro, podría considerarse la incorporación de otras perspectivas para obtener una visión más completa y enriquecedora de los datos, lo que permitiría observar también la parte izquierda del cuerpo, por ejemplo. No obstante, esto implicaría desafíos adicionales en términos de procesamiento y alineación de diferentes ángulos de visión.

Es importante destacar que se respetaron todas las pautas éticas y legales durante la recopilación de los videos, tanto los descargados de internet como los grabados particularmente. Se obtuvo el consentimiento informado de los participantes y se implementaron medidas para garantizar la privacidad y confidencialidad de la información personal.

La combinación de videos descargados de internet y videos grabados particularmente enriqueció la investigación al proporcionar una amplia gama de situaciones y contextos para su análisis. Esta combinación permitió una comprensión más completa de los fenómenos estudiados, contribuyendo a la obtención de hallazgos y conclusiones más sólidos.

En total, se han recopilado 121 vídeos, de los cuales se han clasificado 70 como demostraciones de sentadillas realizadas de manera adecuada, y 51 como ejemplos de ejecución incorrecta.

El proceso de clasificación se llevó a cabo mediante la observación y evaluación detallada de cada vídeo. Se aplicaron criterios específicos para determinar si las sentadillas mostradas cumplían con las técnicas y principios correctos de este ejercicio. Aquellos vídeos en los que se observó una ejecución adecuada, en término de postura, alineación corporal, amplitud de movimiento y control, fueron clasificados como “bien”. Por otro lado, los vídeos en los que se identificaron errores en la técnica como una mala postura, falta de estabilidad o movimientos inapropiados, se categorizaron como “mal”.

### 3.1.2. Librería *MediaPipe*

Una vez que disponemos de los vídeos, procedemos a utilizar la librería *MediaPipe* (comentada anteriormente) para extraer los puntos clave de las personas mientras realizan las acciones correspondientes. Mediante esta herramienta, seremos capaces de detectar y rastrear los puntos de interés en cada fotograma del vídeo. A continuación, se utilizará esta información para calcular los ángulos formados por estos puntos clave.

Se han seleccionado los puntos clave de muñeca, codo, hombro, cadera, rodilla y tobillo para el análisis, centrándonos en la parte derecha del cuerpo debido a la simetría del movimiento en las sentadillas. Sin embargo, es importante tener en cuenta que, aunque solo esté centrado en la parte derecha del cuerpo, en caso de existir una lesión en la rodilla izquierda, se vería afectada la simetría del ejercicio, ya que la flexión de la rodilla derecha no sería realizada de la misma manera. Esto implica que los resultados obtenidos en la parte derecha del cuerpo podrían no reflejar completamente la situación de la rodilla izquierda afectada. En futuros estudios, sería relevante considerar esta asimetría y abordar de manera específica las lesiones o desequilibrios en ambas rodillas durante el análisis de los ejercicios de sentadillas (eso se vería también si un mismo ejercicio está grabado desde diferentes ángulos y puntos de vista).

Por tanto, (centrándose en la *Figure 4* vista anteriormente) de cada *frame* de cada vídeo, se han recogido los datos de estos puntos clave:

- 16. `right_wrist`: punto clave de la muñeca derecha.

- 14. right\_elbow: punto clave del codo derecho.
- 12. right\_shoulder: punto clave del hombro derecho.
- 24. right\_hip: punto clave de la cadera derecha.
- 26. right\_knee: punto clave de la rodilla derecha.
- 28. right\_ankle: punto clave del tobillo derecho.

Cada uno de los puntos clave de muñeca, codo, hombro, cadera, rodilla y tobillo se representan mediante dos variables: una variable  $x$  y una variable  $y$ . Estas variables capturan las coordenadas espaciales de cada punto en el plano de un frame.

Utilizando las coordenadas  $x$  e  $y$  de estos puntos, se calcularán posteriormente los ángulos correspondientes. Estos ángulos permitirán evaluar la amplitud de movimiento, la alineación y la biomecánica de las articulaciones durante el ejercicio de las sentadillas.

### 3.1.3. Cálculo de ángulos de interés

El cálculo de los ángulos se realiza utilizando métodos matemáticos y técnicas de procesamiento de imágenes. Los ángulos de interés en este caso son los del codo, el hombro, la rodilla y el tobillo.

A continuación, se explica en términos generales cómo se calculan estos ángulos y las operaciones matemáticas involucradas:

1. Se definen los puntos  $p1$ ,  $p2$  y  $p3$  utilizando las coordenadas  $(x, y)$  de cada punto en el plano. Es decir, si se va a calcular el ángulo del codo, se necesitan los puntos de la muñeca (sería el punto  $p1$ ), del codo (sería el punto  $p2$ ) y del hombro (sería el punto  $p3$ ). Por otra parte, para calcular el ángulo del hombro, se necesitan los puntos clave del codo (en este caso sería  $p1$ ), el hombro ( $p2$ ) y la cadera ( $p3$ ). Para calcular el ángulo de la cadera, se necesitan los puntos del hombro ( $p1$ ), la cadera ( $p2$ ) y la rodilla ( $p3$ ). Por último, para calcular el ángulo de la rodilla, se necesitan los puntos de la cadera ( $p1$ ), la rodilla ( $p2$ ) y el tobillo ( $p3$ ).

Se puede observar en la *Figure 14* cómo la librería coge los tres puntos que necesitamos para calcular los ángulos de interés. En color azul se muestra el  $p1$  de cada ángulo, en rojo se muestra el  $p2$  y en amarillo el  $p3$ .



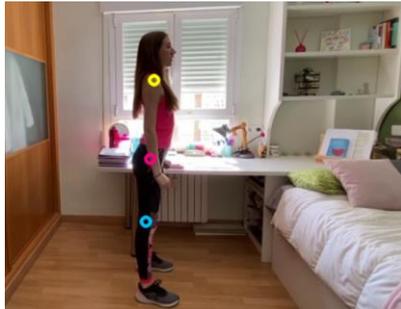
## Mejora del rendimiento deportivo mediante visión artificial



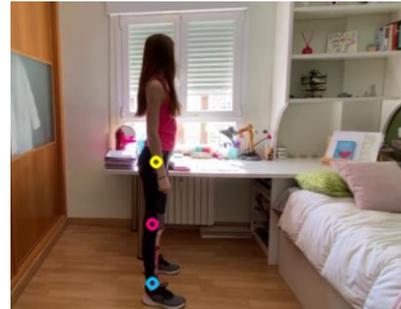
Puntos clave para calcular el ángulo del codo



Puntos clave para calcular el ángulo del hombro



Puntos clave para calcular el ángulo de la cadera



Puntos clave para calcular el ángulo de la rodilla



Figure 14: Puntos clave mediante MediaPipe  
Fuente: Elbaroación propia.

2. A continuación, se calculan los lados del triángulo formado por los puntos. Utilizando la función `np.linalg.norm()`, se calcula la norma Euclidiana (distancia) entre los pares de puntos:  $p_2$  a  $p_3$  (lado  $l_1$ ),  $p_1$  a  $p_3$  (lado  $l_2$ ) y  $p_1$  a  $p_2$  (lado  $l_3$ ). Se puede observar en la *Figure 15* cómo se unen los puntos clave que se ha comentado anteriormente mediante las líneas para formar el triángulo.





Triángulo formado por los puntos para calcular el ángulo del codo



Triángulo formado por los puntos para calcular el ángulo del hombro



Triángulo formado por los puntos para calcular el ángulo de la cadera



Triángulo formado por los puntos para calcular el ángulo de la rodilla



Triángulo formado por los puntos para calcular el ángulo de la cadera



Triángulo formado por los puntos para calcular el ángulo de la rodilla

Figure 15: Triángulo formado por los puntos clave mediante MediaPipe.  
Fuente: Elaboración propia.

- Seguidamente, se calcula el ángulo utilizando la fórmula del coseno conocida como "ley de los cosenos". Esta fórmula se aplica para un triángulo cualquiera y se utiliza para encontrar un ángulo conocidos los tres lados del triángulo. El ángulo se calcula utilizando la función  $\text{acos}()$ , que devuelve el arco coseno en radianes. Para obtener el resultado en grados, se utiliza la función  $\text{degrees}()$ .

Observando la *Figure 16* se puede ver el valor del ángulo que forman esos triángulos.



## Mejora del rendimiento deportivo mediante visión artificial

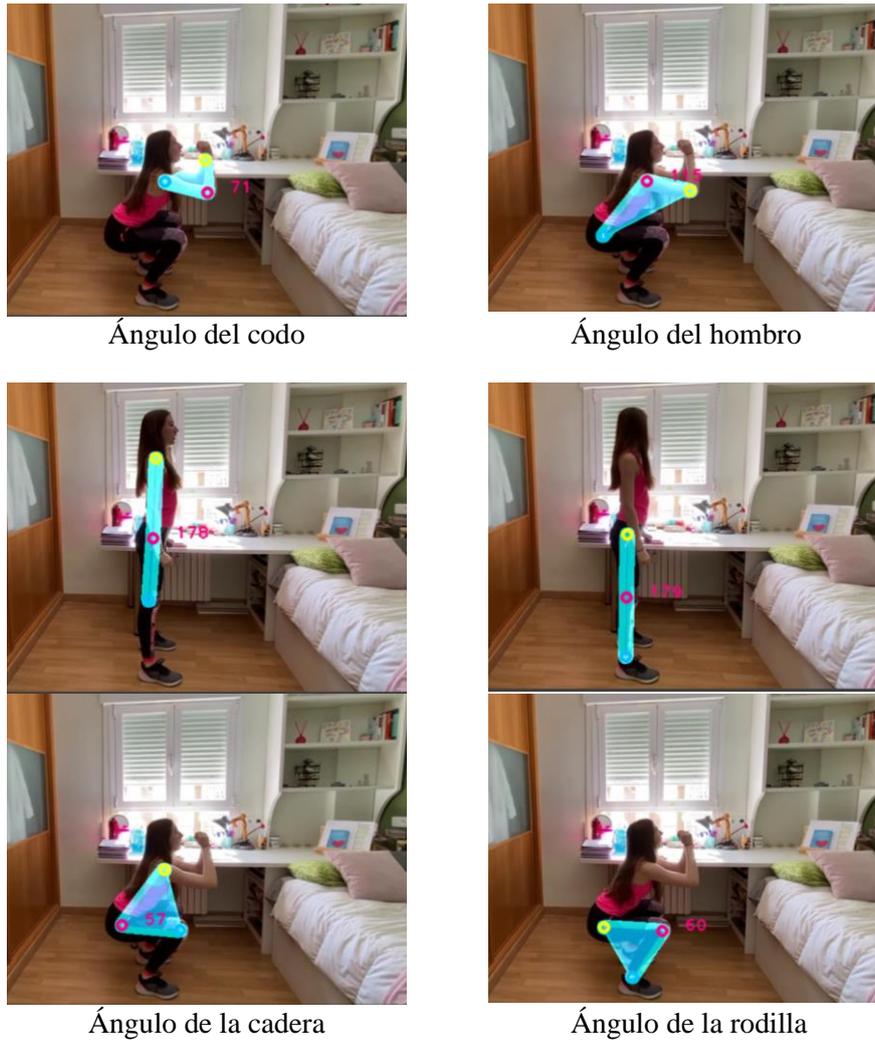


Figure 16: Ángulos calculados.  
Fuente: Elaboración propia.

Con el objetivo de organizar y estructurar estos datos, se genera un archivo en formato Excel. Cada fila de este archivo representa un fotograma del vídeo y contiene información relevante. Se incluyen el número del vídeo utilizado, el número del fotograma y los valores de los ángulos formados por la rodilla, el codo, el hombro y la cadera en ese instante. Además, se han añadido etiquetas manuales para indicar si el ejercicio de la sentadilla se realizó correctamente (etiqueta "bien") o no (etiqueta "mal").

Video	Frame	Angulos_Rodilla	Angulos_Caderas	Angulos_Hombro	Angulos_Codo	Etiqueta
1	1	179,7668031	169,0323241	7,178882625	170,3058315	bien
1	2	178,9812494	169,0329104	7,245074578	170,3058315	bien
1	3	178,2642954	169,0329104	7,245074578	170,3058315	bien
1	4	178,2642954	169,0329104	8,248856391	167,8739935	bien
1	5	178,2642954	169,0329104	8,248856391	167,8739935	bien
1	6	178,2642954	169,0329104	8,248856391	167,8739935	bien

Figure 17: Ejemplo de datos de un vídeo clasificado como "bien".  
Fuente: elaboración propia

Video	Frame	Angulos_Rodilla	Angulos_Caderas	Angulos_Hombro	Angulos_Codo	Etiqueta
71	1	175,1997103	177,4738831	38,29016319	34,38966945	mal
71	2	175,1997103	177,4738831	38,29016319	35,68760099	mal
71	3	175,1997103	177,4738831	39,95754893	36,05705519	mal
71	4	174,3582777	178,3153157	39,2072035	34,0127746	mal
71	5	172,7379491	179,1319486	37,56859203	33,66809829	mal
71	6	172,6735933	178,7409548	38,69850372	36,1434741	mal

Figure 18: Ejemplo de datos de un vídeo clasificado como "mal".  
Fuente: elaboración propia

Después de extraer los ángulos de cada fotograma de todos los vídeos, se obtiene un total de 42.161 datos.

### 3.1.4. Limpieza de datos

En este caso particular, no ha sido necesario realizar ninguna limpieza de datos, ya que no se encontraron valores faltantes, ni duplicados ni erróneos. Todos los videos se han grabado desde un ángulo que ha permitido visualizar los puntos clave necesarios, por lo que no ha habido ausencia de datos en la recopilación.

### 3.1.5. Extracción de características significativas

Una vez que se dispone del archivo *Excel* con los datos por *frames* de cada vídeo, el siguiente paso consiste en extraer las características significativas de esos datos. En este contexto, se aplicarán diferentes medidas estadísticas para analizar y resumir los ángulos obtenidos.

Para organizar y analizar los datos, se procede a agrupar todos los fotogramas por vídeo. Luego, se calculan diversas características a partir de estos grupos. Estas características incluyen la media, la moda, la mediana, el rango (valor mínimo y valor máximo) y la desviación estándar de cada uno de los ángulos. Estas medidas proporcionan información valiosa sobre la tendencia central, la dispersión y la distribución de los ángulos recopilados. De esta manera, se extraen estas características de cada vídeo, permitiendo un análisis más completo y detallado.

Para calcular la media, se suman todos los valores de los ángulos y se dividen por la cantidad total de ángulos. La media es una medida de tendencia central que nos da una idea del valor promedio de los ángulos.

La moda representa el valor o valores que aparecen con mayor frecuencia en el conjunto de ángulos. Es útil para identificar patrones o valores dominantes.

La mediana es el valor medio cuando los ángulos se ordenan de forma ascendente o descendente. Es una medida de tendencia central que no se ve afectada por valores extremos.

El rango se calcula encontrando la diferencia entre el valor máximo y el valor mínimo de los ángulos. Proporciona una idea de la amplitud de los datos.

La desviación estándar mide la dispersión o variabilidad de los ángulos con respecto a la media. Indica cuánto se alejan los valores individuales de la media.



Al calcular estas características para cada ángulo por vídeo, se obtiene un resumen cuantitativo que permite comprender mejor la distribución y las propiedades de los datos angulares. Esto facilita la identificación de patrones, tendencias y variaciones significativas en los ángulos analizados.

Video	Angulos_Rodilla_mean	Angulos_Rodilla_median	Angulos_Rodilla_calcular_moda	Angulos_Rodilla_min	Angulos_Rodilla_max	Angulos_Rodilla_std
1	127,9358981	145,29211	179,9294015	46,41628256	179,9795445	48,73340451
2	133,854381	146,7790953	177,3332768	56,52581608	179,1109738	40,37463639
3	133,8366998	137,4721926	81,80629892	73,66197001	176,7491714	32,60118856
5	121,3220992	118,2178666	174,5854691	66,6976129	179,9279148	40,87618129
6	131,5340481	144,2225832	176,7328387	61,46696945	178,3338924	44,35324764
7	123,2402294	115,2630375	172,1998121	64,45556189	180	40,22245177
8	124,3080815	121,7072938	177,9786351	60,07159665	180	43,2401478

Figure 19: Ejemplo de datos con las características significativas por vídeo (aquí solo se muestran las características significativas del ángulo de la rodilla).

Fuente: elaboración propia

### 3.1.6. Análisis de las características significativas

Se ha elegido utilizar gráficos de *boxplot* para realizar el análisis de las características significativas debido a varias razones fundamentales que aseguran una representación visual efectiva de los datos recopilados.

En primer lugar, los *boxplots* evitan la pérdida de información valiosa y garantizan una representación más realista de los datos. A diferencia de la media, que puede ser influenciada significativamente por valores atípicos, los *boxplots* nos brindan una visión más completa y equilibrada al mostrar la distribución de los datos y resaltar los valores atípicos. Esto nos permite obtener una comprensión más precisa de la distribución de los datos y de sus características distintivas.

Además, son especialmente útiles cuando se comparan diferentes grupos o categorías de datos, como en este caso, donde se clasifican los videos como "bien" o "mal" en términos de ejecución de la sentadilla. Para cada ángulo (cadera, codo, hombro, rodilla) y medida (media, moda, máximo, mínimo y desviación estándar), se generan dos *boxplots* separados, uno para los videos clasificados como "bien" y otro para los videos clasificados como "mal". Esta representación visual directa y comparativa entre los dos grupos nos ayuda a identificar posibles diferencias o patrones distintivos en la ejecución del ejercicio.

El gráfico compara dos distribuciones de datos utilizando dos cajas, una para los datos clasificados como "bien" y otra para los datos clasificados como "mal". Cada caja representa una distribución y muestra estadísticas descriptivas clave, como la media, la mediana, el máximo, el mínimo y la desviación estándar. Los valores del bigote superior e inferior indican el rango de los datos que no se consideran atípicos, mientras que la línea en el centro de cada caja representa la mediana, que divide la distribución en dos partes iguales. Los cuartiles superior e inferior, representados por los bordes superiores e inferiores de las cajas, respectivamente, muestran la variabilidad de los datos en la mitad superior e inferior de la distribución.

#### 3.1.6.1. Análisis de los ángulos de la cadera

El primer ángulo que se analiza es el de la cadera. Al comparar las medias de los ángulos de la cadera (Figure 20) en sentadillas clasificadas como "bien" y "mal", se observaron diferencias significativas. En las sentadillas realizadas correctamente, la mediana del ángulo de la cadera fue

de 118,02 grados, con un rango intercuartílico entre 113,37 y 123,48 grados. En contraste, en las sentadillas mal clasificadas, la mediana del ángulo de la cadera fue ligeramente mayor, con un valor de 138,22 grados y un rango intercuartílico entre 135,90 y 143,36 grados. Esto sugiere que las sentadillas mal clasificadas tienden a tener ángulos de la cadera más altos en comparación con las sentadillas correctamente ejecutadas.

Si nos centramos en las medianas (*Figure 21*), en las sentadillas realizadas correctamente, la mediana del ángulo de la cadera fue de 119,03 grados, con un rango intercuartílico entre 114,46 y 130,35 grados. En contraste, en las sentadillas mal clasificadas, la mediana del ángulo de la cadera fue más alta, con un valor de 147,06 grados y un rango intercuartílico entre 139,66 y 152,93 grados. Esto sugiere que las sentadillas mal clasificadas tienden a tener ángulos de la cadera más altos en comparación con las sentadillas correctamente ejecutadas.

Respecto a los valores máximos y mínimos de los ángulos de la cadera (*Figure 22 y Figure 23*) se encontraron similitudes entre las sentadillas clasificadas como "bien" y "mal". Tanto en las sentadillas correctamente ejecutadas como en las incorrectas, los ángulos de la cadera presentaron valores máximos cercanos a 180 grados, lo que indica una extensión máxima en ambas condiciones. Sin embargo, se observó una diferencia notable en los valores mínimos. En las sentadillas bien clasificadas, el ángulo mínimo de la cadera fue de 28,91 grados, mientras que, en las mal clasificadas, fue de 56,84 grados. Esto indica que las sentadillas mal realizadas tienen ángulos de la cadera significativamente más altos en la posición más baja del ejercicio.

En cuanto a la desviación estándar (*Figure 24*), los ángulos de la cadera han revelado diferencias entre las sentadillas clasificadas como "bien" y "mal". En las sentadillas correctamente ejecutadas, la desviación estándar del ángulo de la cadera fue de 48,52 grados, mientras que en las mal clasificadas fue de 34,44 grados. Esto indica que las sentadillas mal realizadas presentaron una menor variabilidad en los ángulos de la cadera en comparación con las sentadillas correctamente ejecutadas.

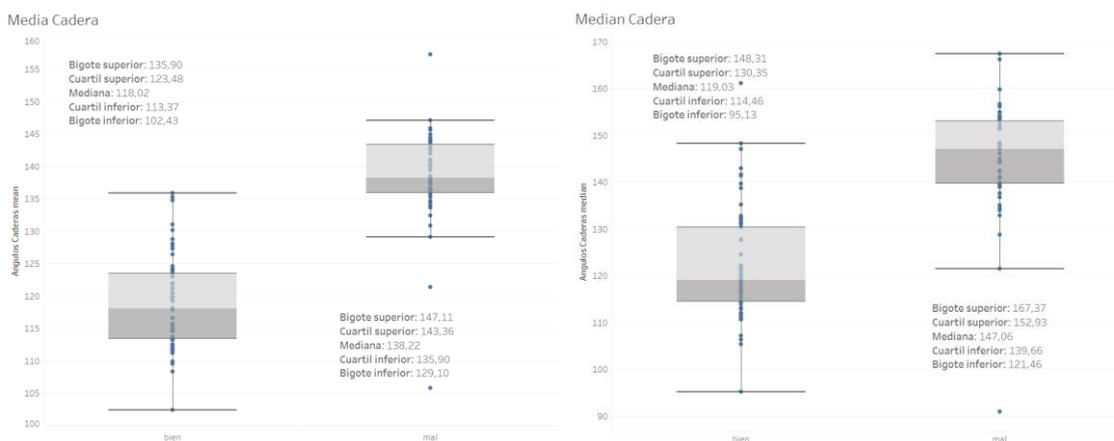


Figure 20: Boxplot Medias ángulo de la cadera. Fuente: Elaboración propia.

Figure 21: Boxplot Medianas ángulo de la cadera. Fuente: Elaboración propia.



## Mejora del rendimiento deportivo mediante visión artificial

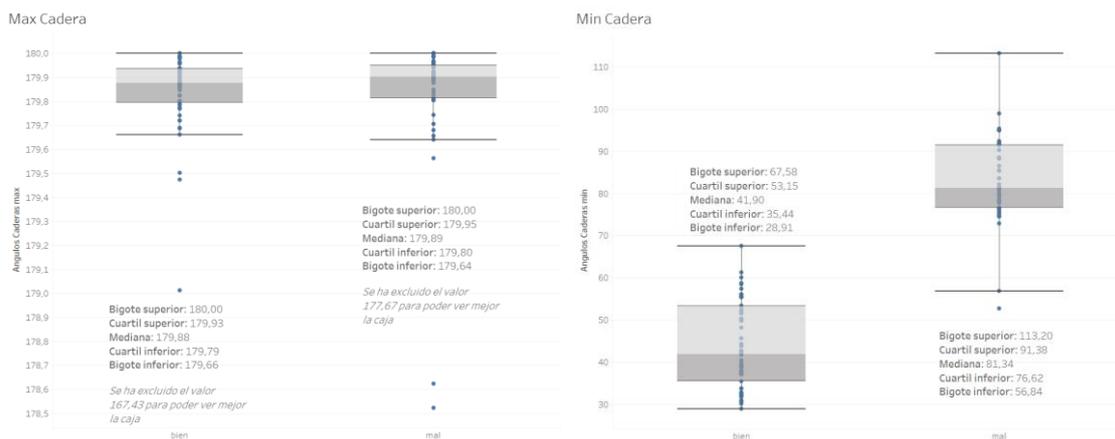


Figure 22: Boxplot Máximos ángulo de la cadera. Fuente:Elaboración propia.

Figure 23: Boxplot Mínimos ángulo de la cadera. Fuente:Elaboración propia.

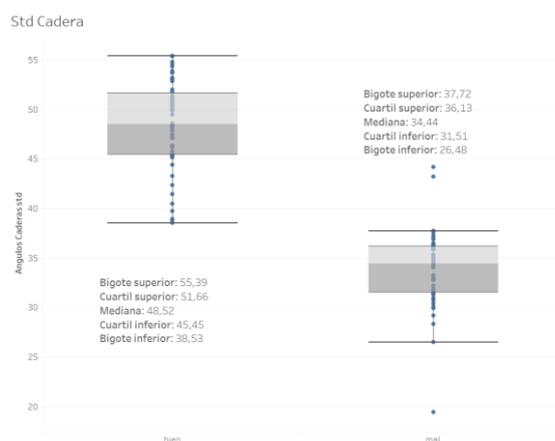


Figure 24: Boxplot Desviación estándar ángulo de la cadera. Fuente: Elaboración propia.

Por tanto, se pueden destacar las siguientes conclusiones respecto a los ángulos de la cadera:

- Los ángulos de la cadera en las sentadillas mal clasificadas tienden a ser más altos en comparación con las sentadillas correctamente ejecutadas.
- La mediana de los ángulos de la cadera en las sentadillas mal clasificadas es significativamente mayor que en las sentadillas correctamente ejecutadas.
- Las sentadillas mal realizadas presentan ángulos de la cadera significativamente más altos en la posición más baja del ejercicio.
- Las sentadillas mal clasificadas exhiben una menor variabilidad en los ángulos de la cadera en comparación con las sentadillas correctamente ejecutadas.

### 3.1.6.2. Análisis de los ángulos del hombro

Seguidamente, también se han realizado *boxplots* para visualizar las diferencias entre los ángulos del hombro en las sentadillas realizadas correctamente e incorrectamente.

Al comparar las medidas de los ángulos del hombro en sentadillas clasificadas como "bien" y "mal", se observaron diferencias significativas. En las sentadillas correctamente ejecutadas, la mediana (Figure 26) del ángulo del hombro fue de 41,70 grados, con un rango intercuartílico entre 30,10 y 58,40 grados. En contraste, en las sentadillas mal clasificadas, la mediana del ángulo del hombro fue más baja, con un valor de 12,00 grados y un rango intercuartílico entre 10,50 y 19,90 grados. Esto sugiere que las sentadillas mal clasificadas tienden a tener ángulos del hombro más bajos en comparación con las sentadillas correctamente ejecutadas.

En cuanto a las medidas de los valores máximos y mínimos de los ángulos del hombro (Figure 27 y Figure 28), se encontraron diferencias entre las sentadillas clasificadas como "bien" y "mal". En las sentadillas correctamente ejecutadas, el ángulo máximo del hombro fue de 136,80 grados, mientras que en las mal clasificadas fue de 64,60 grados. Además, en las sentadillas bien clasificadas, el ángulo mínimo del hombro fue de 0,00 grados, mientras que en las mal clasificadas fue de 0,01 grados. Estos resultados indican que las sentadillas mal realizadas tienden a tener ángulos del hombro más altos en el máximo y más altos en el mínimo en comparación con las sentadillas correctamente ejecutadas.

Por último, respecto a la desviación estándar de los ángulos (Figure 29), en las sentadillas correctamente ejecutadas, la desviación estándar del ángulo del hombro fue de 34,31 grados, mientras que en las mal clasificadas fue de 9,85 grados. Esto indica que las sentadillas mal realizadas presentaron una menor variabilidad en los ángulos del hombro en comparación con las sentadillas correctamente ejecutadas.

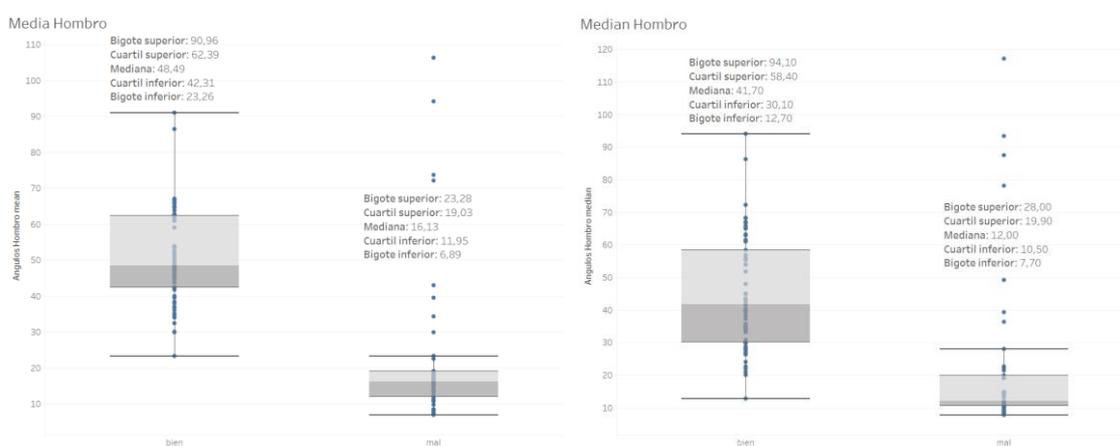


Figure 25: Boxplot Medias ángulo del hombro. Fuente: Elaboración propia.

Figure 26: Boxplot Medianas ángulo del hombro. Fuente: Elaboración propia.



## Mejora del rendimiento deportivo mediante visión artificial

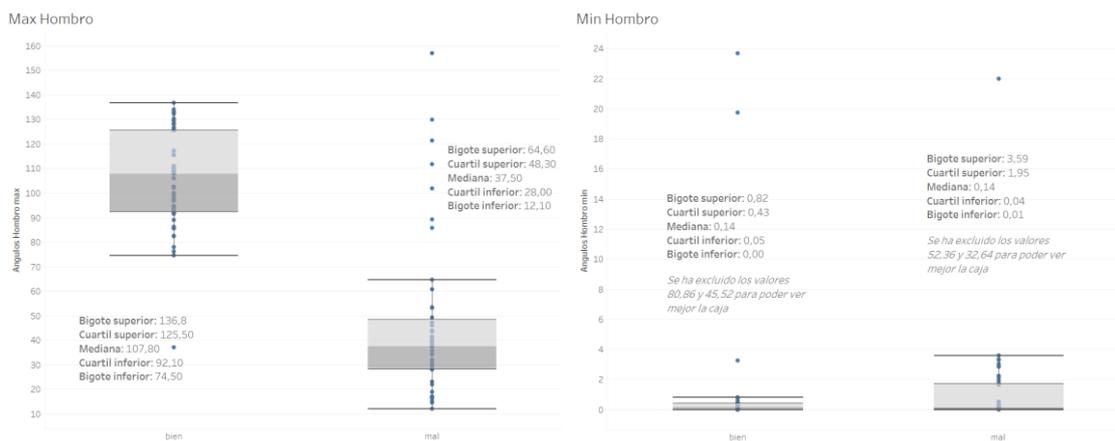


Figure 27: Boxplot Máximos ángulo del hombro. Fuente: Elaboración propia.

Figure 28: Boxplot Mínimos ángulo del hombro. Fuente: Elaboración propia.

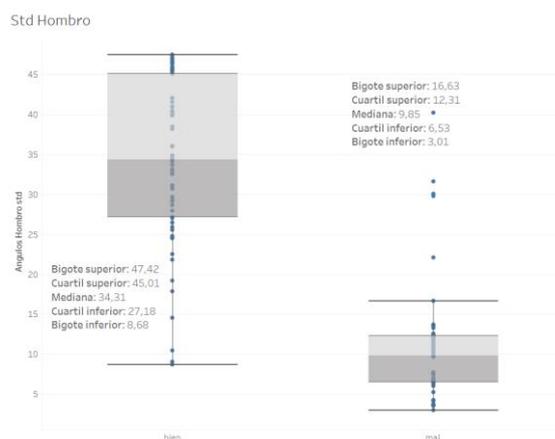


Figure 29: Boxplot Desviación estándar ángulo del hombro. Fuente: Elaboración propia.

Es decir, en base al análisis de los *boxplots* y las medidas resumidas de los ángulos del hombro en las sentadillas clasificadas como "bien" y "mal", se pueden extraer las siguientes conclusiones:

- Las sentadillas mal realizadas presentan ángulos del hombro más bajos en comparación con las sentadillas correctamente ejecutadas.
- Las sentadillas mal clasificadas exhiben ángulos del hombro más altos en el máximo y más altos en el mínimo en comparación con las sentadillas correctamente ejecutadas.
- Las sentadillas mal realizadas presentan una menor variabilidad en los ángulos del hombro en comparación con las sentadillas correctamente ejecutadas.

### 3.1.6.3. Análisis de los ángulos del codo

A continuación, se va a realizar el análisis sobre los ángulos del codo. El análisis de los *boxplots* correspondientes a las medias de los ángulos del codo (*Figure 30*) revela diferencias significativas entre las sentadillas clasificadas como "bien" y "mal". Las sentadillas "bien" presentan una media de ángulo del codo de aproximadamente 123,30 grados, con un rango intercuartil (cuartil superior - cuartil inferior) de 43,00 grados. Por otro lado, las sentadillas clasificadas como "mal" tienen una media de aproximadamente 159,00 grados, con un rango intercuartil de 37,40 grados. Esto indica una tendencia a una mayor extensión del codo en las sentadillas "mal" en comparación con las sentadillas "bien".

Al considerar las medianas de los ángulos del codo (*Figure 31*), se observa que las sentadillas clasificadas como "bien" tienen una mediana de aproximadamente 128,20 grados, con un rango intercuartil de 46,90 grados. Por otro lado, las sentadillas clasificadas como "mal" presentan una mediana de aproximadamente 158,80 grados, con un rango intercuartil de 30,90 grados. Esto sugiere una mayor flexión del codo en las sentadillas "bien" en comparación con las sentadillas "mal".

Al analizar los valores máximos de los ángulos del codo (*Figure 32*), se observa que tanto las sentadillas clasificadas como "bien" como "mal" presentan valores similares en todas las medidas. Por lo tanto, no se identifican diferencias notables en los valores máximos del ángulo del codo entre ambas clasificaciones. Por otra parte, al analizar los valores mínimos de los ángulos del codo (*Figure 33*), se observa una diferencia significativa entre las sentadillas clasificadas como "bien" y "mal". Las sentadillas "bien" presentan valores mínimos más altos, con una mediana de aproximadamente 61,40 grados y un rango intercuartil de 25,00 grados. Por otro lado, las sentadillas clasificadas como "mal" tienen una mediana de aproximadamente 141,80 grados, con un rango intercuartil de 98,50 grados. Esto sugiere una mayor extensión del codo en las sentadillas "mal" en comparación con las sentadillas "bien".

El análisis de la desviación estándar de los ángulos del codo (*Figure 34*) revela una diferencia notable entre las sentadillas clasificadas como "bien" y "mal". Las sentadillas "bien" presentan una desviación estándar más alta, con una mediana de aproximadamente 29,65 grados y un rango intercuartil de 14,79 grados. Por otro lado, las sentadillas clasificadas como "mal" tienen una desviación estándar mucho más baja, con una mediana de aproximadamente 4,36 grados y un rango intercuartil de 30,23 grados. Esto indica una mayor variabilidad en los ángulos del codo en las sentadillas "bien" en comparación con las sentadillas "mal".

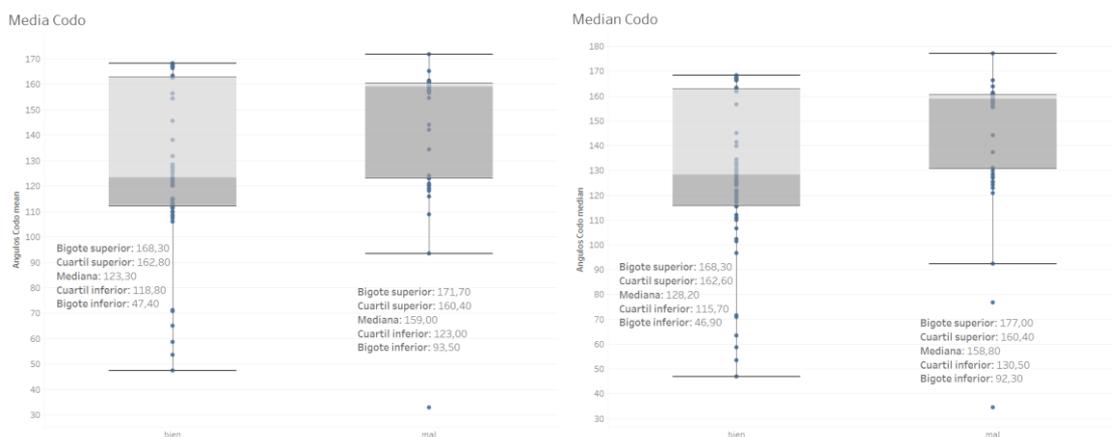


Figure 30: Boxplot Medias ángulo del codo. Fuente: Elaboración propia.

Figure 31: Boxplot Medianas ángulo del codo. Fuente: Elaboración propia.

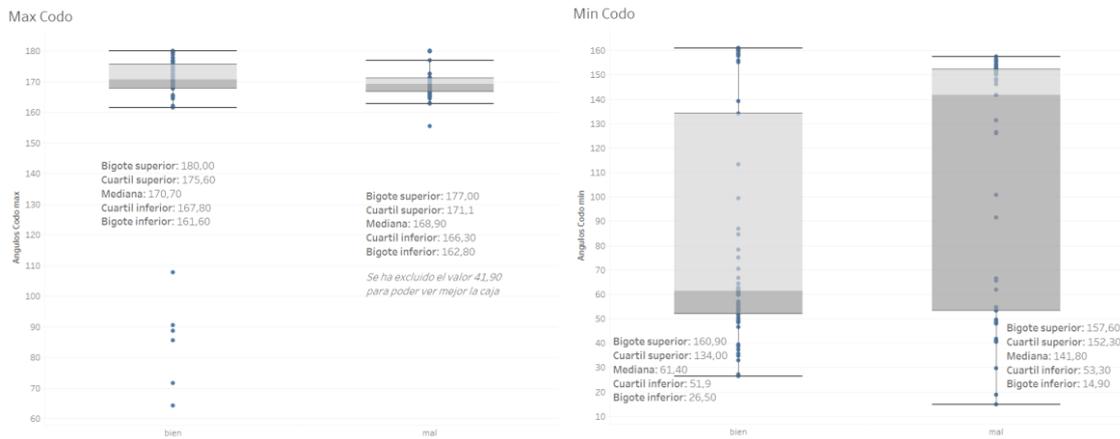


Figure 32: Boxplot Máximos ángulo del codo. Fuente: Elaboración propia.

Figure 33: Boxplot Mínimos ángulo del codo. Fuente: Elaboración propia.

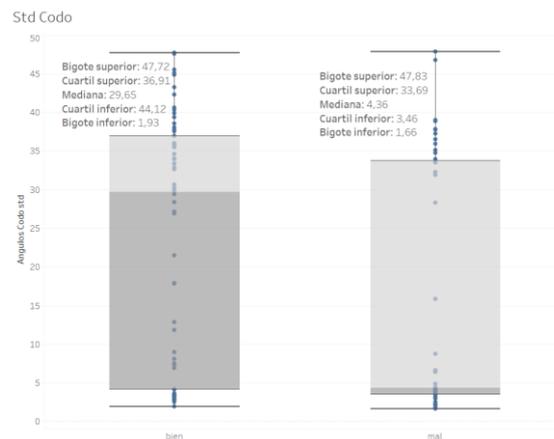


Figure 34: Boxplot Desviación estándar ángulo del codo. Fuente: Elaboración propia.

Por tanto, el análisis de los ángulos del codo en el ejercicio de las sentadillas muestra diferencias significativas entre las sentadillas clasificadas como "bien" y "mal". Las sentadillas "bien" tienden a presentar una menor extensión y flexión del codo, así como una mayor variabilidad en los ángulos. Por otro lado, las sentadillas "mal" muestran una mayor extensión del codo y una menor variabilidad en los ángulos.

### 3.1.6.4. Análisis de los ángulos de la rodilla

Por último, se van a analizar los ángulos de la rodilla. Las sentadillas clasificadas como "bien" presentan valores de media de los ángulos de la rodilla (Figure 35) más bajos en comparación con las sentadillas clasificadas como "mal". Esto sugiere una mayor flexión de la rodilla en las sentadillas clasificadas como "bien" en comparación con las clasificadas como "mal".

Las medianas de los ángulos de la rodilla (*Figure 36*) muestran una diferencia significativa entre las sentadillas clasificadas como "bien" y "mal". Las sentadillas clasificadas como "bien" presentan una menor extensión de la rodilla en comparación con las clasificadas como "mal".

Por una parte, los valores máximos de los ángulos de la rodilla (*Figure 37*) no presentan una diferencia significativa entre las sentadillas clasificadas como "bien" y "mal". Ambas clasificaciones alcanzan valores similares en los ángulos máximos de la rodilla. Por otra parte, los valores mínimos de los ángulos de la rodilla (*Figure 38*) muestran una diferencia notable entre las sentadillas clasificadas como "bien" y "mal". Las sentadillas clasificadas como "bien" presentan una mayor flexión mínima de la rodilla en comparación con las clasificadas como "mal".

La desviación estándar (*Figure 39*) muestra una diferencia significativa entre las sentadillas clasificadas como "bien" y "mal". Las sentadillas clasificadas como "bien" presentan una mayor variabilidad en los ángulos de la rodilla en comparación con las clasificadas como "mal".

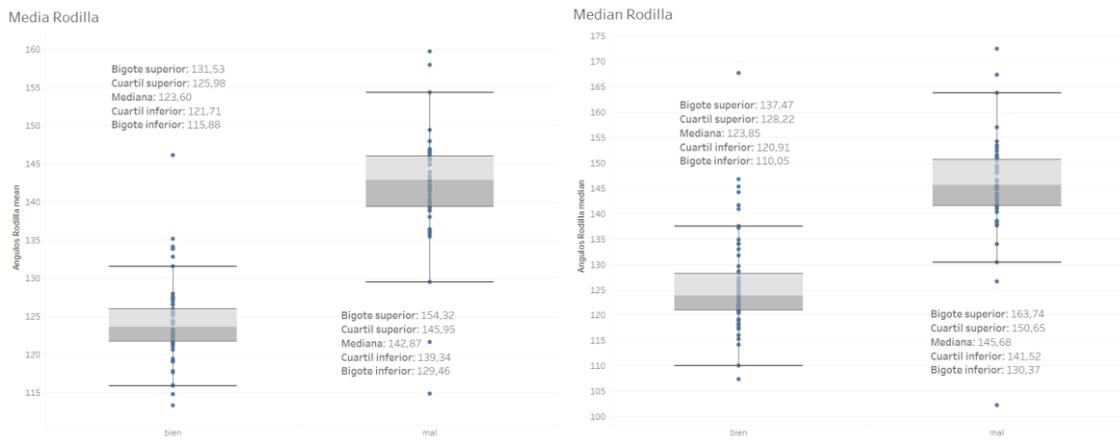


Figure 35: Boxplot Medias ángulo de la rodilla. Fuente: Elaboración propia.

Figure 36: Boxplot Mediana ángulo de la rodilla. Fuente: Elaboración propia.

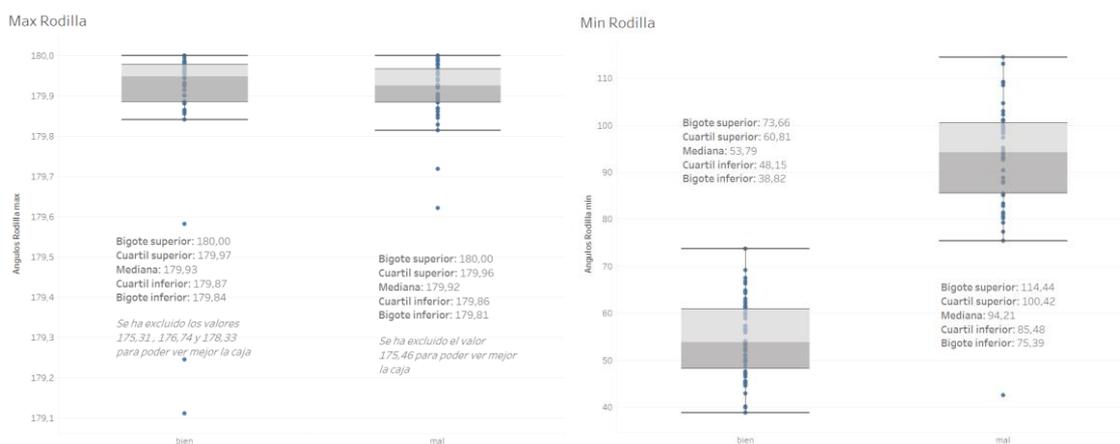


Figure 37: Boxplot Máximos ángulo de la rodilla. Fuente: Elaboración propia.

Figure 38: Boxplot Mínimos ángulo de la rodilla. Fuente: Elaboración propia.



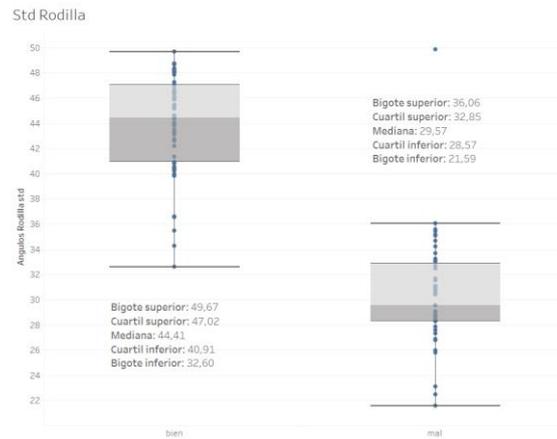


Figure 39: Boxplot Desviación Estándar ángulo de la rodilla. Fuente: Elaboración propia.

En conclusión, el análisis de los ángulos de la rodilla en las sentadillas revela diferencias significativas entre las clasificaciones "bien" y "mal". Las sentadillas clasificadas como "bien" muestran una menor extensión y flexión mínima de la rodilla, mayor variabilidad y medias más bajas en comparación con las sentadillas clasificadas como "mal". Estos hallazgos sugieren que una correcta ejecución del ejercicio de las sentadillas se asocia con ángulos de la rodilla más reducidos y menos variabilidad.

### 3.2. Modelos de clasificación

En vista de los resultados obtenidos en la clasificación manual de los vídeos de sentadillas, se ha tomado la decisión de emplear modelos de clasificación para automatizar y agilizar el proceso de clasificación en el futuro. Esta estrategia se basa en el uso de técnicas de aprendizaje automático y entrenamiento de los modelos con los datos previamente clasificados manualmente.

Para implementar este enfoque, se utilizarán algoritmos de clasificación supervisada, como la regresión logística, los árboles de decisión o las máquinas de vectores de soporte (SVM), que han demostrado ser eficientes en la clasificación de datos en diversos campos. Estos modelos se entrenarán utilizando el conjunto de datos de características significativas de los ángulos de los vídeos, dónde se utilizará la clasificación realizada (bien o mal) como variable objetivo.

Una vez que el modelo ha sido entrenado adecuadamente, se podrá utilizar para clasificar nuevos vídeos de sentadillas automáticamente. Estos vídeos podrán ser sometidos al modelo y, en base a las características extraídas, se obtendrá una predicción sobre si la ejecución de las sentadillas es correcta o incorrecta.

Sin embargo, es importante tener en cuenta que el modelo de clasificación automatizada estará sujeto a ciertos límites y consideraciones. La precisión de la clasificación dependerá de la calidad y representatividad de los datos utilizados para el entrenamiento, así como la generalización del modelo a nuevos vídeos con características similares. Además, es fundamental realizar evaluaciones periódicas del modelo y ajustarlo en consecuencia para mejorar su rendimiento.

Una estrategia ampliamente utilizada para obtener los parámetros óptimos de un modelo de clasificación es la búsqueda en rejilla. Esta técnica se emplea en el aprendizaje automático con el

objetivo de encontrar el mejor modelo posible. La búsqueda en rejilla implica definir un conjunto de valores para cada combinación de parámetros. Esto ayuda a identificar la combinación que maximiza la precisión del modelo en el conjunto de datos *test*.

### 3.2.1. Máquina de Vector Soporte (SVM)

Se ha optado por utilizar Máquinas de Vectores Soporte (*SVM*) para clasificar las sentadillas debido a varias ventajas. Las *SVM* son eficientes en conjuntos de datos de alta dimensionalidad, como los videos de sentadillas que contienen múltiples atributos. También funcionan bien con conjuntos de datos pequeños y pueden manejar conjuntos desequilibrados, como en este caso, donde hay más videos clasificados como buenas sentadillas. Además, las *SVM* son flexibles debido a las diferentes funciones de *kernel*, lo que les permite manejar casos no lineales en los que las clases no se separan claramente en un espacio de características lineal.

Para encontrar los parámetros óptimos, se realiza una búsqueda en rejilla exhaustiva. Los parámetros que se usan para la búsqueda son los siguientes:

- **C:** El parámetro *C* es un factor de regularización que controla la compensación entre el logro de una mejor separación de los datos de entrenamiento y la tolerancia a errores de clasificación. Cuanto mayor es el valor de *C* hay una penalización más fuerte por los errores de clasificación.
  - Si *C* es muy pequeño, el modelo *SVM* se centrará en maximizar el margen de separación incluso si algunos puntos de datos de entrenamiento se clasifican incorrectamente (mayor tendencia al *underfitting*).
  - Si *C* es, muy grande, el modelo *SVM* se esforzará por clasificar correctamente todos los puntos de datos de entrenamiento, incluso si se crea un margen de separación más pequeño (mayor tendencia al *overfitting*).

El ajuste adecuado del parámetro *C* es crucial para lograr un equilibrio entre precisión y la generalización del modelo *SVM*.

- **Gamma:** Define la influencia de un solo punto de datos en la formación de la frontera de decisión. Controla el alcance de influencia de los puntos de datos de entrenamiento en la formación de los límites de decisión.
  - Un valor pequeño de *gamma* significa que solo los puntos de datos cercanos a la frontera de decisión tienen un impacto significativo en la clasificación. Esto genera límites de decisión más suaves y un modelo *SVM* más generalizado.
  - Un valor grande de *gamma* implica que los puntos de los datos de entrenamiento más lejanos tienen un impacto más significativo en la clasificación. Esto genera límites de decisión más ajustados y un modelo *SVM* más ajustado a los datos de entrenamiento (mayor tendencia al *overfitting*).

La elección adecuada del parámetro *gamma* es crucial para el rendimiento del modelo *SVM* y puede depender de la naturaleza de los datos y la complejidad del problema.

- **Kernel:** Especifica la función de *kernel* utilizada para transformar los datos de entrada en un espacio de características de mayor dimensión, donde los datos pueden ser linealmente separables. Los *kernels* más comunes son los siguientes:
  - **Lineal** (*'linear'*): No realiza ninguna transformación y se utiliza para problemas linealmente separables en el espacio original.
  - **RBF** (Función de Base Radial, *'rbf'*): Transforma los datos en un espacio de características infinitamente dimensional utilizando una función de base radial.



Es útil para problemas no lineales y puede manejar fronteras de decisión más complejas.

- Polinómico (*'poly'*): Transforma los datos en un espacio de características utilizando una función polinómica. El grado del polinomio se especifica mediante el parámetro *'degree'*.

La elección del *kernel* depende de la naturaleza del problema y la relación entre los datos de entrada. Algunos problemas pueden requerir un *kernel* no lineal, mientras que otros pueden funcionar bien con un *kernel* lineal.

### 3.2.2. Árbol de decisión

Los Árboles de decisión se han seleccionado para clasificar las sentadillas debido a varias razones. En primer lugar, ofrecen una interpretación intuitiva al proporcionar reglas comprensibles basadas en ángulos del cuerpo humano, lo que facilita la obtención de conocimientos interpretables para mejorar el rendimiento deportivo. Además, son capaces de manejar datos numéricos, lo cual es fundamental en el caso de los ángulos utilizados. También destacan por su escalabilidad y eficiencia, lo que los hace adecuados para trabajar con conjuntos de datos grandes y complejos, como los recopilados para este TFG que involucra múltiples individuos y mediciones de ángulos.

Se utiliza una búsqueda de rejilla exhaustiva para encontrar los mejores parámetros. En la búsqueda se van a tener en cuenta los siguientes parámetros:

- *Criterion*: El criterio se refiere a la medida utilizada para evaluar la calidad de una división en un árbol de decisión. Los dos criterios comunes son *"gini"* y *"entropia"*. El criterio *"gini"* se basa en el índice de impureza de Gini, mientras que el criterio de *"entropia"* se basa en la ganancia de información. Ambos criterios buscan maximizar la pureza de las clases en los nodos del árbol.
- *Max\_depth*: Este parámetro indica la profundidad máxima permitida para el árbol de decisión. Controla el número máximo de niveles de divisiones que el árbol puede tener. Una mayor profundidad puede permitir que el árbol capture relaciones más complejas en los datos, pero también puede llevar a un sobreajuste (*overfitting*) si no se ajusta adecuadamente.
- *Min\_samples\_split*: Este parámetro establece el número mínimo de muestras requeridas para que un nodo se divida en subnodos. Si el número de muestras en un nodo es menor que el valor establecido en *min\_samples\_spli*, entonces no se realizará una división adicional en ese nodo. Un valor más alto de *min\_samples\_split* puede evitar divisiones que resulten en subárboles demasiado pequeños y que se ajusten demasiado a ruido o variaciones aleatorias en los datos.
- *Min\_samples\_leaf*: Este parámetro indica el número mínimo de muestras requeridas en una hoja del árbol de decisión. Si una división resulta en una hoja con un número de muestras menor al valor establecido en *min\_samples\_leaf*, entonces dicha división se considera no válida y se detiene. Un valor más alto de *min\_samples\_leaf* puede evitar particiones demasiado específicas y ayudar a controlar el sobreajuste al requerir un número mínimo de muestras en cada hoja.

### 3.2.3. Regresión logística

La regresión logística se elige como enfoque adecuado para clasificar las sentadillas debido a varias razones. En primer lugar, permite interpretar las probabilidades de pertenencia a una categoría específica, lo que facilita la comprensión de la clasificación de las sentadillas. Además, es capaz de manejar características numéricas, como los ángulos del cuerpo humano, que son relevantes para este tipo de datos. La regresión logística es flexible y adaptable, lo que permite considerar otras variables importantes para la clasificación. Por último, es un método ampliamente utilizado y cuenta con implementaciones eficientes en herramientas de análisis de datos, lo que facilita su aplicación y obtención de resultados.

Se emplea una búsqueda exhaustiva en una rejilla para encontrar los parámetros óptimos. En esta búsqueda se consideran los siguientes parámetros:

- *C*: El parámetro *C* en la regresión logística controla la fuerza de regularización del modelo. La regularización es una técnica utilizada para evitar el sobreajuste (*overfitting*) al penalizar los coeficientes de las variables. Un valor más pequeño de *C* aumenta la regularización, lo que significa que el modelo tiende a tener coeficientes más pequeños y una mayor tendencia a la simplicidad. Por otro lado, un valor más grande de *C* disminuye la regularización, lo que permite al modelo ajustarse más a los datos de entrenamiento.
- *Penalty*: Determina el tipo de regularización aplicada en la regresión. Puede tomar dos valores comunes “*l1*” y “*l2*”. La penalización “*l1*” utiliza la norma L1 para penalizar los coeficientes, lo que puede conducir a una selección de características automática al hacer que algunos coeficientes sean exactamente cero. Por otro lado, la penalización “*l2*” utiliza la norma L2 para penalizar los coeficientes, lo que fomenta coeficientes más pequeños, pero no los reduce a cero. La elección entre “*l1*” y “*l2*” depende de las características del problema y puede influir en la interpretabilidad del modelo.
- *Solver*: Se refiere al algoritmo utilizado para resolver el problema de optimización asociado con la regresión logística. Diferentes *solvers* pueden ser más eficientes o efectivos según el tamaño del conjunto de datos y la naturaleza del problema. Algunos *solvers* comunes incluyen “*liblinear*”, “*newton-cg*”, “*lbfgs*” y “*sag*”. Cada *solver* puede tener diferentes características y propiedades, por lo que es importante elegir el adecuado para el contexto específico.

### 3.3. Normalización de los datos

La normalización de datos es una técnica comúnmente utilizada en el preprocesamiento de datos en el aprendizaje automático, y consiste en ajustar y escalar los valores de las características para que se encuentren dentro de un rango específico.

El *MinMaxScaler* es una herramienta que permite realizar esta normalización. Al utilizarlo, se transforman los datos de manera que el valor mínimo de cada característica se ajusta a cero, y el valor máximo se ajusta a uno. Esto se logra aplicando la siguiente fórmula para cada valor de característica:

$$x_{escalado} = \frac{x - x_{min}}{x_{max} - x_{min}}$$



Donde:

- $x_{escalado}$  es el valor original de la característica.
- $x_{min}$  es el valor mínimo de la característica en el conjunto de datos.
- $x_{max}$  es el valor máximo de la característica en el conjunto de datos.

Al realizar esta transformación, los datos quedan en un rango estandarizado y acotado entre cero y uno. Esto es especialmente útil cuando las características tienen escalas diferentes y no queremos que una característica con valores más grandes tenga un impacto dominante en el modelo en comparación con las características con valores más pequeños.

La normalización de datos con *MinMaxScaler* puede ser beneficiosa para modelos como *SVM*, ya que ayuda a mejorar la convergencia y el rendimiento del algoritmo, especialmente cuando las características tienen rangos diferentes. Al escalar los datos al mismo rango, se garantiza que todas las características contribuyan de manera equitativa al modelo y se evitan problemas de dominación o sesgo hacia características específicas.

### 3.4. Métricas de validación

Las métricas de validación de los modelos de clasificación incluyen la matriz de confusión y el *accuracy* (exactitud). A continuación, se detalla cada una de estas métricas.

La matriz de confusión es una tabla que muestra la clasificación de las instancias en un problema de clasificación. En el caso de un problema binario, como el que se plantea en la clasificación de vídeos de sentadillas (bien o mal), la matriz de confusión tendrá cuatro elementos:

1. *True Positive (TP)*: se utiliza para describir los casos en los que el modelo identifica correctamente como positivos aquellos casos que realmente son positivos. En este caso, representa las instancias correctamente clasificadas como positivas, es decir, ejecución de sentadilla bien.
2. *True Negative (TN)*: son aquellos casos en los que la predicción del modelo indica correctamente que pertenecen a la clase negativa. En este caso, representa las instancias clasificadas como negativas, es decir, ejecución de sentadilla mal.
3. *False Positive (FP)*: se utiliza para describir las muestras que son incorrectamente identificadas como positivas por el modelo, pero en realidad pertenecen a la clase negativa según los datos de prueba o los datos reales. Por lo tanto, los falsos positivos representan casos en los que el modelo genera una predicción errónea al clasificar una muestra como positiva cuando en realidad es negativa.
4. *False Negative (FN)*: son aquellos en los que la predicción del modelo indica correctamente que pertenecen a la clase negativa y, de hecho, son muestras de la clase negativa.

La matriz de confusión se organiza como podemos observar en la *Figure 40*:

		PREDICCIÓN	
		Bien	Mal
REAL	Bien	TP	FN
	Mal	FP	TN

*Figure 40: Ejemplo de matriz de confusión.  
Fuente: Elaboración propia*

Una vez definida la matriz de confusión con sus valores correspondientes ( $TP$ ,  $TN$ ,  $FP$ ,  $FN$ ), podemos calcular varias métricas clave que proporcionan una evaluación más detallada del rendimiento del modelo de clasificación:

- Exactitud (*accuracy*): es el criterio más utilizado para evaluar el rendimiento de un modelo de clasificación, ya que refleja el número de muestras correctamente clasificadas con relación al total de muestras. Sin embargo, es importante tener en cuenta que la exactitud tiene ciertas limitaciones, especialmente en conjuntos de datos desequilibrados. En conjuntos de datos desequilibrados, donde una clase está sobrerrepresentada en comparación con otra, la exactitud puede ser engañosa. Esto se debe a que un modelo puede lograr una alta exactitud al clasificar correctamente la clase mayoritaria, mientras que puede tener un rendimiento deficiente en la clasificación de la clase minoritaria (Arce, 2019).

$$\text{Exactitud} = \frac{(TP+TN)}{(TP+TN+FP+FN)}$$

- Precisión: es una métrica que indica la proporción de verdaderos positivos que el modelo ha clasificado correctamente en relación con el número total de valores positivos que ha predicho. Sin embargo, es necesario tener en cuenta que la precisión también puede verse afectada por conjuntos de datos desequilibrados. Esto significa que cambios en la proporción de muestras en diferentes clases pueden afectar el valor informado por la precisión, incluso si el rendimiento del modelo se mantiene constante. Por ejemplo, si tenemos un conjunto de datos en el que la clase positiva es minoritaria y la clase negativa es mayoritaria, un modelo puede obtener una alta precisión al clasificar correctamente la clase negativa debido a su predominio en el conjunto de datos, incluso si su rendimiento en la clasificación de la clase positiva es deficiente.

$$\text{Precisión} = \frac{TP}{(TP+FP)}$$

- Sensibilidad: mide la tasa de clasificación positiva correcta. En otras palabras, indica la proporción de muestras positivas que el modelo ha clasificado correctamente en relación con el número total de muestras positivas. Una de las ventajas de la sensibilidad es que no se ve afectada por conjuntos de datos desequilibrados, lo que significa que la proporción de muestras en diferentes clases no influye en su valor. La sensibilidad es equivalente a la Tasa de Verdaderos Positivos (TVP).

$$\text{Sensibilidad} = \frac{TP}{(TP+FN)}$$

- F1-Score: representa una métrica de evaluación utilizada en el aprendizaje automático para combinar tanto la precisión como la sensibilidad en una métrica. Esta métrica resulta útil cuando se busca obtener un equilibrio entre ambas medidas, en lugar de enfocarse únicamente en una de ellas, tal como señala (Arce, 2019).

$$F1 \text{ score} = 2 * \frac{\text{Precisión} * \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}}$$

- Tasa de Falsos Positivos (TFP) se utiliza para medir la probabilidad de que se genere una falsa alarma, es decir, la probabilidad de que el modelo de predicción indique que el valor es positivo cuando en realidad es negativo. En otras palabras, representa la proporción de



muestras que han sido clasificadas incorrectamente como positivas, cuando en realidad son negativas, como menciona (Arce, 2019)

$$TFP = \frac{FP}{(FP + TN)}$$

- Tasa de Falsos Negativos (TFN): es una métrica que evalúa la probabilidad de que el modelo de predicción no detecte un verdadero positivo. En pocas palabras, se refiere a la probabilidad de que la prueba pase por alto una muestra positiva cuando en realidad debería de haberla identificado.

$$TFN = \frac{FN}{(FN + TP)}$$

Estas métricas de validación son herramientas importantes para evaluar el rendimiento de los modelos de clasificación y determinar su capacidad para clasificar correctamente los vídeos de sentadillas según la ejecución adecuada o inadecuada.

# 4. Resultados

---

## 4.1. Resultados de los modelos de clasificación

Para cada modelo de clasificación utilizado, que incluye *SVM*, árboles de decisión y regresión logística, se generarán tres modelos distintos, aunque en realidad acabarán siendo seis. Para cada modelo se aplicarán tres diferentes técnicas de división de datos (*holdout*, *k-folds* y *leave-one.out*). Estos modelos se construirán considerando tanto la normalización como la ausencia de normalización de los datos.

Por tanto, se implementarán dos versiones de cada modelo: una versión sin normalización de datos y otra versión con normalización de datos. Cada versión se entrenará utilizando una de las técnicas de división de datos mencionadas, lo que dará lugar a un conjunto completo de seis modelos. Esto permitirá evaluar y comparar el rendimiento de cada modelo en función de la normalización y la técnica de división de datos utilizada.

### 4.1.1. Resultados modelo SVM

#### 4.1.1.1. Modelo 1

El modelo *SVM* entrenado sin normalizar los datos y con una división de datos de tipo *holdout* (con un *test\_size* de 20%) ha obtenido un *accuracy* de 0.9583333333333334, lo que indica que ha logrado clasificar correctamente aproximadamente el 95.58% de las instancias.

Los mejores hiperparámetros encontrados para este modelo son: '*C*': 0.1, '*gamma*': 0.1 y '*kernel*': '*linear*'. Estos determinan la configuración del modelo *SVM* afectan su capacidad para separar y clasificar los datos. Respecto al parámetro *C*, se puede observar que es bajo, por tanto, como se ha explicado anteriormente, permite una mayor regularización. El parámetro *gamma* también es bajo, por tanto, indica una influencia alta y un alcance amplio. Por último, el *kernel* que se ha utilizado es el lineal, que es una función de *kernel* lineal simple.

La matriz de confusión de este modelo (*Figure 41*) proporciona información detallada sobre el rendimiento del modelo en términos de clasificación correcta o incorrecta:

- *TP*: Se han clasificado correctamente 13 instancias en esta categoría, es decir, son instancias clasificadas correctamente como “bien” cuando en realidad son “bien”.
- *TN*: Se han clasificado correctamente 10 instancias en esta categoría, es decir, en este caso son instancias clasificadas correctamente como “mal” cuando en realidad son “mal”.
- *FP*: Hay una instancia clasificada incorrectamente en esta categoría, es decir, está clasificada como “bien” cuando en realidad es “mal”.
- *FN*: No hay instancias clasificadas incorrectamente en esta categoría.



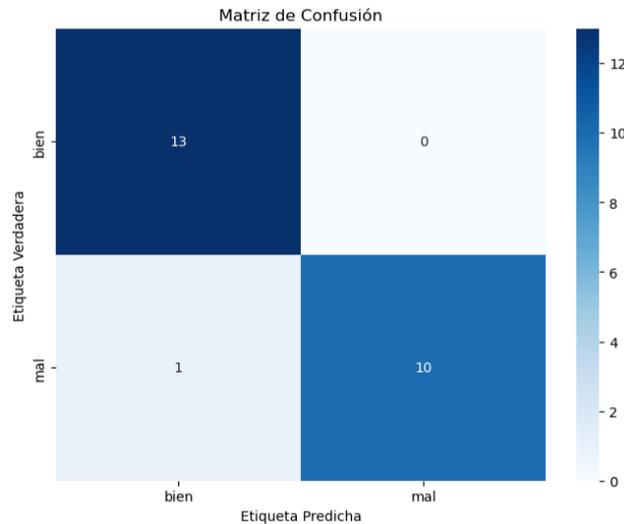


Figure 41: Matriz de confusión modelo 1 SVM sin normalizar.  
Fuente: Elaboración propia.

En resumen, el primer modelo de SVM sin normalización de datos y con una división de datos de tipo *holdout* ha obtenido un alto *accuracy* y ha logrado clasificar correctamente la mayoría de las instancias. Los hiperparámetros encontrados y la matriz de confusión brindan información adicional sobre la configuración y el rendimiento detallado del modelo.

Al realizar el mismo modelo pero normalizando los datos, se obtiene el mismo resultado que sin normalizar los datos. Se obtiene el mismo *accuracy*, los mismos hiperparámetros y la misma matriz de confusión.

#### 4.1.1.2. Modelo 2

Por otra parte, el segundo modelo SVM entrenado sin la normalización de datos y con la división de datos de tipo *k-folds* ha obtenido un *accuracy* de 0.9576271186440678, lo que indica que ha logrado clasificar correctamente el 95.76% de las instancias.

Al realizar la validación cruzada con la técnica *k-folds* en el modelo, se ha determinado que el valor óptimo de *k*, es decir, el número de divisiones del conjunto de datos es  $k=9$  (Figure 42). Este resultado se obtuvo al evaluar el rendimiento del modelo utilizando diferentes valores de *k* y seleccionando aquel que proporcionó los mejores resultados en términos de precisión y rendimiento general. Por lo tanto, se utilizará  $k=9$  en la implementación final del modelo para asegurar una validación cruzada efectiva y precisa.

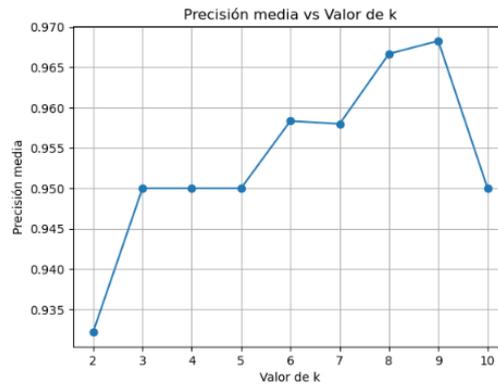


Figure 42: Precisión medida VS Valor de k. Fuente: Elaboración propia.

Los hiperparámetros utilizados en este modelo son los mismos que el modelo anterior: 'C': 0.1, 'gamma': 0.1, 'kernel': 'linear'. Estos parámetros determinan la configuración del modelo SVM y se mantienen constantes en ambos modelos para poder comparar su desempeño con y sin normalización de datos.

La matriz de confusión Figure 43 proporciona información adicional sobre el rendimiento detallado del modelo en términos de clasificación correcta e incorrecta de las instancias:

- **TP:** En este caso, se han clasificado correctamente 67 instancias en esta categoría, es decir, son instancias clasificadas correctamente como “bien” cuando en realidad son “bien”.
- **TN:** Se han clasificado correctamente 46 instancias en esta categoría, es decir, en este caso son instancias clasificadas correctamente como “mal” cuando en realidad son “mal”.
- **FP:** En el modelo, hay 4 instancia clasificada incorrectamente en esta categoría, es decir, está clasificada como “bien” cuando en realidad es “mal”.
- **FN:** Hay 1 instancia clasificada incorrectamente en esta categoría, es decir, está clasificada como “mal” cuando en realidad es “bien”.

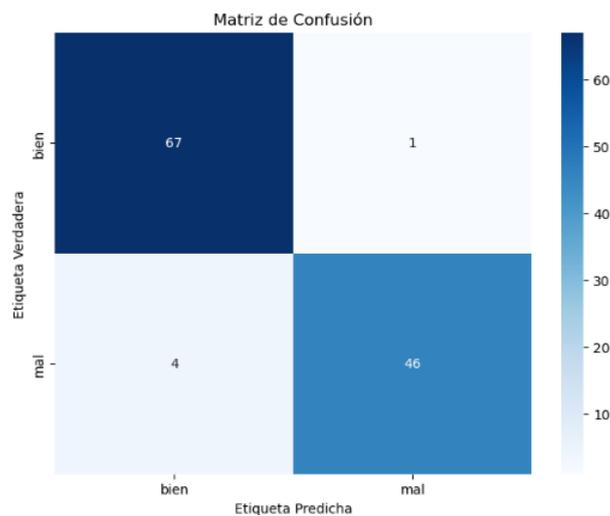
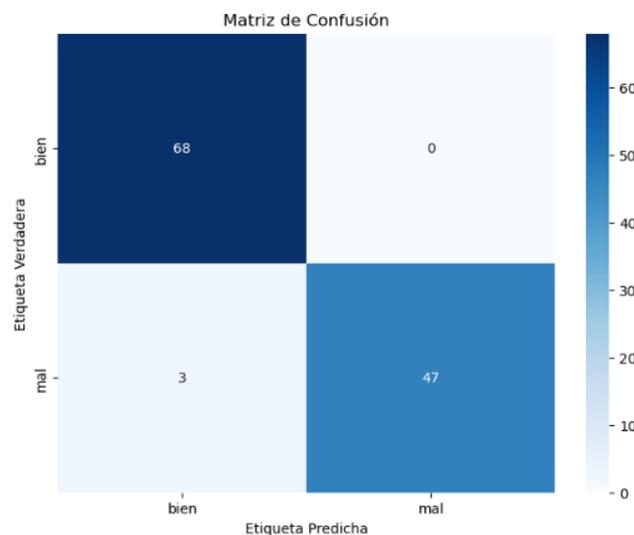


Figure 43: Matriz de confusión modelo 2 SVM sin normalizar. Fuente: Elaboración propia.



Si ahora observamos el mismo modelo pero normalizando los datos, vemos que el *accuracy* es 97.45%, es decir, al normalizar los datos ha aumentado el valor. La mejor *k* obtenida es la misma, *k*= 9 y los mejores hiperparámetros encontrados también son los mismos que el modelo sin normalizar los datos. Pero la matriz de confusión (*Figure 44*) sí que cambia:

- *TP*: En este caso, se han clasificado correctamente 68 instancias en esta categoría, es decir, son instancias clasificadas correctamente como “bien” cuando en realidad son “bien”.
- *TN*: Se han clasificado correctamente 47 instancias en esta categoría, es decir, en este caso son instancias clasificadas correctamente como “mal” cuando en realidad son “mal”.
- *FP*: En el modelo, hay 3 instancia clasificada incorrectamente en esta categoría, es decir, está clasificada como “bien” cuando en realidad es “mal”.
- *FN*: No hay ninguna instancia en esta categoría.



*Figure 44: Matriz de confusión modelo 2 SVM normalizando.*  
Fuente: Elaboración propia.

### 4.1.1.3. Modelo 3

Este último modelo SVM entrenado sin normalizar los datos y con una división de datos de tipo *leave-one-out* ha obtenido un *accuracy* de 1.0, lo que indica que ha logrado clasificar correctamente el 100% de las instancias. Los mejores hiperparámetros encontrados para este modelo son: '*C*': 0.1, '*gamma*': 0.1 y '*kernel*': '*linear*'.

La matriz de confusión de este modelo (*Figure 45*) proporciona información detallada sobre el rendimiento del modelo en términos de clasificación correcta o incorrecta:

- *TP*: Se han clasificado correctamente 68 instancias en esta categoría.
- *TN*: Se han clasificado correctamente 10 instancias en esta categoría.
- *FP*: No hay instancias en esta categoría.
- *FN*: Tampoco hay instancias en esta categoría.

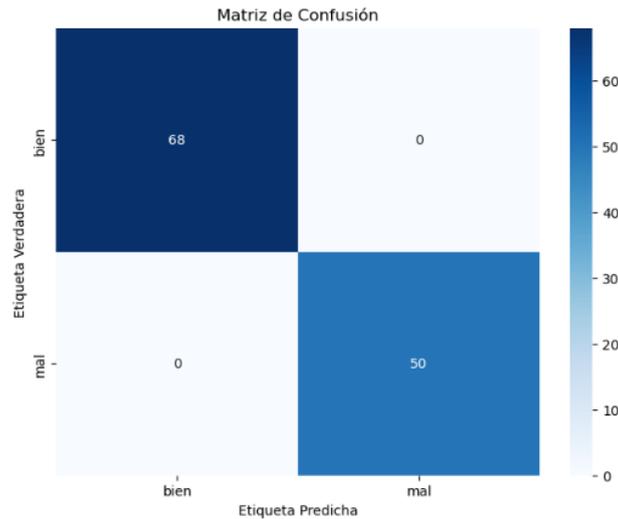


Figure 45: Matriz de confusión modelo 2 SVM sin normalización.  
Fuente: Elaboración propia.

Al normalizar los datos en este modelo, vemos como el *accuracy* baja a 0.9830508474576272, es decir, un 98.30%. Los mejores hiperparámetros encontrados han sido los mismos.

Cabe destacar que el hecho de obtener un 100% de precisión en la clasificación puede indicar que el modelo se ha ajustado demasiado a los datos de entrenamiento y no generaliza bien en nuevos datos. Al aplicar la normalización de los datos, se busca reducir el impacto de las diferencias de escala y magnitud entre las características, lo que puede ayudar a evitar el sobreajuste y mejorar la capacidad del modelo para generalizar correctamente en datos no vistos. La disminución en el *accuracy* al normalizar los datos a un 98.30% sugiere que el modelo ha logrado un mejor equilibrio entre el ajuste a los datos de entrenamiento y la capacidad de generalización a nuevos datos.

#### 4.1.1.4. Comparación de modelos SVM

En base al análisis de los resultados obtenidos, se puede observar que el Modelo 3 ha alcanzado el mejor desempeño en términos de *accuracy*. Sin embargo, es importante tener en cuenta que este modelo ha obtenido un *accuracy* del 100% sin normalizar los datos, lo cual sugiere la posibilidad de un sobreajuste. Por otro lado, al normalizar los datos, el Modelo 3 ha obtenido un *accuracy* ligeramente menor, del 98,30%.

Comparando estos resultados con los del Modelo 2, se puede apreciar que este último ha logrado un buen desempeño tanto sin normalizar como al normalizar los datos, con *accuracy* de 95,7% y 97,45%, respectivamente. Si consideramos la estabilidad y generalización del modelo, es recomendable optar por el Modelo 2, ya que ha demostrado un rendimiento consistente en ambos escenarios y ha logrado un alto *accuracy* después de la normalización de los datos.

En conclusión, se recomienda seleccionar el Modelo 2 como el mejor en términos de precisión y capacidad de generalización, ya que ha mantenido un buen desempeño tanto en los datos sin normalizar como en los datos normalizados. Esto sugiere que el Modelo 2, es decir, el que tiene división de datos de tipo *k-folds*, puede ser más confiable y estable en la clasificación de los datos

de interés en comparación con el Modelo 3, que muestra posibles signos de sobreajuste en los datos sin normalizar.

### 4.1.2. Resultados modelo Árbol de decisión

A partir de ahora, se presenta un resumen conciso de los modelos, donde los gráficos de los *k-folds* y las matrices de confusión se incluirán en el anexo. Esto se hace con el objetivo de agilizar el análisis y la revisión de los resultados, permitiendo que el informe principal se centre en los aspectos más relevantes de los modelos. Los detalles específicos de cada modelo, incluyendo los gráficos y las matrices de confusión, estarán disponibles en el anexo adjunto al informe. De esta manera, se proporcionará una visión general completa y se facilitará la revisión detallada de los resultados por parte de los interesados.

#### 4.1.2.1. Modelo 1

En el primer modelo, que utiliza una división de datos *holdout* con un 20% para pruebas y un 80% para entrenamiento sin normalización, se obtuvo un *accuracy* de 95.83%. Los mejores hiperparámetros encontrados fueron {'*criterion*': '*gini*', '*max\_depth*': *None*, '*min\_samples\_leaf*': 1, '*min\_samples\_split*': 10}. Sin embargo, al normalizar los datos, se logró un *accuracy* del 100% con los hiperparámetros {'*criterion*': '*gini*', '*max\_depth*': *None*, '*min\_samples\_leaf*': 2, '*min\_samples\_split*': 10}.

#### 4.1.2.2. Modelo 2

En el segundo modelo, se utilizó una división de datos *k-fold* para buscar el mejor modelo. Sin normalizar los datos, se obtuvo un *accuracy* de 94.06%, con el valor óptimo de *k* siendo 9. Los mejores hiperparámetros encontrados fueron {'*criterion*': '*gini*', '*max\_depth*': *None*, '*min\_samples\_leaf*': 1, '*min\_samples\_split*': 2}. Al normalizar los datos, el *accuracy* fue de 0.93222, la mejor *k* fue 8 y los hiperparámetros resultaron ser {'*criterion*': '*gini*', '*max\_depth*': *None*, '*min\_samples\_leaf*': 2, '*min\_samples\_split*': 2}.

#### 4.1.2.3. Modelo 3

En el tercer modelo, se empleó el método de división de datos *leave-one-out*. Sin normalizar los datos, se obtuvo un *accuracy* del 100% con los mejores hiperparámetros {'*criterion*': '*gini*', '*max\_depth*': *None*, '*min\_samples\_leaf*': 4, '*min\_samples\_split*': 2}. Al normalizar los datos, el *accuracy* también fue del 100%, con los hiperparámetros {'*criterion*': '*gini*', '*max\_depth*': *None*, '*min\_samples\_leaf*': 1, '*min\_samples\_split*': 5}.

#### 4.1.2.4. Comparación de modelos de árboles de decisión

Teniendo en cuenta la posibilidad de sobreajuste, me quedaría con el primer modelo que utiliza la división de datos *holdout* sin normalización. Aunque el modelo normalizado alcanza un *accuracy* perfecto, es probable que esté sobreajustado a los datos de entrenamiento y no generalice bien a nuevos datos. El primer modelo, con una alta precisión de 95,8% y buenos hiperparámetros

*{'criterion': 'gini', 'max\_depth': None, 'min\_samples\_leaf': 1, 'min\_samples\_split': 10}*, parece ser una elección más equilibrada y con menor riesgo de sobreajuste.

#### **4.1.3. Resultados Regresión logística**

En este punto también se va a realizar un resumen conciso de los modelos, donde los gráficos de los *k-folds* y las matrices de confusión se incluirán en el anexo.

##### **4.1.3.1. Modelo 1**

En el primer modelo, se aplicó una división de datos *holdout*, utilizando un 20% de los datos para prueba y un 80% para entrenamiento, sin realizar normalización. Este modelo obtuvo un *accuracy* de 95.83%. Los hiperparámetros óptimos encontrados fueron *{'C': 0.1, 'penalty': 'l1', 'solver': 'liblinear'}*. Sorprendentemente, al normalizar los datos, se obtuvo el mismo *accuracy* y los mismos hiperparámetros óptimos.

##### **4.1.3.2. Modelo 2**

En el segundo modelo, se utilizó una división de datos *k-fold* para encontrar la mejor configuración. Sin normalización, se alcanzó un *accuracy* de 97.46%, con el mejor valor de *k* igual a 10. Los hiperparámetros óptimos para esta configuración fueron *{'C': 0.1, 'penalty': 'l2', 'solver': 'saga'}*. Por otro lado, al normalizar los datos, se logró un *accuracy* de 98.31%, con la mejor *k* igual a 9. Los hiperparámetros óptimos en este caso fueron *{'C': 1, 'penalty': 'l1', 'solver': 'liblinear'}*.

##### **4.1.3.3. Modelo 3**

El tercer modelo utilizó una estrategia de división de datos *leave-one-out*. Sin normalización, se obtuvo un *accuracy* perfecto de 1.0, y los mejores hiperparámetros encontrados fueron *{'C': 1, 'penalty': 'l2', 'solver': 'liblinear'}*. Al normalizar los datos, el *accuracy* se redujo ligeramente a 99.15%, pero se mantuvo un rendimiento excelente. Los hiperparámetros óptimos en este caso fueron *{'C': 1, 'penalty': 'l1', 'solver': 'liblinear'}*.

##### **4.1.3.4. Comparación de modelos de regresión logística**

Teniendo en cuenta la posibilidad de sobreajuste, es importante considerar el modelo que proporciona un buen rendimiento sin comprometer la generalización. En este caso, el segundo modelo con división de datos *k-fold* y normalización de los datos presenta un buen equilibrio entre rendimiento y capacidad de generalización, ya que obtuvo un *accuracy* de 98.31% y mostró un desempeño sólido en diferentes configuraciones de *k*.

#### **4.1.4. Comparación de los tres modelos**

En base al análisis de los resultados obtenidos en el presente estudio, se ha evaluado el desempeño de tres modelos de aprendizaje automático: *SVM*, árbol de decisión y regresión logística. Estos modelos han sido comparados en términos de precisión y capacidad de generalización, considerando diferentes técnicas de división de datos y normalización.



## Mejora del rendimiento deportivo mediante visión artificial

Teniendo en cuenta la posibilidad de sobreajuste y la importancia de obtener resultados confiables y generalizables, se recomienda seleccionar el Modelo 2 de regresión logística con división de datos *k-fold* y normalización. Este modelo ha mantenido un buen rendimiento tanto en los datos sin normalizar como en los datos normalizados, lo cual indica su confiabilidad en la clasificación de nuevos datos.

# 5. Conclusiones

---

## 5.1. Conclusiones del estudio

Basándose en los estudios de clasificaciones anteriores, se ha determinado que el modelo de regresión logística, aplicando la normalización de datos y la división de datos *k-fold*, ofrece el mejor rendimiento para el objetivo de mejora del rendimiento deportivo mediante la visión artificial.

A partir de este punto, al recibir un nuevo vídeo de una persona realizando sentadillas, se extraerán los ángulos y las características significativas de dichos ángulos, siguiendo el mismo enfoque utilizado en la base de datos. Estas características significativas se introducirán en el modelo de regresión logística para obtener una predicción sobre si el ejercicio está siendo realizado correctamente o no.

Si la clasificación resultante indica que el ejercicio está siendo realizado correctamente, se proporcionará al usuario el mismo vídeo, con una superposición visual que resalte el ángulo de la rodilla, considerado el más relevante y el tiempo empleado en cada una de ellas. Además, se registrarán y se mostrarán el número de repeticiones realizadas y el tiempo empleado en cada una de ellas. También se indicará el tipo de sentadilla realizada que considera normal (alcanzando un ángulo de justo 90° en las rodillas) o si se trata de una sentadilla profunda (descendiendo por debajo de los 90°).

En caso de que la clasificación del ejercicio sea negativa, se analizarán las características específicas que deben mejorarse para lograr una ejecución correcta. Se compararán estas características con el análisis previo realizado en la base de datos, donde se evaluaron las características cuando el ejercicio estaba siendo realizado correctamente. De esta manera, se podrán identificar las áreas que requieren atención y mejora para lograr una técnica adecuada.

En resumen, el uso de visión artificial y el modelo de regresión logística ofrece un enfoque para mejorar el rendimiento deportivo en el ejercicio de sentadillas. El sistema es capaz de proporcionar retroalimentaciones en tiempo real, mostrando visualmente el ángulo de la rodilla, registrando repeticiones y tiempos, y ofreciendo recomendaciones específicas para corregir y perfeccionar la técnica en caso de una clasificación negativa. Este enfoque promete ser una herramienta útil en el ámbito del entrenamiento y la mejora del rendimiento deportivo.

### 5.1.1. Clasificar un nuevo vídeo

Una vez obtenido un nuevo vídeo, se realizan extracciones de los ángulos del codo, hombro, cadera y rodilla en cada uno de los *frames* (igual que se ha realizado para crear la base de datos) *Figure 47*. A partir de los ángulos, se calculan las características significativas correspondientes. Estas características *Figure 48* se utilizan como entrada para el modelo de regresión logística previamente entrenado.

Video	Frame	Angulos_Rodilla	Angulos_Caderas	Angulos_Hombro	Angulos_Codo	
0	116	1	97.190369	89.852479	84.829917	146.279407
1	116	2	98.284462	90.138770	84.862695	146.279582
2	116	3	97.508033	89.554437	85.760941	149.155819
3	116	4	98.615648	90.334966	84.030650	148.099843
4	116	5	99.916318	90.957611	84.030650	148.099843
...	...	...	...	...	...	...
432	116	433	101.818763	88.799454	77.509839	143.071004
433	116	434	102.139519	89.244202	77.836469	143.842382
434	116	435	102.375474	89.428965	74.128821	141.896084
435	116	436	98.208447	86.616271	78.154609	146.081473
436	116	437	96.911227	86.529080	80.216888	148.056373

Figure 46: Excel con los datos por cada frame de un vídeo nuevo.  
Fuente: Elaboración propia.

Video	Angulos_Rodilla_mean	Angulos_Rodilla_median	Angulos_Rodilla_calcular_moda	Angulos_Rodilla_min	Angulos_Rodilla_max	Angulos_Rodilla_std
116	114.848207	102.284108	104.466599	87.998978	179.922495	28.31216

Figure 47: Excel con las características de los ángulos (solo se ven las de la rodilla).  
Fuente: Elaboración propia.

### ¿Qué pasaría si en vez de querer clasificar todo el vídeo, se quiere clasificar cada sentadilla que se produce en el vídeo?

A la hora de predecir el vídeo nuevo, lo que se tendría que hacer es no sacar las características de los ángulos, si no que, se debería de predecir cada *frame* del vídeo y así, predeciría si está bien o mal cada movimiento en el vídeo. Luego habría que hacer un estudio para ver qué *frames* corresponden a una sentadilla.

#### 5.1.2. Caso clasificado como “bien”

Utilizando el modelo de regresión logística previamente entrenado, se realiza la clasificación del ejercicio y se obtiene una predicción de "bien".

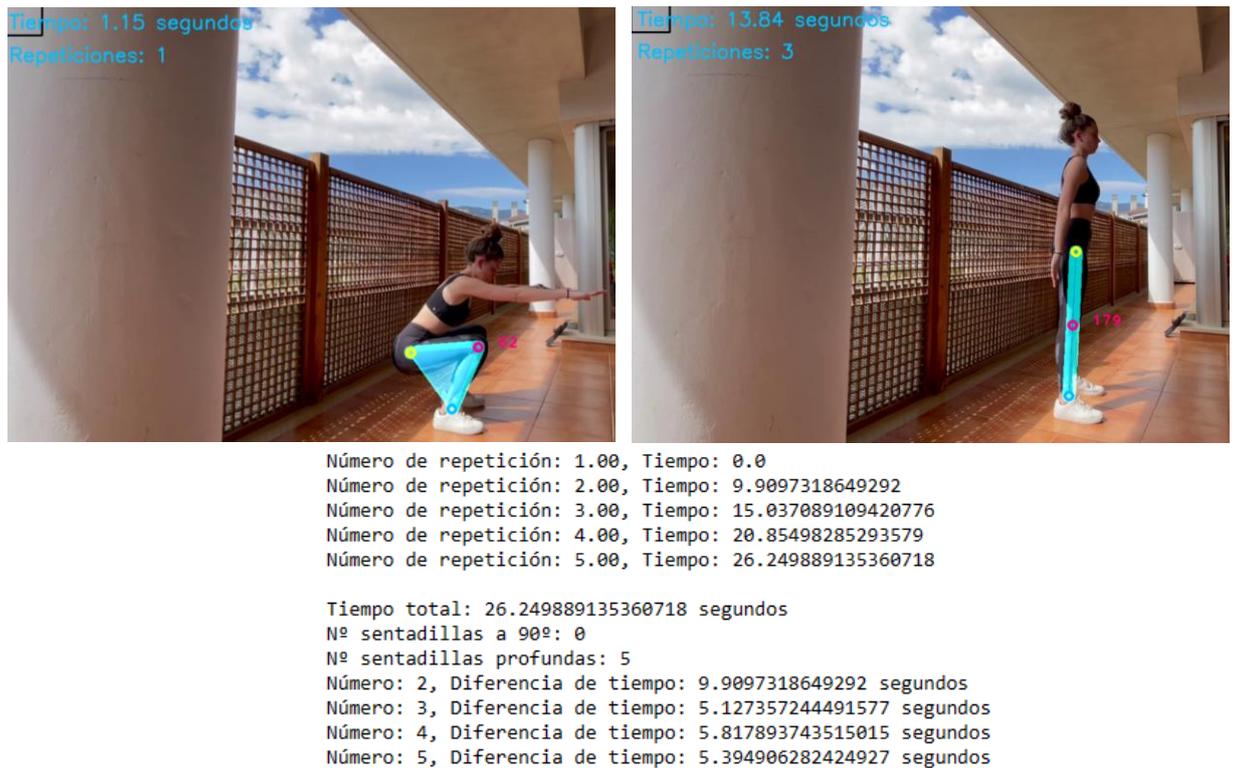
Como resultado de esta clasificación exitosa, se realizan las siguientes acciones:

1. Visualización del ángulo de la rodilla: Dado que el ángulo de la rodilla se identifica como el más significativo en este ejercicio, se muestra en el vídeo el valor de dicho ángulo en cada fotograma, lo que permitirá evaluar la adecuada flexión y extensión de la rodilla durante el ejercicio.
2. Registro del número de repeticiones: Se contabiliza el número de repeticiones completadas en el vídeo, lo cual proporciona una métrica cuantitativa del rendimiento. Cada vez que se detecta una repetición completa del ejercicio, se incrementa el contador en una unidad. Cuando el ángulo de la rodilla baja desde casi 180 grados hasta 90 grados y luego vuelve a

subir, se incrementa el contador en una unidad. De esta manera, se puede cuantificar y rastrear el número de repeticiones realizadas durante el ejercicio.

3. Medición del tiempo por repetición: Se calcula el tiempo que lleva completar cada repetición del ejercicio. Se registra el tiempo transcurrido en segundos desde el inicio hasta la finalización de cada repetición, lo que brinda información sobre la velocidad y el ritmo del movimiento.
4. Identificación del tipo de sentadilla: Se determina si el tipo de sentadilla realizada es normal (alcanzando un ángulo de 90° con las rodillas) o profunda (descendiendo por debajo de los 90°). Esto permite evaluar la amplitud y la profundidad del ejercicio, brindando información adicional sobre la técnica utilizada.

Todo esto se puede ver en la *Figure 46*:



*Figure 48: Ejemplo de superposición visual cuando se clasifica como "bien".  
Fuente: Elaboración propia.*

En resumen, el vídeo clasificado como "bien" es procesado para proporcionar información detallada sobre el ángulo de la rodilla, el número de repeticiones, el tiempo por repetición y el tipo de sentadilla realizado. Estos datos serán valiosos para evaluar el rendimiento, analizar la técnica utilizada y realizar ajustes con el objetivo de mejorar el rendimiento deportivo.

### 5.1.3. Caso clasificado como "mal"

Tras aplicar el modelo al nuevo vídeo, se obtiene una predicción de "mal" en la clasificación del ejercicio. Para identificar las áreas de mejora, se compararon las características significativas extraídas del nuevo vídeo con el análisis previo realizado en los ejercicios bien realizados.

Mediante esta comparación, es posible identificar las discrepancias y determinar las características que requieren mejoras para alcanzar un rendimiento adecuado en el ejercicio, Esta comparación permite establecer una referencia entre las características de los ejercicios bien realizados y las del vídeo clasificado como “mal”, brindando una guía para enfocar los aspectos que deben ser corregidos.

El análisis realizado, se va a centrar únicamente en las medias de los ángulos del vídeo nuevo clasificado como “mal” y las medias de los vídeos bien clasificados. Se ha considerado que la media es una medida estadística adecuada para evaluar el rendimiento promedio de los ángulos en ambos grupos de vídeos. Este enfoque permite evaluar el comportamiento promedio de los ángulos de cada grupo y proporcionar recomendaciones específicas para mejorar el rendimiento deportivo. No se han tenido en cuenta otras medidas estadísticas como la moda, el máximo, el mínimo, la mediana y la desviación estándar, ya que en este caso se centra solo en las medias para simplificar el análisis y destacar las diferencias.

Al utilizar las medias como punto de referencia, se han identificado discrepancias en los ángulos del vídeo mal clasificado en comparación con los vídeos bien clasificados. Estas diferencias, permiten ofrecer recomendaciones personalizadas para corregir y optimizar la ejecución del ejercicio.

En base a las medias obtenidas, se sugiere prestar especial atención a los siguientes aspectos ya que son consejos para mejorar el rendimiento de la sentadilla a modo general:

- **Ángulo del hombro:** Si la media del ángulo del hombro en el vídeo mal clasificado está por encima de la media de los vídeos bien clasificados se recomienda prestar atención a la posición y alineación del hombro durante el ejercicio. Habría que asegurarse de mantener los hombros en posición adecuada y evitar inclinaciones excesivas o encogimientos innecesarios.  
En caso contrario, se debería fortalecer los músculos del hombro y mejorar la estabilidad, así como, trabajar en ejercicios específicos para fortalecer los músculos deltoides y mantener una buena postura durante la realización del ejercicio.
- **Ángulo de la rodilla:** Si la media del nuevo vídeo está por encima de la media de los vídeos bien clasificados, es recomendable trabajar en la amplitud y profundidad del movimiento de la rodilla para lograr una mayor efectividad del ejercicio.  
De lo contrario, si está por debajo, se debe prestar atención a la técnica y a la alineación de la rodilla durante el ejercicio. Hay que asegurarse de mantener una posición correcta de las rodillas y evitar desviaciones o movimientos inadecuados.
- **Ángulo del codo:** En caso de que la media del vídeo clasificado como “mal” esté por encima, sería importante trabajar la estabilidad y control del codo durante la actividad. Habría que evitar la hipertensión excesiva y asegurarse de mantener una alineación adecuada.  
De no ser así, el consejo es fortalecer los músculos del bíceps y tríceps, y asegurarse de mantener un rango de movimiento completo durante el ejercicio.
- **Ángulo de la cadera:** Siendo la media del nuevo vídeo superior, se recomienda trabajar en la estabilidad y la alineación de la cadera, habría que mantener una buena postura en todo momento y evitar movimientos desequilibrados.  
En caso contrario, se deberían fortalecer los músculos de relacionados con la cadera (glúteos y abductores) para poder realizar de manera correcta la actividad.

En este caso concreto si comparásemos las medias de los vídeos que realizan bien el ejercicio con las medias de este vídeo que está clasificado como mal (*Tabla 1*) se puede observar que, respecto a la rodilla, en el ejercicio clasificado como “mal”, la media del ángulo es más baja que la de los ejercicios realizados correctamente. Esto sugiere que es necesario incrementar la amplitud de la flexión de la rodilla durante el ejercicio para alcanzar la posición óptima. Se recomendaría trabajar en la movilidad y la flexibilidad de la articulación de la rodilla, así como fortalecer los músculos asociados para lograr una mayor flexión. En cuanto a la cadera, vemos también como el ángulo del vídeo nuevo es más bajo que el de los ejercicios bien realizados, esto indica que se requiere una mayor apertura de la cadera durante el ejercicio. Con el codo ocurre al contrario, la media del nuevo vídeo es mayor. Para corregir esto, se recomendaría enfocarse en mantener una posición adecuada del codo, evitando la hiperextensión y asegurando una alineación adecuada durante todo el movimiento. Por último, los hombros también tienen mayor ángulo, por tanto, indica que se está produciendo una elevación excesiva del hombro durante el ejercicio.

En resumen, en este caso, se recomendaría enfocarse en mejorar la flexión de la rodilla, la apertura de cadera, la alineación del codo y la estabilidad del hombro para realizar correctamente el ejercicio y mejorar el rendimiento deportivo. Es importante trabajar en la movilidad, la flexibilidad y la fuerza de las articulaciones y los músculos involucrados para lograr la ejecución adecuada y segura del ejercicio.

Medias ejercicio realizado de forma correcta	Medias del ejercicio clasificado como mal
Rodilla: 124.3	Rodilla: 114.848207
Cadera: 118.6	Cadera: 105.81321
Codo: 128.3	Codo: 143.975823
Hombro: 51.2	Hombro: 72,15059859

*Tabla 1*

## 5.2. Conclusiones personales

Después de llevar a cabo mi TFG sobre la mejora del rendimiento deportivo mediante visión artificial, he llegado a algunas reflexiones significativas.

En primer lugar, he constatado la eficacia y el potencial de la visión artificial en el ámbito del análisis del movimiento y la mejora del rendimiento deportivo. La capacidad de extraer y analizar datos sobre los ángulos y características significativas de las articulaciones a partir de vídeos de entrenamiento ha demostrado ser una herramienta valiosa para evaluar la técnica y proporcionar retroalimentación precisa.

Además, la utilización de modelo de aprendizaje automático ha sido fundamental para la clasificación y predicción de la ejecución de los ejercicios. La normalización de los datos ha mostrado ser una técnica efectiva, lo que destaca la importancia de la preparación y procesamiento adecuado de los datos en el análisis de visión artificial.

En cuanto a las aplicaciones prácticas de este estudio, he llegado a la conclusión de que la retroalimentación en tiempo real y las recomendaciones específicas para corregir la técnica de los ejercicios tiene un gran potencial para optimizar el rendimiento deportivo. Proporcionar información visual a los deportistas, resaltando los ángulos relevantes y registrando métricas



como el número de repeticiones y el tiempo empleado, puede ser muy motivador y contribuir a un entrenamiento más efectivo.

Aunque existen desafíos y áreas de mejora, considero que este campo de estudio tiene un gran alcance para seguir evolucionando y contribuyendo al desarrollo del entrenamiento deportivo en un futuro.

### 5.3. Legado

En la siguiente URL, se encuentra una carpeta en Google Drive que proporciona acceso al código utilizado para obtener los ángulos de los vídeos, así como a la base de datos generada con cada *frame* y a la recopilación de características significativas agrupadas por vídeo. Además, también se encuentra disponible el código de los modelos utilizados en el proceso. Esta carpeta es una valiosa fuente de información para aquellos interesados en comprender en detalle el enfoque utilizado y explorar los aspectos técnicos y metodológicos relacionados con el procesamiento de los vídeos y el análisis de características. Para acceder a la carpeta, simplemente haz clic en la siguiente URL: [https://drive.google.com/drive/folders/1\\_0zim1kI2fwoJQjdJ-6NX\\_CncO560tQ0?usp=sharing](https://drive.google.com/drive/folders/1_0zim1kI2fwoJQjdJ-6NX_CncO560tQ0?usp=sharing)

### 5.4. Trabajos futuros

En cuanto a los trabajos futuros que se podrían realizar en este campo de investigación, hay varias áreas que podrían explorarse y expandirse.

1. Ampliar a ejercicios o actividades más complejas: Se puede considerar la aplicación de este enfoque a ejercicios o actividades más desafiantes y específicas de diferentes disciplinas deportivas. Esto requeriría una colaboración estrecha con profesionales y expertos en cada deporte para definir y establecer los criterios de clasificación de buen y mal movimiento.
2. Análisis en tiempo real mediante cámaras o sensores especiales: En lugar de procesar los vídeos nuevos, se puede explorar la posibilidad de realizar el análisis de movimiento en tiempo real utilizando cámaras o sensores especiales. Esto permitiría obtener retroalimentación instantánea durante la realización del ejercicio, lo cual es especialmente útil en el ámbito del entrenamiento o competición y la corrección de la técnica en tiempo real.
3. Desarrollo de interfaces interactivas y aplicaciones móviles: Una dirección prometedora es la creación de interfaces interactivas y aplicaciones móviles que permitan a los deportistas realizar un seguimiento de su propio rendimiento, recibir retroalimentación personalizada y acceder a programas de entrenamiento específicos. Estas herramientas pueden motivar y ayudar a los deportistas a mejorar su técnica y alcanzar sus objetivos de rendimiento.
4. Análisis de grandes conjuntos de datos: A medida que se recopilen y almacenen más datos de ejercicios y movimiento, será posible realizar análisis a gran escala para identificar patrones y tendencias más amplias. Esto podría llevar a una comprensión más profunda de los factores que influyen en el rendimiento deportivo y permitir la personalización aún más precisa de los programas de entrenamiento.
5. Automatización de un sistema experto basado en conjuntos de reglas, que genere las sugerencias cuando el vídeo está clasificado como “mal”. Este trabajo requeriría la recopilación de datos y conocimiento experto, la representación adecuada de las reglas, la

definición de la lógica de inferencia, la validación y ajuste del sistema, la optimización utilizando técnicas de aprendizaje automático, y finalmente, la integración en un entorno de aplicación real. La colaboración con expertos en el dominio sería fundamental para definir las reglas y evaluar el rendimiento del sistema a lo largo del proceso de desarrollo.

En resumen, los trabajos futuros podrían incluir la expansión a ejercicios más complejos, la integración de tecnologías adicionales, el análisis en tiempo real, el desarrollo de interfaces interactivas y aplicaciones móviles, así como el análisis de grandes conjuntos de datos. Estas direcciones de investigación tienen el potencial de mejorar aún más la precisión y utilidad de la visión artificial en el ámbito del rendimiento deportivo y la mejora del movimiento.

### **5.5. Relación del trabajo desarrollado con los estudios cursados**

Gracias al conocimiento adquirido en las diversas asignaturas del Grado en Ciencia de Datos, he logrado llevar a cabo este trabajo. A continuación, se mencionan aquellas que considero que han tenido mayor relevancia en el desarrollo de esta labor:

- **Fundamentos de programación y programación:** En este trabajo, se ha empleado Python para programar todos los cálculos necesarios para crear la base de datos y los modelos. Sin un sólido conocimiento en programación no habría sido factible llevar a cabo esta tarea.
- **Análisis exploratorio de datos:** Es fundamental comprender los datos disponibles en un proyecto de ciencia de datos para obtener resultados válidos. Esto implica entender la distribución de las muestras y extraer características relevantes de ellas.
- **Evaluación, despliegue y monitorización de modelos, Modelos descriptivos y predictivos I y II y Técnicas escalables en aprendizaje automático:** En este trabajo se ha llevado a cabo la clasificación de características de diferentes vídeos, con el objetivo de clasificar nuevos vídeos. Para ello, se han utilizado modelos de clasificación como SVM, árboles de decisión y regresión logística, los cuales son estudiados en las asignaturas mencionadas.
- **Visualización:** Se ha realizado una visualización de los datos para mejorar el rendimiento. En esta asignatura se abordan aspectos clave de una buena representación visual, los cuales se han tenido en cuenta en este trabajo.
- **Proyecto I, II y II y Gestión de proyectos:** Las asignaturas relacionadas con proyectos han sido de gran apoyo en la realización de este trabajo. Estas asignaturas enseñan, a través de la práctica, cómo llevar a cabo un proyecto sólido en el campo de la ciencia de datos. Se aprende a seguir paso a paso un proyecto de este tipo, lo que permite una buena gestión y la obtención de resultados buenos.

## Referencias

- Alex, G., & Schmidhuber, J. (2005). *Frameworkwise phoneme classification with bidirectional LSTM and other neural network architectures* (Vol. 1). Retrieved from <https://www.sciencedirect.com/science/article/abs/pii/S0893608005001206>
- Arce, J. I. (2019, 07 26). *Health Big Data*. Retrieved from La matriz de confusión y sus métricas: <https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/>
- Barbieri, D., V Chawla, N., Zaccagni, L., & Grgurinovic, T. (2020). *Predicting Cardiovascular Risk in Athletes: Resampling Improves Classification Performance*. Retrieved from [https://www.researchgate.net/publication/345003553\\_Predicting\\_Cardiovascular\\_Risk\\_in\\_Athletes\\_Resampling\\_Improves\\_Classification\\_Performance](https://www.researchgate.net/publication/345003553_Predicting_Cardiovascular_Risk_in_Athletes_Resampling_Improves_Classification_Performance)
- Cao, Z., Simon, T., Wei, S.-E., & Sheikh, Y. (2017). Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields. Retrieved from <https://arxiv.org/pdf/1611.08050.pdf>
- Carreira, J., Agrawal, P., Fragkiadaki, K., & Malik, J. (2016). Human Pose Estimation With Iterative Error Feedback., (pp. 4733-4742). Retrieved from [https://openaccess.thecvf.com/content\\_cvpr\\_2016/html/Carreira\\_Human\\_Pose\\_Estimation\\_CVPR\\_2016\\_paper.html](https://openaccess.thecvf.com/content_cvpr_2016/html/Carreira_Human_Pose_Estimation_CVPR_2016_paper.html)
- EDS Robotics. (2022, 01 31). Retrieved from <https://www.edsrobotics.com/blog/vision-computador-que-es/>
- Everett Rumelhart, D., Hinton, G., & Jay Williams, R. (n.d.). *Learning representations by back-propagating errors* (Vol. 323).
- Gandhi, R. (2018, 06 07). *Medium*. Retrieved from Support Vector Machine — Introduction to Machine Learning Algorithms: <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>
- García, R. G. (2018, 06). RECONOCIMIENTO AUTOMÁTICO DE IDIOMA.
- Google. (n.d.). *MediaPipe*. Retrieved from <https://developers.google.com/mediapipe>
- Greyrat, R. (2022, 07 05). *Barcelona Geeks*. Retrieved from OpenPose: método de estimación de pose humana: <https://barcelonageeks.com/openpose-metodo-de-estimacion-de-la-postura-humana/>
- Gupta, M. (2019). *GeeksforGeeks*. Retrieved from <https://www.geeksforgeeks.org/ml-machine-learning/>
- Gupta, P. (2017, 05 17). *Medium*. Retrieved from Decision Trees in Machine Learning: <https://towardsdatascience.com/decision-trees-in-machine-learning-641b9c4e8052>

- Haykin, S. (2009). *Neural Networks and Learning Machines* (Third ed.). Pearson. Retrieved from <https://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>
- Hidalgo, G., Cao, Z., Simon, T., Wei, S.-E., Raaj, Y., Joo, H., & Sheikh, Y. (n.d.). *GitHub*. Retrieved from <https://github.com/CMU-Perceptual-Computing-Lab/openpose>
- Hochreiter, S., & Schmidhuber, J. (1997). *Long short-term memory* (Vol. 9). Retrieved from [https://www.researchgate.net/publication/13853244\\_Long\\_Short-term\\_Memory](https://www.researchgate.net/publication/13853244_Long_Short-term_Memory)
- IBM. (n.d.). Retrieved from <https://www.ibm.com/es-es/topics/computer-vision>
- iStock. (n.d.). Retrieved from <https://www.istockphoto.com/es>
- Keshari, K. (2023, 06 01). *Edureka*. Retrieved from Top 10 Applications of Machine Learning: Machine Learning Applications in Daily Life: <https://www.edureka.co/blog/machine-learning-applications/>
- Kocabas, M. (2019, 03). *ResearchGate*. Retrieved from [https://www.researchgate.net/figure/Qualitative-results-on-H36M-dataset-Provided-3D-poses-are-from-different-camera-views\\_fig4\\_331561896](https://www.researchgate.net/figure/Qualitative-results-on-H36M-dataset-Provided-3D-poses-are-from-different-camera-views_fig4_331561896)
- Kumar, A. (2020, 11 07). *Medium*. Retrieved from A Complete Guide to Choose the Correct Cross Validation Technique: <https://medium.com/analytics-vidhya/a-complete-guide-to-choose-the-correct-cross-validation-technique-d70810a02f27>
- MLMath. (2019, 02 13). *Medium*. Retrieved from Math behind SVM(Support Vector Machine): <https://ankitnitjsr13.medium.com/math-behind-svm-support-vector-machine-864e58977fdb>
- Moon, G., Yong Chang, J., & Mu Lee, K. (2019). PoseFix: Model-agnostic general human pose refinement network., (pp. 9307-9316). Retrieved from [https://openaccess.thecvf.com/content\\_CVPR\\_2019/html/Moon\\_PoseFix\\_Model-Agnostic\\_General\\_Human\\_Pose\\_Refinement\\_Network\\_CVPR\\_2019\\_paper.html](https://openaccess.thecvf.com/content_CVPR_2019/html/Moon_PoseFix_Model-Agnostic_General_Human_Pose_Refinement_Network_CVPR_2019_paper.html)
- Noticias Parlamento Europeo*. (2021, 03 26). Retrieved from ¿Qué es la inteligencia artificial y cómo se usa?: [https://www.europarl.europa.eu/news/es/headlines/society/20200827STO85804/que-es-la-inteligencia-artificial-y-como-se-usa?at\\_campaign=20234-Digital&at\\_medium=Google\\_Ads&at\\_platform=Search&at\\_creation=DSA&at\\_goal=TR\\_G&at\\_audience=&at\\_topic=Artificial\\_Intel](https://www.europarl.europa.eu/news/es/headlines/society/20200827STO85804/que-es-la-inteligencia-artificial-y-como-se-usa?at_campaign=20234-Digital&at_medium=Google_Ads&at_platform=Search&at_creation=DSA&at_goal=TR_G&at_audience=&at_topic=Artificial_Intel)
- Oinkina. (2015, 08 31). *El blog de Colah*. Retrieved from Cálculo en grafos computacionales: retropropagación: <http://colah.github.io/posts/2015-08-Backprop/>
- Olgac, U. V., & Karlik, B. (2011). *Performance analysis of various activation functions in generalized MLP architectures of neural networks* (Vol. 1). Retrieved from

- [https://www.researchgate.net/publication/228813985\\_Performance\\_Analysis\\_of\\_Various\\_Activation\\_Functions\\_in\\_Generalized\\_MLP\\_Architectures\\_of\\_Neural\\_Networks](https://www.researchgate.net/publication/228813985_Performance_Analysis_of_Various_Activation_Functions_in_Generalized_MLP_Architectures_of_Neural_Networks)
- Omes. (2021, 06 30). Retrieved from Estimación de Postura ? | Python – MediaPipe – OpenCV: <https://omes-va.com/estimacion-postura-mediapipe-python/>
- Pascanu, R., Mikolov, T., & Bengio, Y. (2013). *On the difficult of training recurrent neural networks*. Retrieved from <https://arxiv.org/abs/1211.5063>
- Pulipaka, D. G. (2016, 06 06). *Medium*. Retrieved from An essential guide to classification and regression trees in R Language: [https://medium.com/@gp\\_pulipaka/an-essential-guide-to-classification-and-regression-trees-in-r-language-4ced657d176b](https://medium.com/@gp_pulipaka/an-essential-guide-to-classification-and-regression-trees-in-r-language-4ced657d176b)
- Rodrigo, J. A. (2020, 10). *Ciencia de datos*. Retrieved from Random Forest con Python: [https://www.cienciadedatos.net/documentos/py08\\_random\\_forest\\_python](https://www.cienciadedatos.net/documentos/py08_random_forest_python)
- Rovai, M. (2020, 08 03). *Medium*. Retrieved from Realtime Multiple Person 2D Pose Estimation using TensorFlow2.x: <https://towardsdatascience.com/realtime-multiple-person-2d-pose-estimation-using-tensorflow2-x-93e4c156d45f>
- Scikit Learn*. (n.d.). Retrieved from Cross-validation: evaluating estimator performance: [https://scikit-learn.org/stable/modules/cross\\_validation.html](https://scikit-learn.org/stable/modules/cross_validation.html)
- Sundermeyer, M., Schlüter, R., & Ney, H. (2012). *Lstm neural networks for language modeling*. doi:10.21437/Interspeech.2012-65
- Thorn, J. (2020, 03 08). *Medium*. Retrieved from Decision Trees Explained: <https://towardsdatascience.com/decision-trees-explained-3ec41632ceb6>
- Tim Jones, M. (2017). *Deep learning architectures*. Retrieved from <https://www.ibm.com/developerworks/library/cc-machine-learning-deeplearning-architectures/index.html>
- Videvo*. (n.d.). Retrieved from <https://www.videvo.net/es/>
- Xenopoulos, P. (2017, 05 17). *Medium*. Retrieved from Why is machine learning happening now?: <https://medium.com/@peterx/machine-learning-why-is-everyone-doing-it-now-98boae6e3fc>
- Xu, Y. (2021). *A Sports Training Video Classification Model Based on Deep Learning*. Retrieved from [https://www.researchgate.net/publication/351997184\\_A\\_Sports\\_Training\\_Video\\_Classification\\_Model\\_Based\\_on\\_Deep\\_Learning](https://www.researchgate.net/publication/351997184_A_Sports_Training_Video_Classification_Model_Based_on_Deep_Learning)
- Zephyrnet*. (2023, 01). Retrieved from <https://www.zephyrnet.com/es/una-gu%C3%ADa-completa-sobre-la-estimaci%C3%B3n-de-la-pose-humana/>

## Anexo I: Objetivos de desarrollo sostenible

Grado de relación del trabajo con los Objetivos de Desarrollo Sostenible (ODS).

<b>Objetivos de Desarrollo Sostenibles</b>	<b>Alto</b>	<b>Medio</b>	<b>Bajo</b>	<b>No Procede</b>
ODS 1. <b>Fin de la pobreza.</b>				<b>X</b>
ODS 2. <b>Hambre cero.</b>				<b>X</b>
ODS 3. <b>Salud y bienestar.</b>	<b>X</b>			
ODS 4. <b>Educación de calidad.</b>				<b>X</b>
ODS 5. <b>Igualdad de género.</b>				<b>X</b>
ODS 6. <b>Agua limpia y saneamiento.</b>				<b>X</b>
ODS 7. <b>Energía asequible y no contaminante.</b>				<b>X</b>
ODS 8. <b>Trabajo decente y crecimiento económico.</b>				<b>X</b>
ODS 9. <b>Industria, innovación e infraestructuras.</b>				<b>X</b>
ODS 10. <b>Reducción de las desigualdades.</b>				<b>X</b>
ODS 11. <b>Ciudades y comunidades sostenibles.</b>				<b>X</b>
ODS 12. <b>Producción y consumo responsables.</b>				<b>X</b>
ODS 13. <b>Acción por el clima.</b>				<b>X</b>
ODS 14. <b>Vida submarina.</b>				<b>X</b>
ODS 15. <b>Vida de ecosistemas terrestres.</b>				<b>X</b>
ODS 16. <b>Paz, justicia e instituciones sólidas.</b>				<b>X</b>
ODS 17. <b>Alianzas para lograr objetivos.</b>				<b>X</b>

### **Consideración de los ODS y aquellos con los que el TFG está más conectados.**

La Organización de las Naciones Unidas aprobó la Agenda 2030 para el Desarrollo Sostenible en 2015, brindando a las naciones y sus sociedades la oportunidad de avanzar en un nuevo camino para mejorar la vida de todos sin dejar a nadie atrás. Con el fin de promover el crecimiento, la Agenda identifica un total de 17 Objetivos de Desarrollo Sostenible (ODS) destinados a proteger el medio ambiente, promover la justicia social y fomentar el crecimiento económico.

Este Trabajo Final de Grado tiene el potencial de ayudar a alcanzar un ODS. Sobre todo el objetivo de salud y bienestar.

Está altamente relacionado ya que el uso de la visión artificial en el ámbito deportivo puede contribuir a promover la salud de los deportistas. Al utilizar tecnologías de análisis visual, es posible monitorear el rendimiento físico y detectar posibles lesiones o condiciones de salud que podrían afectar a los atletas. Esto permite una intervención temprana y un cuidado personalizado, promoviendo la salud y previniendo problemas más graves.

También hace que haya prevención de lesiones. La visión artificial puede desempeñar un papel crucial en la prevención de lesiones deportivas. Mediante el seguimiento y análisis de movimientos, se pueden identificar patrones de movimiento incorrectos o desequilibrados que podrían aumentar el riesgo de lesiones. Al detectar estas anomalías, los entrenadores y especialistas en medicina deportiva pueden intervenir y proporcionar recomendaciones para corregir y mejorar la técnica, reduciendo así el riesgo de lesiones.

Por otra parte, está la optimización del rendimiento. La visión artificial puede ayudar a los deportistas a mejorar su rendimiento y alcanzar su máximo potencial. A través del análisis de datos visuales, se pueden obtener métricas precisas sobre la velocidad, la técnica, la potencia y otros aspectos del rendimiento deportivo. Estas métricas pueden utilizarse para identificar áreas de mejora, establecer objetivos específicos y personalizar programas de entrenamiento. Al optimizar el rendimiento deportivo, se fomenta el bienestar físico y mental de los atletas.

Por último, está el acceso equitativo a la atención médica deportiva. La visión artificial también puede contribuir a promover la equidad en la atención médica deportiva. Al utilizar tecnologías accesibles y asequibles, se puede brindar a un mayor número de deportistas la oportunidad de beneficiarse de la detección temprana de lesiones, la optimización del rendimiento y la promoción de la salud. Esto es especialmente relevante en comunidades con recursos limitados, donde el acceso a servicios médicos especializados puede ser limitado.

En resumen, la utilización de la visión artificial en la mejora del rendimiento deportivo está estrechamente relacionada con el ODS 3: Salud y Bienestar. Al promover la salud, prevenir lesiones, optimizar el rendimiento y garantizar un acceso equitativo a la atención médica deportiva, se contribuye al bienestar físico y mental de los deportistas, al mismo tiempo que se fomenta la práctica deportiva inclusiva y sostenible.

## Anexo 2: Gráficos de los modelos

### Árbol de decisión

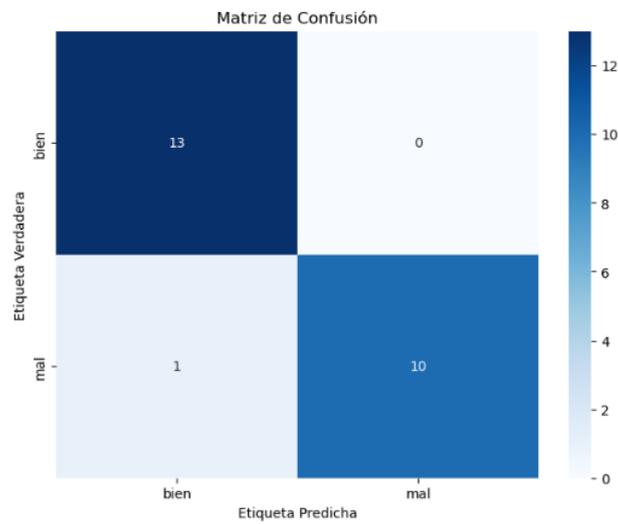


Figure 49: Matriz de confusión Modelo 1 árbol de decisión sin normalizar. Fuente: Elaboración propia.

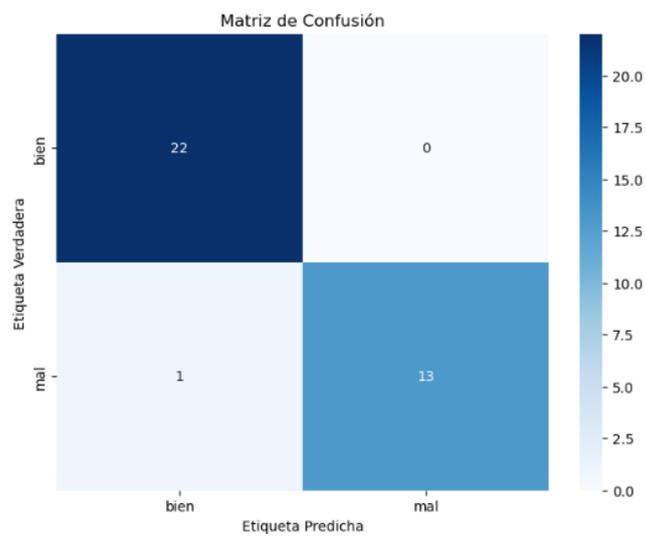


Figure 50: Matriz de confusión Modelo 1 árbol de decisión con normalización. Fuente: Elaboración propia.

# Mejora del rendimiento deportivo mediante visión artificial

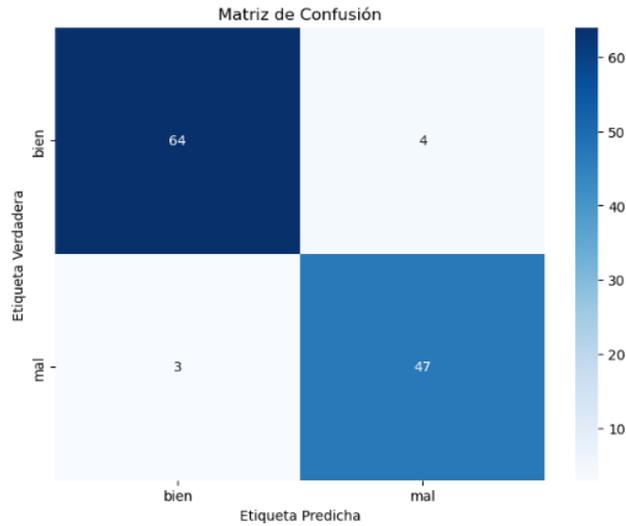


Figure 51: Matriz de confusión Modelo 2 árbol de decisión sin normalizar. Fuente: Elaboración propia.

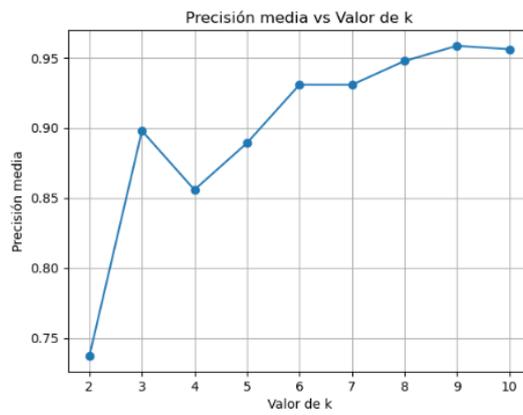


Figure 52: Gráfico precisión media VS valor de k Modelo 2 árbol de decisión sin normalizar. Fuente: Elaboración propia.

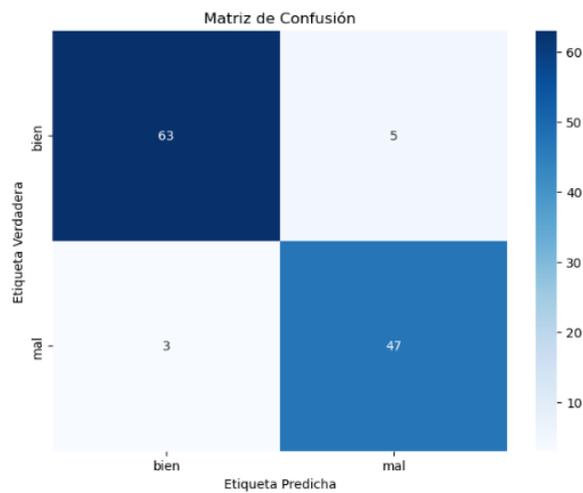


Figure 53: Matriz de confusión Modelo 2 árbol de decisión con normalización. Fuente: Elaboración propia.

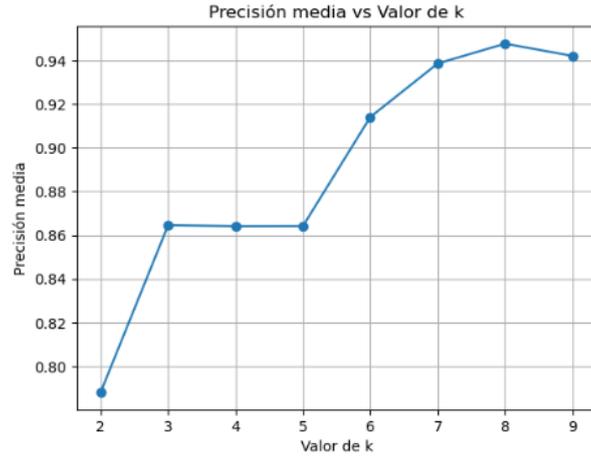


Figure 54: Gráfico precisión media VS valor de k Modelo 2 árbol de decisión con normalización. Fuente: Elaboración propia.

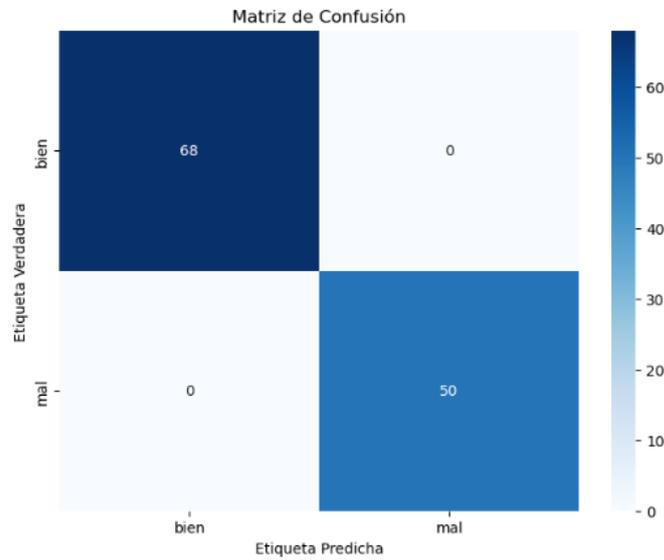


Figure 55: Matriz de confusión Modelo 3 árbol de decisión sin normalización. Fuente: Elaboración propia.



## Mejora del rendimiento deportivo mediante visión artificial

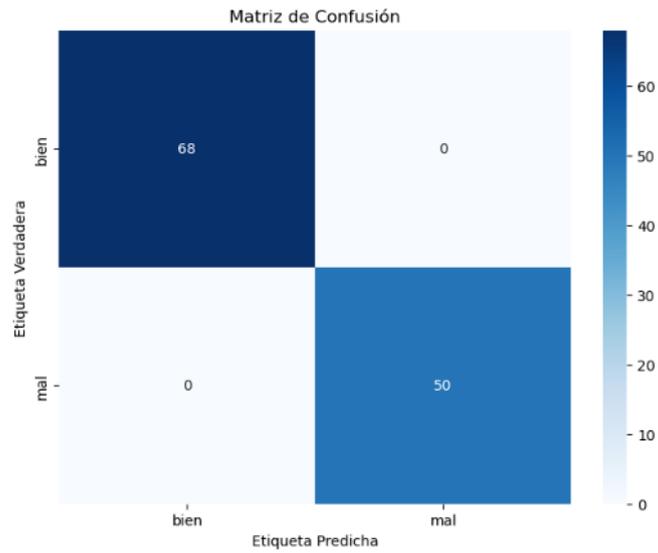


Figure 56: Matriz de confusión Modelo 3 árbol de decisión con normalización. Fuente: Elaboración propia.

### Regresión logística

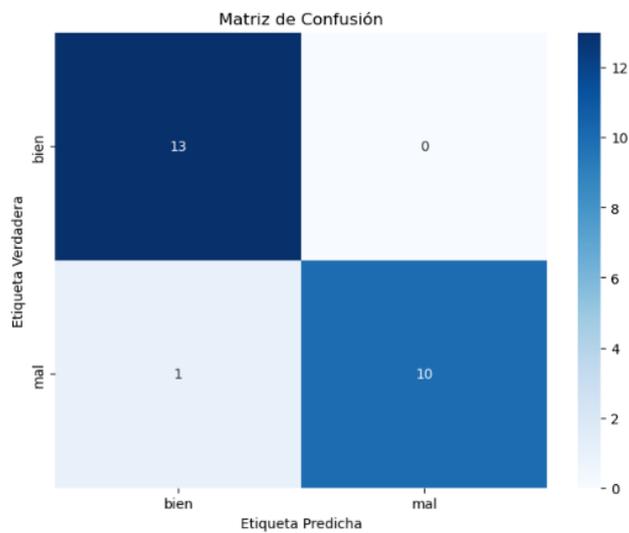


Figure 57: Matriz de confusión Modelo 1 regresión logística sin normalización. Fuente: Elaboración propia.

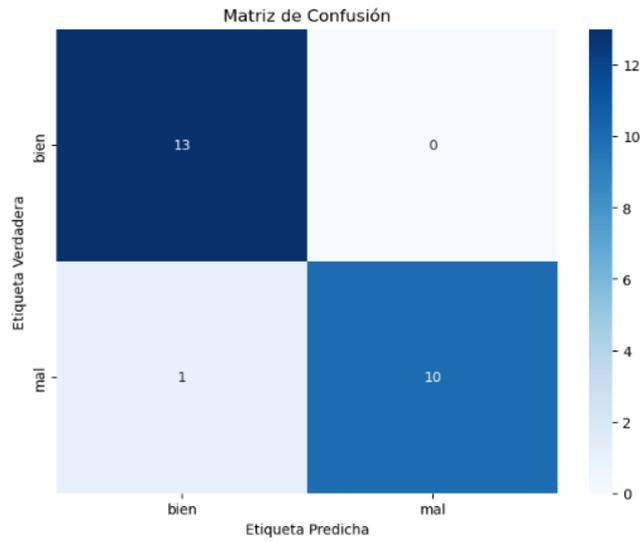


Figure 58: Matriz de confusión Modelo 1 regresión logística con normalización. Fuente: Elaboración propia.

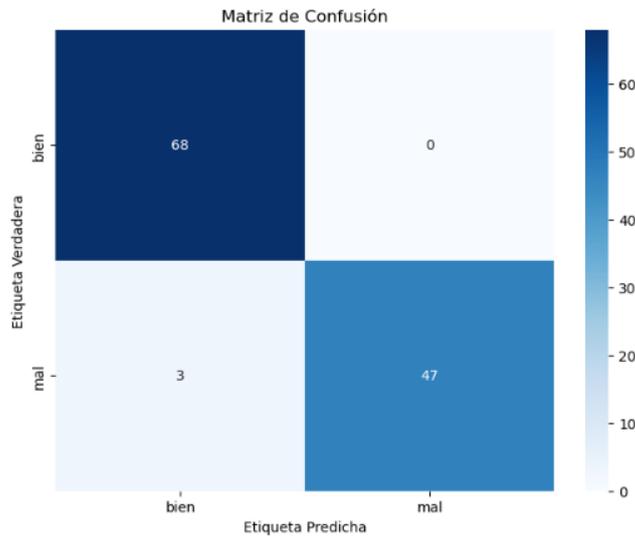


Figure 59: Matriz de confusión Modelo 2 regresión logística sin normalización. Fuente: Elaboración propia.

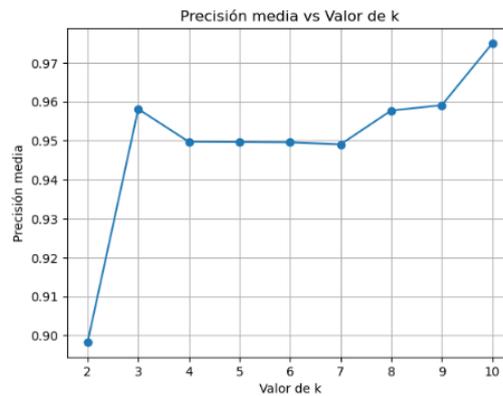


Figure 60: Precisión media VS valor de k Modelo 2 regresión logística. Fuente: Elaboración propia.

## Mejora del rendimiento deportivo mediante visión artificial

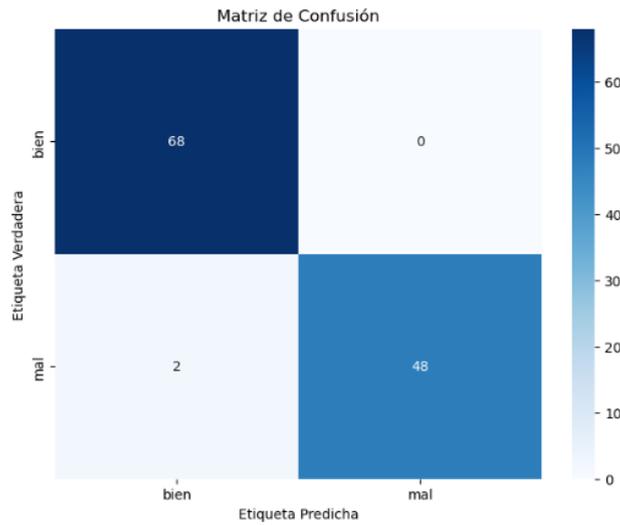


Figure 61: Matriz de confusión Modelo 2 regresión logística con normalización. Fuente: Elaboración propia.

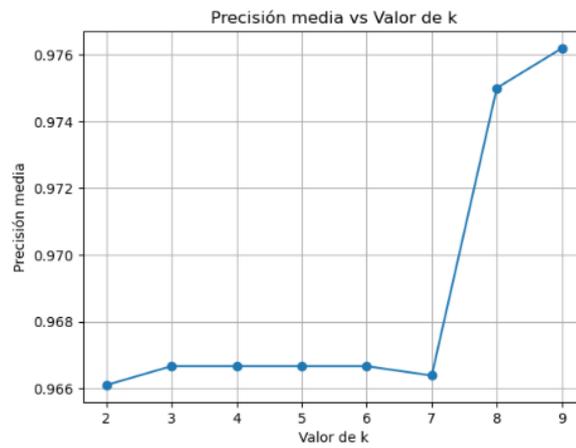


Figure 62: Precisión media VS valor de k Modelo 2 regresión logística. Fuente: Elaboración propia.

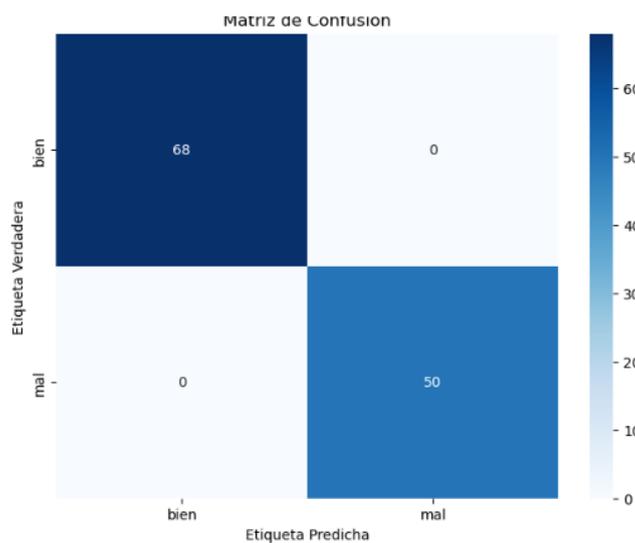


Figure 63: Matriz de confusión Modelo 3 regresión logística sin normalización. Fuente: Elaboración propia.

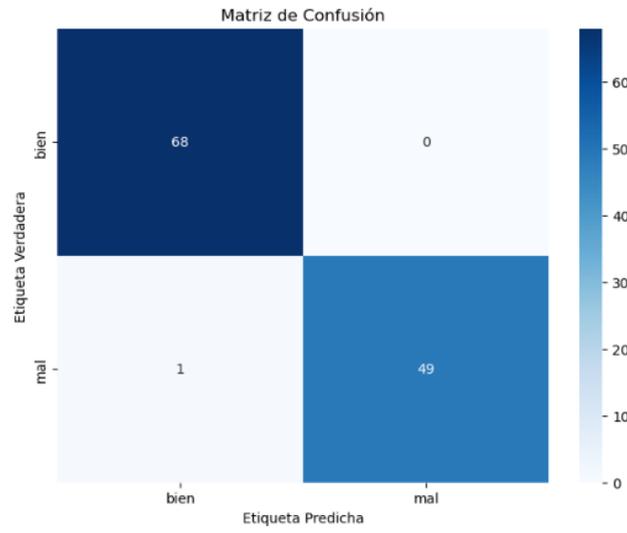


Figure 64: Matriz de confusión Modelo 3 regresión logística con normalización. Fuente: Elaboración propia.