Pontificia Universidad
JAVERIANA
Cali

CLASIFICACIÓN DE DATOS MOCAP SOBRE UNA DISCIPLINA DEPORTIVA USANDO MODELOS DE MACHINE LEARNING

Mario Fernando García Moncayo

código 8984973

Proyecto Aplicado para optar al título de

Magister en Ciencia de Datos

Director

Cristhian Kaori Valencia Marín

FACULTAD DE INGENIERÍA Y CIENCIAS

MAESTRÍA EN CIENCIA DE DATOS

PASTO, OCTUBRE 14 DE 2024

Contenido

INTRODUCCIÓN 6
1. DEFINICIÓN DEL PROBLEMA 7
1.1 PLANTEAMIENTO DEL PROBLEMA 7
1.2 FORMULACIÓN DEL PROBLEMA 8
2. OBJETIVOS DEL PROYECTO 10
2.1 OBJETIVO GENERAL 10
2.2 OBJETIVOS ESPECÍFICOS 10
3. MARCO DE REFERENCIA 11
3.1. MARCO TEÓRICO 11
3.1.1 Introducción a la Ciencia de Datos y su Impacto en el Deporte 11
3.1.2 Biomecánica Deportiva 12
3.1.3 Tecnología de Captura de Movimiento (MOCAP) 13
3.1.4 Reconocimiento de Actividades Humanas (HAR) 13
3.1.5 Inteligencia Artificial. 14
3.1.6 Machine Learning en la Clasificación de Datos MOCAP 15
3.1.7 Tecnologías para Datos MOCAP 19
3.1.8 Lenguajes de programación 20
3.2. ANTECEDENTES 20
4. PREPROCESAMIENTO DE LOS DATOS 23
4.1 Descripción datos: 24
4.2 Transformación datos: 28
4.3 Limpieza de datos: 32
4.4 Preparación datos: 32
4.5 Visualización datos: 35
5. CLASIFICACION MOCAP 37
5.1 NORMALIZACIÓN. 38
5.2 CLÚSTER. 40
5.3 Matriz de disimilitudes: 44
5.4 TSNE 46
5.6 Selección del Modelo 48
5.6.1 Support Vector Machines (SVM). 49
5.6.2 Random Forest. 50

5.6.3 K-Nearest Neighbors (KNN). 51
5.6.4 Redes Neuronales. 53
6. VALIDACIÓN Y ENTRENAMIENTO 55
6.2 Entrenamiento del Modelo. 55
6.3 Resultados de los Modelos. 57
6.4 Optimización del Modelo. 61
6.6 Validación del Modelo. 61
7. CONCLUSIONES Y TRABAJOS FUTUROS 62
7.1 CONCLUSIONES 62
7.2 TRABAJOS FUTUROS 63
BIBLIOGRAFIA 64

Lista figuras

		Pág.
Figura 1.	Movimientos en el tenis	16
Figura 2.	Etapas de Machine Learning	17
Figura 3.	Posicionamiento de los marcadores	26
Figura 4.	Transformación de los movimientos BVH	30
Figura 5.	Transformación MP	31
Figura 6.	Transformación 3D a 2D	32
Figura 7.	Comparación CHEST	35
Figura 8.	Visualización de categorías de movimiento	36
Figura 9.	Resultado clúster	42
Figura 10.	Visualización PCA	44
Figura 11.	Matriz de disimilitud	46
Figura 12.	Visualización TSNE	48
Figura 13.	Matriz confusión SVM	57
Figura 14.	Matriz confusión Random Forest	58
Figura 15.	Matriz confusión KNN	59
Figura 16.	Matriz confusión Redes Neuronales	60
Figura 17.	Comparación precisión de modelos	17

Lista tablas

		Pág.
Tabla 1.	Datos MOCAP	28
Tabla 2.	JOINT Articulaciones	34

INTRODUCCIÓN

La ciencia de datos y las tecnologías avanzadas de captura de movimiento (MOCAP) han comenzado a transformar el análisis del rendimiento deportivo. Estas herramientas abren nuevas oportunidades para mejorar las técnicas deportivas, prevenir lesiones y personalizar el entrenamiento de los atletas en función de datos específicos de cada movimiento. En los últimos años, el análisis biomecánico apoyado en inteligencia artificial (IA) y Machine Learning ha permitido identificar patrones detallados y relaciones biomecánicas que de otro modo serían difíciles de capturar.[1] esto permite a entrenadores y especialistas en rendimiento físico acceder a un nivel de detalle, facilitando el desarrollo de programas de entrenamiento adaptados a las necesidades de cada atleta.

En el ámbito del tenis, un deporte que exige precisión técnica y control biomecánico en cada movimiento, las tecnologías de MOCAP y Machine Learning permiten realizar un análisis profundo de los gestos técnicos y patrones de movimiento específicos de cada jugador. Los golpes, desplazamientos y posturas requieren una ejecución rigurosa y controlada que, de no realizarse adecuadamente, puede impactar negativamente en el rendimiento o incluso derivar en lesiones. La clasificación de los datos de movimiento corporal en el tenis ofrece una forma objetiva de evaluar la ejecución técnica, y es aquí donde la IA desempeña un papel crucial, permitiendo procesar grandes volúmenes de datos con rapidez y precisión.[2] Este estudio investiga el potencial y los desafíos de utilizar el aprendizaje profundo para clasificar acciones en el tenis, demostrando cómo los avances en IA permiten identificar eventos específicos en videos con mayor precisión, lo que es relevante para analizar movimientos y mejorar la técnica de los jugadores.

Este proyecto se centra en la clasificación de movimientos en jugadores de tenis utilizando datos de captura de movimiento obtenidos previamente en un entorno controlado. La investigación se enfoca en patrones biomecánicos de acciones como el golpe de derecha, el revés y el servicio, gestos esenciales en el tenis que requieren control, precisión y una técnica pulida para su correcta ejecución. Mediante técnicas de Machine Learning, se identifican posiciones clave en estos movimientos, proporcionando un análisis objetivo de la técnica utilizada por cada jugador. A través de esta metodología, el proyecto busca ofrecer información detallada y cuantitativa que contribuya al diseño de entrenamientos personalizados y a la mejora en categorías de movimiento. Este enfoque es especialmente relevante para los jugadores de la liga de tenis de Caldas, quienes pueden beneficiarse de un análisis biomecánico profundo, permitiéndoles perfeccionar sus habilidades y minimizar el riesgo de lesiones.

Este análisis objetivo y avanzado permite a entrenadores y deportistas no solo corregir la técnica, sino también ajustar los entrenamientos en función de los datos obtenidos, contribuyendo a un desarrollo deportivo más saludable y efectivo. En resumen, el proyecto combina el poder de la ciencia de datos y las técnicas de Machine Learning para ofrecer una herramienta avanzada de análisis en el tenis.

1. DEFINICIÓN DEL PROBLEMA

El procesamiento de datos MOCAP en conjunto con los modelos basados en ciencia de datos permiten captar y analizar patrones biomecánicos de los deportistas con base a las categorías de movimiento, estas técnicas son un importante insumo para procesos relacionados con la rehabilitación y retroalimentación de los deportistas.[3]

Si entendemos la biomecánica como un área que facilita el estudio de variables corporales involucradas en los seres humanos, entonces este proceso puede ser abordado a partir de la ciencia de datos, pues las técnicas sofisticadas de captura permiten adquirir movimiento y almacenarlo en forma digital para su posterior análisis. Estos datos (MOCAP) se representan por medio de series temporales permitiendo codificar las dependencias intrínsecas (incluso relaciones no lineales) entre el cuerpo humano y sus articulaciones.

Hablar de reconocer las actividades adentradas en el análisis de patrones biomecánicos como resistencia, saque, revés, volea, y otras tareas del tenis, involucra una captura de movimiento en tiempo real, lo cual ayuda en la toma de decisiones frente a las potencialidades observadas en los deportistas propios de esta disciplina.[4]

Se menciona un conjunto disperso de tecnologías necesarias para conseguir sus planteamientos. La biomecánica, la captura de movimiento, el Big Data, la inteligencia artificial, los procesos de automatización entre otros son la base fundamental para interpretar, analizar, y resolver ecuaciones de tiempo, por eso todas esas ciencias llevan a clasificar datos MOCAP con base en categorías de movimiento lo cual implica que el ejecutar esa tendencia genera una buena o mala técnica de desempeño por parte del deportista, dicha ejecución pueda causar problemas futuros de salud. Todas estas características serán importantes para que el cuerpo técnico defina los aspectos a mejorar y tratar frente a esa persona.

1.1 PLANTEAMIENTO DEL PROBLEMA

En el tenis, la técnica y la biomecánica juegan un papel fundamental en el rendimiento de los atletas. Cada golpe, postura y desplazamiento en la cancha requiere un control preciso y una ejecución adecuada para maximizar la eficacia del movimiento y minimizar el riesgo de lesiones. Dada la importancia de la biomecánica en este deporte, se hace necesario contar con métodos avanzados que permitan analizar detalladamente los gestos técnicos y patrones de movimiento específicos de cada jugador.

Movimientos como el golpe de derecha, el revés y el servicio requieren una alineación exacta del cuerpo y un manejo adecuado de las articulaciones y músculos implicados. La clasificación de estos movimientos es esencial para comprender cómo cada jugador ejecuta su técnica y cuáles son las posibles áreas de mejora.

Sin embargo, realizar una clasificación precisa y en tiempo real de estos movimientos sigue siendo un reto significativo, ya que implica la necesidad de procesar y analizar grandes volúmenes de datos complejos. La captura de movimiento (MOCAP) y los modelos de Machine Learning ofrecen una solución prometedora a este desafío, permitiendo descomponer y clasificar los gestos en tiempo real con un nivel de precisión que no sería posible de manera manual.[5] Aun así, la aplicación de estos métodos al análisis biomecánico en deportes como el tenis es un campo en desarrollo, y existen limitaciones inherentes a la precisión de los sistemas, la calidad de los datos y la interpretación técnica de los resultados obtenidos.

Este proyecto se propone responder a la necesidad de un sistema que permita identificar y clasificar posiciones específicas en el tenis mediante modelos de Machine Learning aplicados a datos de captura de movimiento. No obstante, el alcance del proyecto está claramente delimitado: **su objetivo no es evaluar el rendimiento del jugador ni calificar la calidad de la ejecución**. En lugar de ello, se centra en clasificar y analizar técnicamente los movimientos en función de patrones biomecánicos, sin emitir juicios sobre la correcta o incorrecta ejecución de cada gesto.[6] De este modo, el sistema proporciona información detallada sobre la posición y el movimiento, lo cual puede ser valioso tanto para entrenadores como para jugadores en la toma de decisiones y el ajuste de técnicas específicas.

Este proyecto busca aportar una herramienta que apoye el entrenamiento en el tenis a través de un análisis técnico basado en datos de MOCAP, facilitando la identificación de patrones biomecánicos clave. La precisión en esta clasificación tiene el potencial de proporcionar un recurso objetivo para entrenadores y atletas, permitiéndoles optimizar la técnica en base a datos cuantitativos sin extenderse a evaluaciones de calidad de ejecución.

Al enfocarse exclusivamente en la clasificación técnica de posiciones, el proyecto establece un punto de partida sobre el cual pueden desarrollarse futuras investigaciones orientadas a la evaluación de rendimiento o calidad en el movimiento deportivo.

1.2 FORMULACIÓN DEL PROBLEMA

¿Como Implementar una estrategia para clasificar datos MOCAP sobre una disciplina deportiva usando modelos de Machine Learning?

Preguntas de sistematización:

¿Cuál es la importancia de realizar un análisis exploratorio de los datos MOCAP que permita procesar, acondicionar y visualizar dichos datos de una disciplina deportiva específica?

¿Cuáles son los modelos de Machine Learning y cuáles son los principales desafíos y limitaciones en la aplicación de estos para la clasificación de datos MOCAP?

¿Cómo se evaluará la precisión y eficacia de los modelos propuestos para la clasificación de datos MOCAP?

2. OBJETIVOS DEL PROYECTO

2.1 OBJETIVO GENERAL

Implementar una estrategia para clasificar datos MOCAP sobre una disciplina deportiva usando modelos de Machine Learning

2.2 OBJETIVOS ESPECÍFICOS

1. Desarrollar un módulo para el procesamiento y acondicionamiento de datos MOCAP utilizando herramientas basadas en ciencia de datos, que a su vez permita la representación y la visualización adecuada de los movimientos.

2. Implementar un modelo utilizando técnicas basadas en Machine Learning y reconocimiento de patrones para la clasificación de datos MOCAP propios de la disciplina deportiva.

3. Implementar una estrategia para la validación del modelo desarrollado utilizando base de datos MOCAP disponibles asociadas a la ejecución de movimientos específicos en el deporte, teniendo en cuenta las medidas de desempeño más comunes en el estado del arte.

3. MARCO DE REFERENCIA

3.1. MARCO TEÓRICO

3.1.1 Introducción a la Ciencia de Datos y su Impacto en el Deporte

La ciencia de datos se ha consolidado como una herramienta esencial para transformar el análisis deportivo, permitiendo estudiar patrones biomecánicos y de rendimiento con una precisión sin precedentes. En deportes como el tenis, donde la técnica y la biomecánica son críticas para el éxito, los enfoques basados en datos han revolucionado la manera en que se evalúan y optimizan las habilidades de los atletas.

La ciencia de datos se ha convertido en un pilar fundamental para el crecimiento y transformación digital de las organizaciones en todos los sectores. El uso eficiente de los datos permite no solo la optimización de procesos, sino también la generación de nuevas oportunidades de negocio, mejorando la toma de decisiones a partir de análisis predictivos y prescriptivos. En las últimas décadas, hemos presenciado un cambio radical impulsado por la llamada Revolución Industrial 4.0 [7]. En la que la integración de tecnologías avanzadas como el Big Data [8], y el Internet de las Cosas (IOT) [9] han habilitado la automatización y optimización de procesos empresariales y productivos.

En este contexto, la ciencia de datos actúa como una disciplina que integra la estadística, el análisis de datos y el aprendizaje automático, para extraer conocimiento y valor a partir de grandes volúmenes de información. Las organizaciones modernas, tanto gubernamentales como privadas y sin ánimo de lucro, se han visto obligadas a adaptarse rápidamente a este paradigma, invirtiendo en infraestructura y en talento especializado para aprovechar el potencial que ofrece el análisis de datos. Los datos ya no se perciben como un subproducto de las operaciones empresariales, sino como un recurso estratégico que, si se explota adecuadamente, puede generar una ventaja competitiva sostenible.

Uno de los principales impactos de la ciencia de datos en las organizaciones es la capacidad para transformar los procesos de toma de decisiones. Tradicionalmente, las decisiones en las empresas se basaban en la experiencia de los gestores o en análisis descriptivos que miraban al pasado. Sin embargo, el uso de modelos predictivos y algoritmos de aprendizaje automático permite a las organizaciones anticiparse a eventos futuros, predecir comportamientos y optimizar operaciones. Este enfoque ha sido ampliamente adoptado en sectores como el manufacturero y el financiero, donde el análisis de grandes volúmenes de datos ha permitido desde la optimización de cadenas de suministro hasta la detección de fraudes en tiempo real.[10]

Sin embargo, un sector donde la ciencia de datos está comenzando a generar un impacto transformador es el deporte. El uso de la captura de movimiento (MOCAP), en combinación con modelos de Machine Learning, ha abierto nuevas oportunidades para el análisis del rendimiento deportivo, la prevención de lesiones y la personalización de los entrenamientos. En el ámbito deportivo, los datos MOCAP permiten capturar con alta precisión los movimientos de los atletas, proporcionando información detallada sobre la cinemática de sus gestos técnicos.

3.1.2 Biomecánica Deportiva

Para los seres humanos gran parte de su bienestar debe estar de la mano del deporte pues aparte de ser una disciplina también es una fuente de beneficio individual, por eso si se tiene en cuenta que la Biomecánica Deportiva [11]., pone a disposición de los pacientes una serie de evaluaciones avaladas y respaldadas científicamente, que permiten gestionar el riesgo de sufrir lesiones de acuerdo con el deporte y el nivel físico del atleta.

La Biomecánica Deportiva se basa en una serie de métodos de análisis y evaluaciones avaladas científicamente, que permiten gestionar de manera precisa el riesgo de lesiones. Estas evaluaciones toman en cuenta factores como las características físicas del deportista, su técnica, y las demandas biomecánicas específicas del deporte practicado. En este sentido, es posible desarrollar programas personalizados de corrección y optimización técnica, que no solo mejoran el rendimiento deportivo, sino que también promueven una mayor seguridad durante la práctica, reduciendo la probabilidad de lesiones a corto y largo plazo.

Además, la biomecánica no solo contribuye a mejorar la técnica deportiva, sino que es clave en los procesos de rehabilitación y reintegración tras una lesión. El análisis detallado del movimiento permite determinar si un atleta está en condiciones óptimas para volver a la competición o si requiere ajustes adicionales para minimizar el riesgo de recaídas.[12] En este sentido, la biomecánica deportiva proporciona un enfoque integral que permite al atleta regresar a su actividad con confianza y de manera segura, mejorando no solo su rendimiento físico, sino también su longevidad deportiva.

En conclusión, la Biomecánica Deportiva constituye una herramienta invaluable en el ámbito de la prevención y el tratamiento de lesiones deportivas, así como en la mejora del rendimiento de los atletas. A través de evaluaciones científicas y personalizadas, los deportistas pueden optimizar sus técnicas, garantizar su seguridad durante la actividad física, y gestionar de manera efectiva su retorno a la competición tras una pausa o proceso de rehabilitación.

3.1.3 Tecnología de Captura de Movimiento (MOCAP)

Registrar el movimiento de las personas u objetos se conoce como MOTION CAPTURE. Esta tecnología captura los datos que se transfieren a un programa de ordenador para activar foto realismo en un entorno virtual [13].

Los sistemas de captura de movimiento, por su naturaleza, generan datos que representan medidas físicas del movimiento capturado en tiempo real. Estos sistemas permiten a los investigadores recolectar información detallada sobre los movimientos humanos, incluyendo la velocidad, aceleración, ángulos articulares y fuerzas aplicadas, entre otros. Sin embargo, para obtener valor real de estos datos, es necesario un análisis exhaustivo y sistemático, apoyado en los principios de la ciencia de datos. El uso de técnicas avanzadas de ciencia de datos facilita la transformación de los datos brutos de MOCAP en información valiosa y comprensible para distintos propósitos de investigación y desarrollo.

Un enfoque adecuado en la investigación basada en MOCAP comienza por la identificación de las fuentes de datos, es decir, los dispositivos y sistemas utilizados para la captura de movimiento, como sistemas ópticos [14], los sistemas inerciales [15] o los sistemas electromagnéticos [16]. Estas fuentes proporcionan los dataset iniciales, que luego pasan por un proceso de análisis exploratorio de datos (EDA) [17]. Durante esta fase, es fundamental aplicar técnicas de limpieza de datos, para eliminar cualquier ruido o inconsistencias que puedan comprometer los resultados, y proceder con su normalización para un procesamiento eficiente. Esto permite tener una base de datos más precisa y adecuada para su posterior análisis.

La visualización de datos MOCAP es otra etapa crucial que facilita la interpretación de los patrones de movimiento capturados. Herramientas de visualización avanzadas, como gráficos tridimensionales y animaciones interactivas, permiten a los investigadores observar los movimientos de manera detallada y evaluar la biomecánica involucrada, lo que puede ser especialmente útil en disciplinas como la rehabilitación, el entrenamiento deportivo y el desarrollo de interfaces humano-robot.

Es así como el procesamiento de datos MOCAP permite aplicar modelos predictivos y técnicas de aprendizaje automático para generar perspectivas más profundas. Estos análisis pueden incluir el reconocimiento de patrones en el movimiento, la identificación de anomalías o desviaciones respecto a un estándar, y la optimización de la técnica deportiva o motriz. De esta manera, los datos obtenidos a través de sistemas de MOCAP no solo sirven como una representación física del movimiento, sino que también pueden proporcionar un soporte crucial para el desarrollo de aplicaciones innovadoras en una variedad de campos científicos y tecnológicos.

3.1.4 Reconocimiento de Actividades Humanas (HAR)

El reconocimiento de actividades humanas es un tema de mucha relevancia debido a su amplia gama de aplicaciones. Se han propuesto diferentes enfoques para HAR,

desde la comparación de señales con umbrales hasta la aplicación de técnicas de aprendizaje automático y profundo [18].

Por tanto, en el campo deportivo se exponen una cantidad de movimientos articulares que se identifican visualmente, como la forma en la que se ejecuta un saque, una recepción, y otras actividades que proveen información que necesita ser digitalizada para lograr su interpretación y análisis. HAR permite visualizar dichas actividades en entornos sistemáticos indicando como la inteligencia artificial se apodera de las actividades cotidianas de una persona.

En el tenis, HAR se utiliza para:

- Clasificar gestos técnicos: Identificar movimientos específicos como golpes de derecha, servicios y voleas.
- Evaluar patrones biomecánicos: Analizar diferencias entre jugadores aficionados y expertos.
- Optimizar entrenamientos: Proveer retroalimentación en tiempo real basada en la ejecución técnica.

3.1.5 Inteligencia Artificial.

Adentrándose en el campo de la Inteligencia Artificial se observa como a través de algoritmos, se dota a los ordenadores de la capacidad de identificar patrones en datos masivos y elaborar predicciones (análisis predictivo). Este aprendizaje permite a los computadores realizar tareas específicas de forma autónoma, es decir, sin necesidad de ser programados [19]. La inteligencia artificial (IA) se ha convertido en un término general para referirse a aplicaciones que realizan tareas complejas para las que antes era necesaria la intervención humana. Por tanto, en la Figura 1, las categorías de movimiento implícitas como saque, servicio, revés, volea, derecha, recepción y otras que son en resumen el reconocimiento HAR; permiten ser manejables, manipulables, y predictores para algoritmos de IA logrando así tener información a partir de la cual se tomará decisiones favorables o no para los deportistas.

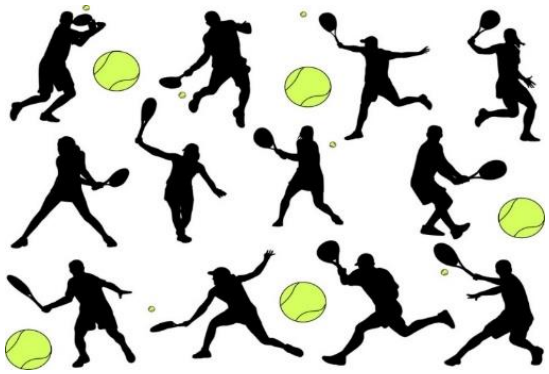

Figura 1. Movimientos en el tenis [20].

Los cuerpos técnicos deportivos están en el constante estudio de sus atletas, de las estrategias y de las competencias en diferentes escenarios, por tanto apoyados en todas estas técnicas de ciencia de datos podemos crear módulos de aprendizaje de máquina que influyan en las decisiones de las juntas de administración del deporte, como realizar un ranking de rendimiento en deportistas expertos, novatos y amateur que se encuentran identificados en la base de datos para identificar quienes son aptos para competencias regionales, departamentales, nacionales e internacionales.

3.1.6 Machine Learning en la Clasificación de Datos MOCAP

La ciencia de datos para lograr proyectos de impacto e innovación se apoya en modelos de Machine Learning el cual es uno de los pilares sobre los que descansa la transformación digital mediante la interpretación de algoritmos. En la actualidad, ya se está utilizando para encontrar nuevas soluciones en diferentes campos, entre los que cabe destacar: Recomendaciones personalizadas de compra en plataformas online, vehículos inteligentes en las carreteras, redes sociales, Procesamiento de Lenguaje Natural (PLN), motores de búsqueda, Deporte, Medicina, Ciberseguridad, entre otros [21].

Una de las aplicaciones más inmediatas que hay del aprendizaje automático es el procesamiento de datos acerca de la clasificación de la ejecución de los golpes de los atletas, esto puede ser utilizado para mejorar sus entrenamientos y dietas, así como también ayudarlos a prevenir lesiones y ponderar sus logros.

La Figura 2 ilustra las ocho etapas del proceso de Machine Learning, fundamentales para estructurar nuestro proyecto de clasificación de datos MOCAP en tenis. En primer lugar, se define el objetivo, que consiste en clasificar categorías de movimiento y la experticia de los atletas. Luego, se parte de una base de datos MOCAP ya recolectada, la cual contiene información detallada sobre distintos gestos técnicos en tenis. Posteriormente, se realiza un procesamiento y análisis exploratorio de los datos para identificar patrones biomecánicos relevantes.

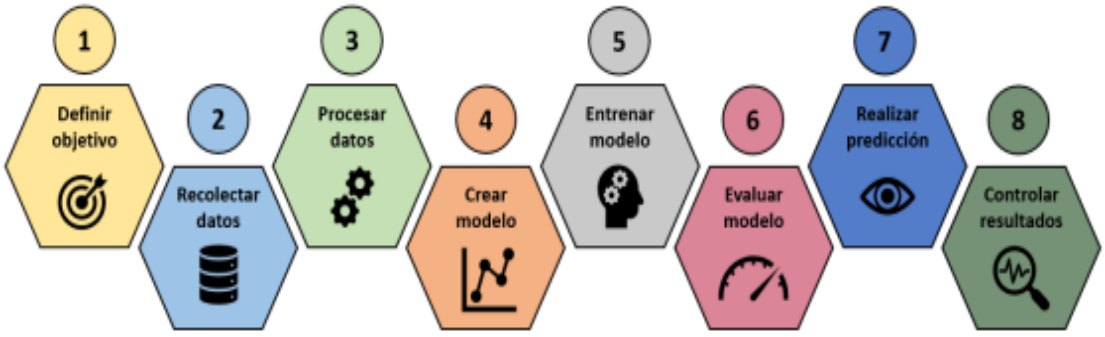

Figura 2. Etapas de Machine Learning [22].

Con esta información, se procede a la creación de modelos de Machine Learning capaces de clasificar los movimientos en categorías específicas, como golpes de derecha, revés y servicio. Estos modelos son entrenados y optimizados con los datos procesados, asegurando su capacidad predictiva. A continuación, se evalúan con para comprobar su precisión y minimizar errores. Una vez validados, se utilizan para realizar predicciones sobre nuevos datos, clasificando los movimientos de los atletas de manera automática. Finalmente, se controlan y ajustan los resultados según sea necesario, mejorando la fiabilidad del sistema y garantizando su utilidad en la evaluación biomecánica del tenis.

Si la investigación se pone a prueba bajo diferentes técnicas de Machine Learning se puede nombrar varias de ellas que aplican para el desarrollo de este proyecto entre las cuales se encuentran:

- **Deep Learning:** Es básicamente una red neuronal con tres o más capas. Estas redes neuronales intentan emular el comportamiento del cerebro humano, aunque lejos de igualar su capacidad, pero le permiten "aprender" a partir de grandes cantidades de datos. Aunque una red neuronal con una sola capa ya puede realizar predicciones aproximadas, las capas ocultas adicionales ayudan a optimizar y refinar la precisión [23].

En nuestro proyecto, es fundamental aterrizar el uso del Deep Learning en la clasificación de datos MOCAP en tenis, aprovechando su capacidad para identificar y analizar patrones biomecánicos con un alto nivel de precisión. Las redes neuronales profundas permiten descomponer los movimientos en características relevantes, facilitando la diferenciación entre gestos técnicos como el saque, el revés o la volea, lo que contribuye a una evaluación más objetiva y detallada del desempeño del atleta. Además, el uso de modelos de aprendizaje profundo posibilita el procesamiento en tiempo real de grandes volúmenes de datos, lo que resulta crucial para proporcionar retroalimentación inmediata en escenarios de entrenamiento o rehabilitación. Por tanto, más que enfocarnos en una discusión teórica sobre el futuro del aprendizaje automático, es importante destacar cómo el Deep Learning puede integrarse de manera práctica en nuestra investigación, optimizando la clasificación de los movimientos y ofreciendo una herramienta innovadora para el análisis biomecánico en el tenis.

- **Reproducing kernel Hilbert space (RKHS):** Dentro de la literatura de los métodos kernel, recientemente ha surgido el método embebido de distribuciones de probabilidad en RKHS. Este método consiste en representar distribuciones de probabilidad como un elemento de un espacio de Hilbert generado por un kernel [24].

En este trabajo pueden llegar a desarrollarse métricas entre distribuciones de probabilidad basadas en los espacios de Hilbert de núcleo reproductor, que permitan resolver problemas de clasificación de los datos MOCAP, así como problemas de regresión con la geometría de estos espacios, buscando reconocer actividades físicas humanas como movimientos perpendiculares del deportista en

el tenis. Estos espacios permiten representar distribuciones de probabilidad como elementos en un espacio de Hilbert generado por un núcleo, facilitando el desarrollo de métricas avanzadas para comparar distribuciones y resolver problemas de clasificación y regresión.

Representación de Distribuciones en RKHS.

Dada una distribución de probabilidad ***P***, se puede asociar un elemento en el RKHS mediante la esperanza de las funciones de característica definidas por el núcleo **k**:

$$\mu p = E\ x\ \sim p\ [k(X, .)]$$

Aquí, (***μP***) es la media de la distribución ***P*** en el espacio de Hilbert, (X) los datos y (***k***) es una función de núcleo que define el RKHS. Esta representación permite comparar distribuciones evaluando la distancia entre sus medias en el RKHS [25].

En términos geométricos, (***μP***) es el "centroide" de las representaciones kernel de los puntos de ***P*** en el espacio RKHS.

Métricas entre Distribuciones.

Una métrica comúnmente utilizada es la Discrepancia de Máxima Media **(MMD)** [26], que mide la distancia entre dos distribuciones **P** y ***Q*** en el RKHS:

$$MMD(P, Q) = \| \mu p - \mu q \| H$$

Esta métrica se calcula como la norma de la diferencia entre las medias de las distribuciones en el RKHS, proporcionando una medida de la similitud entre las distribuciones.

En el contexto de datos MOCAP, las secuencias de movimiento pueden ser vistas como realizaciones de distribuciones de probabilidad en espacios de alta dimensionalidad. Al mapear estas distribuciones en un RKHS, es posible calcular matrices de distancia utilizando funciones de núcleo como la gaussiana o la polinómica. Estas matrices reflejan la similitud entre diferentes secuencias de movimiento, permitiendo identificar patrones similares o detectar anomalías.

Implementación Matemática.

1. **Selección del Núcleo:** La elección de la función kernel ***k*** es crucial. Núcleos comunes incluyen el núcleo gaussiano

$$k(x, y) = \exp(-\| x - y \|^2/(2\sigma^2))$$

y el kernel:

$$k(x, y) = (x^T y + c)^d$$

2. **Cálculo de la Media en RKHS:** Para una muestra $\{\boldsymbol{x_i}\}^{\boldsymbol{n}}_{\boldsymbol{i=1}}$ de la distribución ***P***, la media en el RKHS se estima como:

$$\hat{\mu}p = \frac{1}{n}\sum_{i=1}^{n} k(x_i, .)$$

3. **Cálculo de MMD:** Dadas dos muestras X, Y en la siguiente manera $\{\boldsymbol{x_i}\}^{\boldsymbol{n}}_{\boldsymbol{i=1}}$ de la distribución ***P*** *y* $\{\boldsymbol{y_j}\}^{\boldsymbol{n}}_{\boldsymbol{j=1}}$ de la distribución ***Q,*** la MMD se estima como:

$$MMD^2 = \frac{1}{n^2}\sum_{i,i'} k(x_i, x_{i'}) + \frac{1}{m^2}\sum_{j,j'} k(y_j, y_{j'}) - \frac{2}{nm}\sum_{i,j} k(x_i, y_j)$$

Para una aplicación práctica de estos conceptos en la clasificación de datos MOCAP, se puede consultar el artículo "AN ENHANCED JOINT HILBERT EMBEDDING-BASED METRIC TO SUPPORT MOCAP DATA CLASSIFICATION WITH PRESERVED INTERPRETABILITY [27]." donde se introduce un enfoque mejorado basado en incrustaciones de Hilbert para mapear series temporales de MOCAP a un espacio tensorial, facilitando la clasificación de datos de movimiento humano.

- **Support Vector Machine (SVM):** Es un algoritmo de aprendizaje supervisado que se utiliza en muchos problemas de clasificación y regresión, incluidas aplicaciones médicas de procesamiento de señales, procesamiento del lenguaje natural y reconocimiento de imágenes y voz. El objetivo del algoritmo (SVM) es encontrar un hiperplano que separe de la mejor forma posible dos clases diferentes de puntos de datos. El algoritmo sólo puede encontrar este hiperplano en problemas que permiten separación lineal; en la mayoría de los problemas prácticos, el algoritmo maximiza el margen flexible permitiendo un pequeño número de clasificaciones erróneas [28].

Las máquinas de vectores de soporte se relacionan con el proyecto porque cómo bien lo enuncia en la cita resuelve problemas de clasificación y regresión de datos MOCAP, si entendemos que es un modelo que representa a los puntos de muestra en el espacio, que equivalen a los sensores que emiten datos específicos de las tareas realizadas durante la práctica deportiva, dichos problemas de clasificación no lineales emplean técnicas de mapeo permitiendo reorganizan los datos a través de funciones matemáticas, ya sea en el mismo plano o en planos de dimensiones mayores, para que adopten una configuración que los haga separables.

- **Clustering:** Es una disciplina particular del Machine Learning que tiene como objetivo separar sus datos en grupos homogéneos con características comunes.

Es un campo muy popular en el marketing, por ejemplo, donde a menudo se intenta segmentar las bases de clientes para detectar comportamientos particulares [29].

Para la investigación esta técnica de aprendizaje de máquina permite descubrir patrones ocultos y estructuras subyacentes en conjuntos de datos MOCAP, de manera aparente. En esencia, el clustering es como el hábil artista que organiza una galería de datos dispersos en una obra maestra coherente y significativa.

Por último, si seguimos con el orden de las etapas de los modelos de Machine Learning se deben realizar las pruebas necesarias y pertinentes para validar el correcto funcionamiento del modelo el cual se ha entrenado en busca de los objetivos relacionados con los datos MOCAP y su aplicación en el deporte.

3.1.7 Tecnologías para Datos MOCAP

El uso de aprendizaje automático (Machine Learning) en el análisis de datos MOCAP ha permitido avances significativos en la comprensión de patrones biomecánicos y en la personalización de entrenamientos. Sin embargo, también presenta desafíos técnicos que deben abordarse para maximizar su efectividad.

1. **Modelos avanzados para datos secuenciales:** Algoritmos como LSTM [30] y TRANSFORMER [31] han demostrado su capacidad para manejar la alta dimensionalidad y las dependencias temporales en los datos MOCAP. Por ejemplo, estos modelos pueden analizar cómo varían las trayectorias articulares durante un saque o un revés en el tenis.

2. **Visualización y retroalimentación en tiempo real:** La integración de modelos de Machine Learning con sistemas de visualización ha permitido desarrollar herramientas que generan retroalimentación inmediata durante entrenamientos. Esto es crucial para corregir errores técnicos sobre la marcha.

3. **Uso de aprendizaje transferido:** Los modelos pre - entrenados en tareas generales de reconocimiento de actividades se están adaptando con éxito a dominios específicos, como el análisis biomecánico deportivo, reduciendo los costos computacionales y el tiempo de desarrollo.

4. **Dimensionalidad de los datos:** Los sistemas MOCAP generan grandes volúmenes de datos multidimensionales que requieren técnicas avanzadas de reducción de dimensionalidad, como PCA [32] o t-SNE [33], para ser manejables sin pérdida de información crítica.

5. **Anotación de datos:** La clasificación manual de movimientos es costosa y propensa a errores, lo que limita la calidad de los modelos supervisados. Se están desarrollando sistemas semiautomatizados para abordar este problema.

6. **Generalización:** Los modelos deben ser capaces de adaptarse a diferentes atletas, niveles de habilidad y estilos de juego sin comprometer su precisión.

Caso de Uso: Machine Learning en el Análisis de Movimientos en Tenis

Un modelo SVM puede utilizar datos MOCAP para clasificar golpes de derecha entre jugadores amateurs y expertos. El análisis revela que los expertos mantienen una mayor estabilidad en el tronco y generan una transferencia de peso más eficiente, mientras que los amateurs presentan oscilaciones que reducen la efectividad del golpe. Este tipo de análisis proporciona información valiosa para personalizar programas de entrenamiento.

3.1.8 Lenguajes de programación

Para la implementación de este proyecto, se eligió el lenguaje de programación Python [34] por varias razones clave. Python es ampliamente reconocido por su facilidad de uso, flexibilidad y extensa comunidad de desarrolladores, lo que facilita la resolución de problemas y la integración de diferentes tecnologías. Además, Python cuenta con un ecosistema robusto de bibliotecas especializadas ideales para trabajar con datos MOCAP. Su capacidad para realizar procesamiento de datos a gran escala y su soporte para herramientas avanzadas de visualización y análisis lo convierten en una opción preferida para proyectos de ciencia de datos.

Aunque existen otros lenguajes de programación como C++ [35], MATLAB [36] y R [37], Python ofrece ventajas significativas para este tipo de proyectos. C++, por ejemplo, es un lenguaje muy eficiente en términos de rendimiento, pero requiere una mayor complejidad en su implementación, lo que puede hacer más difícil el desarrollo rápido de prototipos y soluciones. MATLAB, aunque es potente para cálculos numéricos y análisis de datos, tiene una curva de aprendizaje más empinada y está menos orientado a la manipulación de datos externos y al uso de aprendizaje automático de manera integrada. Por su parte, R es excelente para análisis estadístico, pero carece de la misma versatilidad y soporte que Python ofrece para proyectos complejos de visualización y procesamiento de datos como MOCAP. Python, al ser un lenguaje de propósito general, permite abarcar múltiples fases del proyecto de manera eficiente y con menor esfuerzo en la curva de aprendizaje.

3.2. ANTECEDENTES

EL desarrollo del proyecto se sustenta en base a las ciencias de entornos tecnológicos como son: la captura de movimiento, la inteligencia artificial hacia el reconocimiento de movimientos corporales humanos, la ciencia de datos con sus respectivas técnicas de exploración, visualización, modelamiento, entrenamiento, y verificación de los datos, entre otras ciencias que como bien se ha explicado a lo largo de este documento han tomado el control en una buena parte de todos los procesos en cualquier organización sin importar su misión ni su estructura privada o pública. El ser humano busca facilitar y mejorar la interpretación de la información

para tomar mejores decisiones desde la alta gerencia que aporten en el desarrollo de la visión empresarial y colectiva.

Es así como se muestra aplicaciones donde se implica la clasificación de los datos MOCAP, como el cine, el entretenimiento, la música, espacios publicitarios [38], medicina [39], otros, y el deporte [40] es aquí donde se aporta al estudio de los atletas de la liga de Tenis, como se puede observar estas aplicaciones se basan en reconocer actividades humanas cotidianas (HAR), las cuales se pueden modelar mediante algoritmos de Machine Learning.

Es importante codificar e investigar sobre las relaciones entre articulaciones MOCAP para resaltar patrones discriminativos [41]. Dentro de la investigación Las "articulaciones" se refieren a las partes móviles del cuerpo humano, como las rodillas, los codos, los hombros, etc. La "codificación" implica procesar los datos capturados para extraer características relevantes del movimiento, como la velocidad, la aceleración, los ángulos de las articulaciones, entre otras. Una vez que se han extraído estas características, se pueden analizar para encontrar relaciones entre las articulaciones. Por ejemplo, cómo se mueve una articulación en relación con otras durante una actividad específica, como caminar, correr o levantar objetos.

Practicar una actividad deportiva puede tener variaciones que pueden ser el resultado de alteración de la expresión, la postura, el movimiento y los efectos de perspectiva de los individuos [42]. La expresión, entendida como la manera en que los individuos manifiestan emociones y actitudes a través de su lenguaje corporal, puede influir en la ejecución de movimientos deportivos. Por ejemplo, la confianza o la ansiedad pueden afectar la forma en que un deportista realiza una técnica específica, lo que resulta en variaciones en el movimiento observado. La postura es otro aspecto importante para considerar pues las diferencias individuales en la estructura corporal, la flexibilidad y la fuerza muscular pueden influir en la postura adoptada durante la práctica deportiva. Estas variaciones pueden afectar la eficiencia del movimiento y aumentar el riesgo de lesiones si no se abordan adecuadamente. Por tanto, el movimiento en sí mismo es altamente variable entre individuos y puede estar sujeto a influencias externas, como el entorno de práctica, la fatiga o la experiencia previa. La comprensión de cómo estas variables afectan el movimiento es esencial para optimizar el entrenamiento y mejorar el rendimiento deportivo.

Existen estudios de dichos movimientos que estudian la biomecánica de los atletas de fútbol, baloncesto, baile, entre otros que muestran variaciones las cuales predicen trayectorias de datos MOCAP obtenidas a partir de representaciones esqueléticas en 3D, están codificadas en espacios de alta dimensión que contienen dinámicas no estacionarias [43]. la biomecánica de los atletas en diversas actividades deportivas ha demostrado que las variaciones en el movimiento pueden predecirse y analizarse mediante datos MOCAP codificados en espacios de alta dimensión. Estos estudios son fundamentales para comprender mejor el rendimiento humano y optimizar la práctica deportiva para nuestra liga de Tenis.

A su vez, se reproducen enfoques basados en el espacio kernel de Hilbert (RKHS) estos métodos tradicionales del kernel, mapeando la distribución de probabilidad de los datos de entrada como un vector/operador en RKHS favorece la estimación de medidas basadas en disimilitud dentro de espacios de alta dimensión [44]. Los métodos tradicionales del kernel son técnicas poderosas que permiten capturar la estructura subyacente y las relaciones no lineales en conjuntos de datos de alta dimensionalidad. Al aplicar estos métodos del kernel en esta investigación de la captura de movimiento, se mapea la distribución de probabilidad de los datos de entrada en un espacio de Hilbert de alta dimensión, conocido como RKHS. Este mapeo permite representar los datos de movimiento de manera más eficiente y expresiva, lo que facilita la detección y comprensión de patrones complejos en el movimiento humano.

Una de las ventajas clave de utilizar RKHS en este contexto es su capacidad para estimar medidas basadas en disimilitud dentro de espacios de alta dimensión. Estas medidas de disimilitud son fundamentales para comparar y contrastar diferentes secuencias de movimientos, identificar similitudes y diferencias entre ellas, y cuantificar la variabilidad en el movimiento entre diferentes individuos, actividades o condiciones. Por último, en la actualidad ha aumentado el número de proyectos enfocados a la visión por computador y el uso práctico de estos métodos en la vida cotidiana, de hecho, en Colombia existen empresas que se han enfocado en estos campos de las ciencias de datos especialmente en datos MOCAP como: Signos Studio S.A.S,[45] CRISALIDASSTUDIO [46], SINERMED [47], etc.

4. PREPROCESAMIENTO DE LOS DATOS

Los proyectos tecnológicos juegan un papel crucial en el desarrollo de las comunidades, ya que sus aplicaciones abarcan una amplia gama de sectores como la industria, las finanzas, la salud, y en este caso específico, el deporte. La liga de tenis de Caldas busca optimizar sus procesos de entrenamiento, retroalimentación y rehabilitación de atletas mediante el uso de tecnologías avanzadas, apoyadas en la ciencia de datos y el aprendizaje automático. El objetivo central de este proyecto es utilizar datos de captura de movimiento (MOCAP) para desarrollar modelos de Machine Learning para clasificar dichos datos.

En cuanto a las bibliotecas utilizadas en el proyecto y que se encuentran almacenadas en el (siguiente enlace) de Google COLAB, donde se puede destacar el uso de la biblioteca OS. La cuál es una biblioteca estándar de Python que facilita la interacción con el sistema operativo. Con OS, se puede manejar la navegación por los directorios, crear, leer y modificar archivos, lo cual es esencial para organizar y manipular grandes volúmenes de datos MOCAP distribuidos en diferentes archivos y carpetas.

Por otro lado, PYMO que también se ubica en el anterior enlace es una biblioteca especializada en la manipulación y análisis de datos de captura de movimiento. Dentro de PYMO, se emplean módulos como BVHPARSER, que permite leer y procesar archivos en formato BVH, utilizados comúnmente en la captura de movimiento; PREPROCESSING, que proporciona herramientas para limpiar y normalizar los datos, y VIZ_TOOLS, que facilita la creación de visualizaciones tridimensionales de los datos capturados, permitiendo a los entrenadores y analistas observar de manera detallada los movimientos de los atletas.

La elección de la clase SHECCO y que se encuentra en la celda No. 4 del libro de Google COLAB del (siguiente enlace) es especialmente importante dentro de este proyecto, ya que ofrece una infraestructura robusta para el análisis avanzado de datos de captura de movimiento. SHECCO implementa varios métodos de aprendizaje automático, como el Clustering Espectral y los Kernel Métodos, que permiten agrupar y clasificar los datos en función de patrones biomecánicos específicos.

Estas técnicas son útiles para identificar las diferencias entre atletas expertos y amateurs, así como para analizar cómo los atletas mejoran o varían su técnica a lo largo del tiempo. Además, la capacidad de SHECCO para transformar y visualizar los datos permite realizar análisis detallados, facilitando la toma de decisiones en el entrenamiento y la rehabilitación de los atletas.

4.1 Descripción datos:

El protocolo de captura de movimiento descrito en este estudio fue desarrollado por un equipo externo como parte de un proyecto anterior, y los datos resultantes fueron entregados para su análisis en esta investigación. Este protocolo incluyó la colocación de 34 marcadores reflectantes en puntos anatómicos clave del cuerpo de los atletas, específicamente diseñados para rastrear los movimientos articulares durante actividades deportivas complejas. Los marcadores se distribuyeron estratégicamente en zonas como las extremidades superiores e inferiores, la columna vertebral y las articulaciones principales, basándose en principios de biomecánica que aseguran un seguimiento preciso de los movimientos, como se muestra en la figura 3.

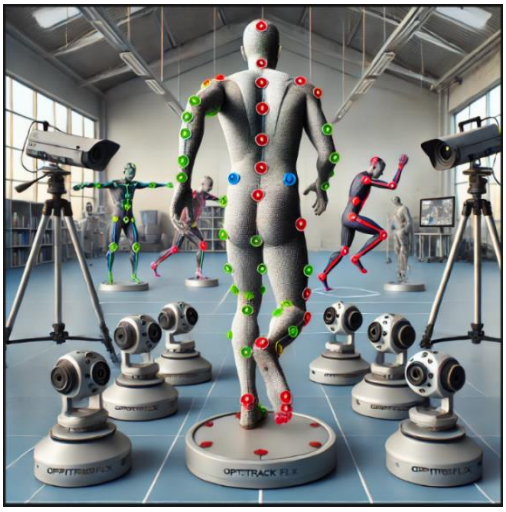

Figura 3. Posicionamiento de los marcadores (fuente propia con uso de PIXLR inteligencia artificial).

Para registrar estos datos, se utilizó un sistema de captura de movimiento por videografía infrarroja, compuesto por seis cámaras OptiTrack Flex [48]. Estas cámaras operaban a una frecuencia de muestreo de 100 Hz, lo que permite capturar datos a una alta resolución temporal, asegurando que los movimientos rápidos o sutiles, como los gestos deportivos de alta velocidad, se registraran con precisión.

Cada una de las cámaras estaba ubicada estratégicamente para capturar imágenes desde diferentes ángulos: planos sagitales, frontales y laterales, proporcionando una visión completa de los movimientos tridimensionales de los atletas. La elección de un sistema de múltiples cámaras garantiza que los datos de movimiento no se pierdan debido a la oclusión (es decir, cuando un marcador queda oculto desde el punto de vista de una cámara).

Tras la captura, los datos fueron procesados y convertidos al formato BVH (Biovision Hierarchy) [49]. Este formato es un estándar reconocido internacionalmente para la representación y almacenamiento de datos de captura de movimiento, utilizado comúnmente en estudios biomecánicos, animación por ordenador, y simulaciones en entornos 3D. El formato BVH no solo conserva las coordenadas espaciales y

temporales de los movimientos, sino que también permite una jerarquización de las partes del cuerpo, lo que facilita el análisis detallado de las interacciones entre las distintas articulaciones durante los movimientos.

Es importante aclarar que, aunque describimos el protocolo de captura de datos, este procedimiento de recolección no fue realizado por esta investigación. Sin embargo, consideramos relevante incluir esta información para comprender plenamente la naturaleza y calidad de los datos utilizados, lo que nos permite centrarnos en el análisis y la interpretación de estos para cumplir con los objetivos de nuestro estudio, estos datos se almacenan en el (siguiente enlace) [50] del GITHUB y los cuales son datos abiertos al acceso público.

Desde una perspectiva teórica, este enfoque se basa en los principios de la biomecánica deportiva, que estudia el comportamiento del cuerpo humano en movimiento, especialmente bajo las condiciones en el deporte del tenis. La biomecánica utiliza herramientas como la captura de movimiento para evaluar aspectos como la eficiencia mecánica, la fuerza aplicada en las diferentes articulaciones, y las posibles compensaciones que puedan llevar a lesiones. En este contexto, la captura de movimiento ayuda a diseñar programas de rehabilitación y prevención de lesiones.

Además, el análisis de estos datos se apoya en metodologías de ciencia de datos y aprendizaje automático. La fase inicial de cualquier estudio que utilice datos de captura de movimiento implica un análisis exploratorio de datos (EDA), que nos permite identificar patrones, relaciones y posibles anomalías en los datos. A partir de estos datos limpios y preprocesados, es posible aplicar técnicas de aprendizaje automático como el clustering o la clasificación supervisada para evaluar y segmentar los diferentes niveles de habilidad de los atletas.

El protocolo BVH, los datos recolectados han sido organizados en un **dataset estructurado e identificado en 6 subcarpetas con su movimiento específico que contiene los 16 archivos BVH de los 16 atletas como se muestra en la Tabla 1 de datos MOCAP**, dichos jugadores realizaban una serie de ejercicios específicos, que incluyeron seis golpes de tenis. Este enfoque no solo captura la cinemática del movimiento, sino que también facilita el análisis posterior mediante técnicas de aprendizaje automático y visión por computadora, permitiendo la identificación de patrones y anomalías que podrían pasar desapercibidas en una evaluación visual tradicional.

El uso de bases de datos públicas, como la que se generó en este proyecto, es fundamental para avanzar en la investigación en ciencias del deporte. Estas bases de datos permiten replicar estudios, validar modelos y contribuir al desarrollo de nuevas metodologías. Cada carpeta del dataset contiene registros de seis tipos de movimientos: derecha, remate, revés, servicio, V derecha y V revés.

Tabla 1 de Datos MOCAP (fuente propia).

DATOS MOCAP					
No. CARPETA					
No.	**MOVIMIENTO DERECHA (01)**	**No**	**MOVIMIENTO REMATE (02)**	**No**	**MOVIMIENTO REVES (03)**
01	jjmarin_Derecha.bvh	01	jsguevara_Remate.bvh	01	jgacosta_Reves.bvh
02	astrejos_Derecha.bvh	02	lvargas_Remate.bvh	02	jsgiraldo_Reves.bvh
03	jpmoreno_Derecha.bvh	03	jgacosta_Remate.bvh	03	jsguevara_Reves.bvh
04	lvargas_Derecha.bvh	04	jpmoreno_Remate.bvh	04	jangel_Reves.bvh
05	adorozco_Derecha.bvh	05	jjmarin_Remate.bvh	05	jarua_Reves.bvh
06	jarua_Derecha.bvh	06	adorozco_Remate.bvh	06	mrios_Reves.bvh
07	mrios_Derecha.bvh	07	secheverri_Remate.bvh	07	jpmoreno_Reves.bvh
08	jpcardona_Derecha.bvh	08	jdescobar_Remate.bvh	08	astrejos_Remate.bvh
09	jsguevara_Derecha.bvh	09	mrios_Remate.bvh	09	cferrero_Reves.bvh
10	jangel_Derecha.bvh	10	jangel_Remate.bvh	10	secheverri_Reves.bvh
11	cferrero_Derecha.bvh	11	cferrero_Remate.bvh	11	jdescobar_Reves.bvh
12	jsgiraldo_Derecha.bvh	12	jarua_Remate.bvh	12	lvargas_Reves.bvh
13	jduribe_Derecha.bvh	13	jpcardona_Remate.bvh	13	adorozco_Reves.bvh
14	jdescobar_Derecha.bvh	14	astrejos_Remate.bvh	14	jpcardona_Reves.bvh
15	jgacosta_Derecha.bvh	15	jsgiraldo_Remate.bvh	15	jduribe_Reves.bvh
16	secheverri_Derecha.bvh	16	jduribe_Remate.bvh	16	jjmarin_Reves.bvh
No. CARPETA					
No.	**MOVIMIENTO SERVICIO (04)**	**No.**	**MOVIMIENTO VDERECHA (05)**	**No.**	**MOVIMIENTO VREVES(06)**
01	jduribe_Servicio.bvh	01	jduribe_VDerecha.bvh	01	jpcardona_VReves.bvh
02	cferrero_Servicio.bvh	02	jangel_VDerecha.bvh	02	adorozco_VReves.bvh

03	jsgiraldo_Servicio.bvh	03	mrios_VDerecha.bvh	03	cferrero_VReves.bvh
04	jangel_Servicio.bvh	04	astrejos_VDerecha.bvh	04	jsgiraldo_VReves.bvh
05	jdescobar_Servicio.bvh	05	jgacosta_VDerecha.bvh	05	jpmoreno_VReves.bvh
06	jpcardona_Servicio.bvh	06	secheverri_VDerecha.bvh	06	jdescobar_VReves.bvh
07	astrejos_Servicio.bvh	07	jsguevara_VDerecha.bvh	07	secheverri_VReves.bvh
08	jsguevara_Servicio.bvh	08	jpmoreno_VDerecha.bvh	08	jsguevara_VReves.bvh
09	adorozco_Servicio.bvh	09	jsgiraldo_VDerecha.bvh	09	jjmarin_VReves.bvh
10	secheverri_Servicio.bvh	10	lvargas_VDerecha.bvh	10	jangel_VReves.bvh
11	jarua_Servicio.bvh	11	jdescobar_VDerecha.bvh	11	mrios_VReves.bvh
12	mrios_Servicio.bvh	12	jjmarin_VDerecha.bvh	12	jarua_VReves.bvh
13	jpmoreno_Servicio.bvh	13	cferrero_VDerecha.bvh	13	lvargas_VReves.bvh
14	jgacosta_Servicio.bvh	14	adorozco_VDerecha.bvh	14	jduribe_VReves.bvh
15	jjmarin_Servicio.bvh	15	jpcardona_VDerecha.bvh	15	jgacosta_VReves.bvh
16	lvargas_Servicio.bvh	16	jarua_VDerecha.bvh	16	astrejos_VReves.bvh

Esta organización facilita el acceso y análisis de los datos, y los archivos, originalmente en formato MP4, fueron convertidos al formato BVH para su procesamiento, a continuación, en el (siguiente enlace) se muestra la estructura de los datos de uno de los atletas archivo que se compone de 2 partes: Una sección HIERARCHY que define la estructura esquelética, especificando los nombres y relaciones de las articulaciones o en inglés llamados (JOINTS) [51], mientras que la sección MOTION contiene los datos de movimiento para cada fotograma.

Para mejor entendimiento y descripción de los datos se toma estos datos en formato BVH y se explica la composición uniforme para cada uno de los 16 atletas y sus 6 movimientos lo que nos da un total de 96 iteraciones con la misma estructura compuesta así:

- HIERARCHY:

Define los Joint del esqueleto, comenzando desde la raíz (Hips) o cadera.

Cada Joint tiene un OFFSET que describe su posición en relación con el Joint padre y los CHANNELS, que indican los tipos de rotaciones o posiciones que se aplican para la rotación o traslación en los ejes X, Y, Z.

La jerarquía del esqueleto incluye Joint como (['Hips', 'Chest', 'Neck', 'Head', 'Head_Nub', 'LeftCollar', 'LeftShoulder', 'LeftElbow', 'LeftWrist', 'LeftWrist_Nub', 'RightCollar', 'RightShoulder', 'RightElbow', 'RightWrist', 'RightWrist_Nub', 'LeftHip', 'LeftKnee', 'LeftAnkle', 'LeftAnkle_Nub', 'RightHip', 'RightKnee', 'RightAnkle', 'RightAnkle_Nub']) almacenadas en el siguiente directorio dict_keys.

- MOTION:

La sección de movimiento indica que hay 2999 frames de datos de movimiento.

Cada línea en la sección de MOTION representa las posiciones y rotaciones de los Joint para un frames dado.

El tiempo entre frames es 0.01 segundos, lo que sugiere que los datos se capturan a una velocidad de 100 FPS (frames por segundo).

La veracidad y precisión de los datos MOCAP obtenidos son cruciales para la eficacia de los modelos de clasificación que se aplicarán. La correcta adquisición y procesamiento de estos datos asegura que el análisis resultante sea robusto y confiable, proporcionando información valiosa para la toma de decisiones en el ámbito deportivo. En un contexto deportivo es cada vez más competitivo, herramientas como las desarrolladas en este proyecto pueden marcar la diferencia al identificar errores técnicos o patrones de movimiento que podrían ser optimizados en la clasificación de los datos MOCAP.

Finalmente, los archivos recopilados y organizados en el dataset están disponibles para su análisis, contribuyendo al desarrollo de aplicaciones que no solo apoyan el entrenamiento deportivo, sino que también permiten una evaluación objetiva y detallada, ayudando a identificar áreas de mejora que no son evidentes a simple vista. Este tipo de análisis, sustentado en datos precisos y bien estructurados, es esencial para escalar y optimizar las actividades diarias de los deportistas en las disciplinas que practican.

4.2 Transformación datos:

Para analizar los movimientos de los tenistas, el primer paso es transformar los datos de captura de movimiento (MOCAP) almacenados en archivos con formato BVH (Biovision Hierarchy). Este formato es ampliamente utilizado en estudios biomecánicos, ya que permite capturar y organizar la estructura de un esqueleto humano en movimiento, registrando las posiciones de sus articulaciones a lo largo del tiempo.

Para llevar a cabo esta tarea, se utiliza una herramienta llamada BVHParser [52]. Esta clase actúa como un "traductor" que toma los datos de los archivos BVH y los descompone en su estructura más básica: la jerarquía del esqueleto y las posiciones de las articulaciones del cuerpo en cada instante del movimiento. Básicamente, imagina que tenemos un mapa del cuerpo humano con puntos clave, como las muñecas, los codos, las rodillas, y el BVHParser se encarga de extraer esa información para que podamos trabajar con ella. La figura 4 ilustra dicha transformación.

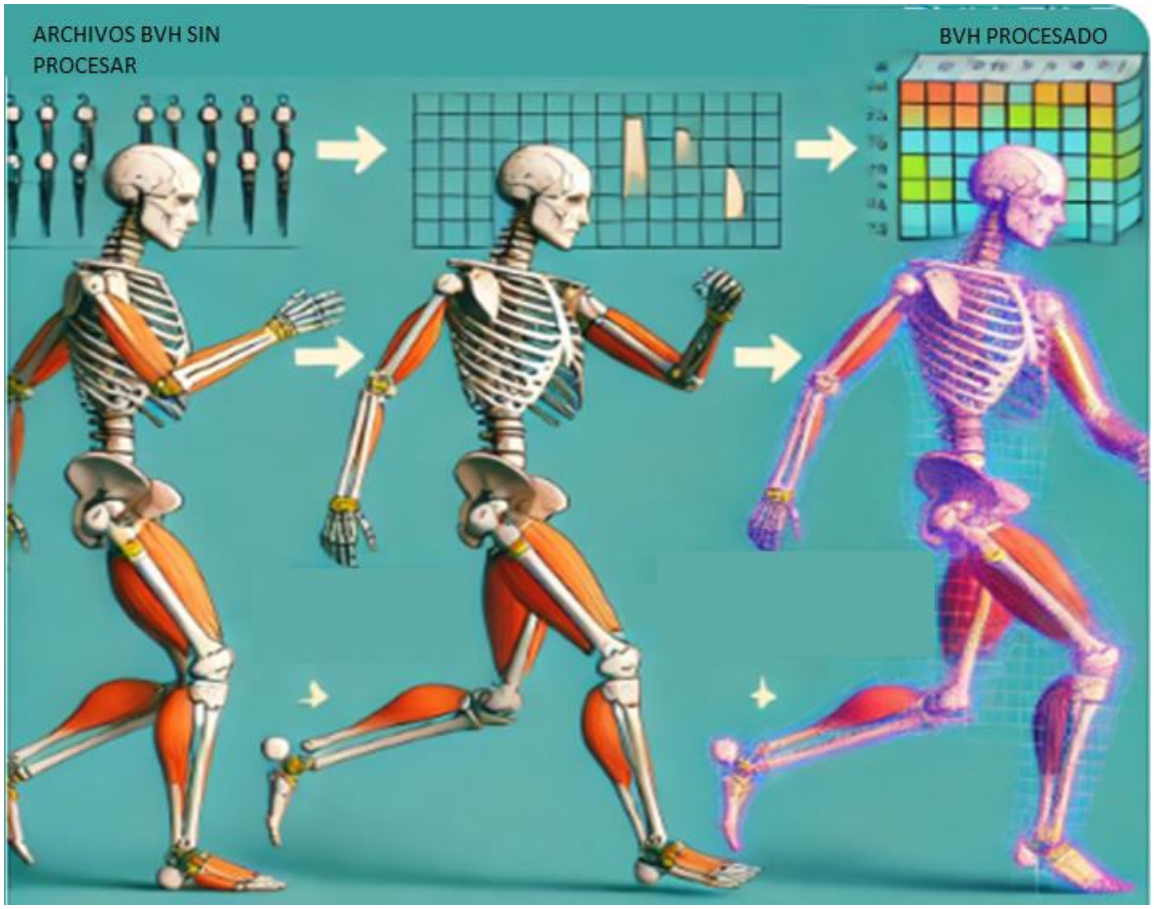

Figura 4. Transformación de los movimientos BVH (fuente propia con uso de PIXLR inteligencia artificial).

Sin embargo, los datos por sí solos no son fáciles de manejar o interpretar. Por ello, el siguiente paso consiste en procesarlos usando otra herramienta llamada MOCAP Parameterizer (MP) [53]. Esta herramienta convierte las posiciones de las articulaciones en una forma que resulta más sencilla de utilizar en análisis posteriores. En otras palabras, se encarga de simplificar los datos sin perder información importante, lo que facilita que podamos hacer análisis detallados más adelante, la Figura 5 hace una indicación ilustrativa de la función.

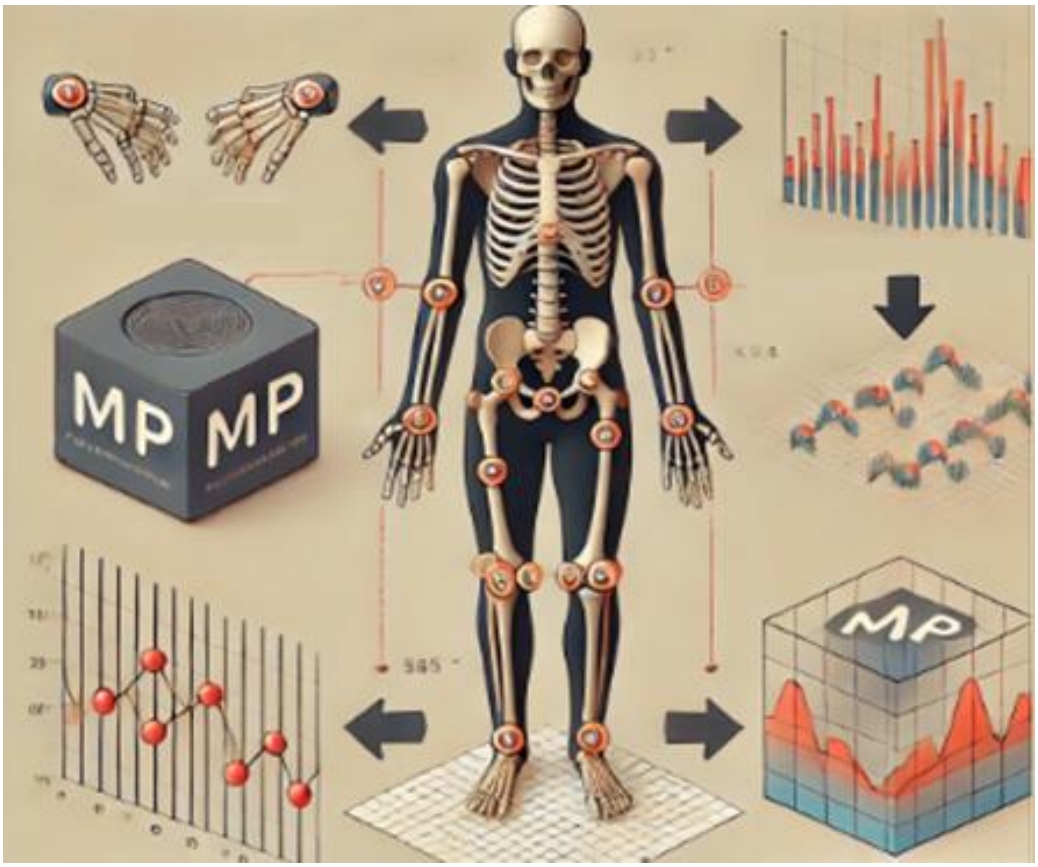

Figura 5. Transformación MP (fuente propia).

Para organizar toda esta información, se utiliza el (siguiente enlace) de Google COLAB denominado TESIS_MOCAP en la celda No. 11 podemos encontrar lo necesario el procesamiento de los datos donde un diccionario llamado POS_CENT es un tipo de contenedor como se muestra en la (celda No.14) que contiene la estructura del diccionario POS_CENT que nos permite guardar y organizar la información de una manera que sea fácil de acceder. Este diccionario almacena las posiciones de las articulaciones de los jugadores, capturadas desde los archivos BVH, y las mantiene ordenadas según la ruta del directorio donde se encuentran los archivos de cada jugador del dataset. Este dataset contiene información crítica sobre los movimientos que realizan los tenistas, como golpes de derecha, reveses, servicios, y más.

Después de procesar estos datos, el siguiente paso es convertir las posiciones en coordenadas en dos dimensiones (2D), utilizando una función llamada fit_transform [54]. ¿Por qué convertir los datos tridimensionales (3D) en 2D? Porque, para muchas aplicaciones prácticas, especialmente las visualizaciones, es más sencillo interpretar y analizar los datos en dos dimensiones. Este paso es clave, ya que, aunque estamos reduciendo la complejidad, la función fit_transform se asegura de que no perdamos la información más importante sobre cómo se mueven los jugadores.

Los datos resultantes, que ahora están en 2D como se muestra en la Figura 6, se almacenan en la variable POSITIONS. Esta variable guarda las posiciones de las articulaciones de los tenistas, permitiendo que podamos visualizarlas fácilmente. Para ello, se utiliza una función llamada draw_stickfigure [55], que básicamente crea una figura esquelética del jugador en movimiento, función que se usará más adelante para el subcapítulo de visualización de los datos. Esta representación gráfica es muy útil para analizar los movimientos de los jugadores, ya que nos permite ver claramente cómo se comportan sus cuerpos durante un golpe o un movimiento específico.

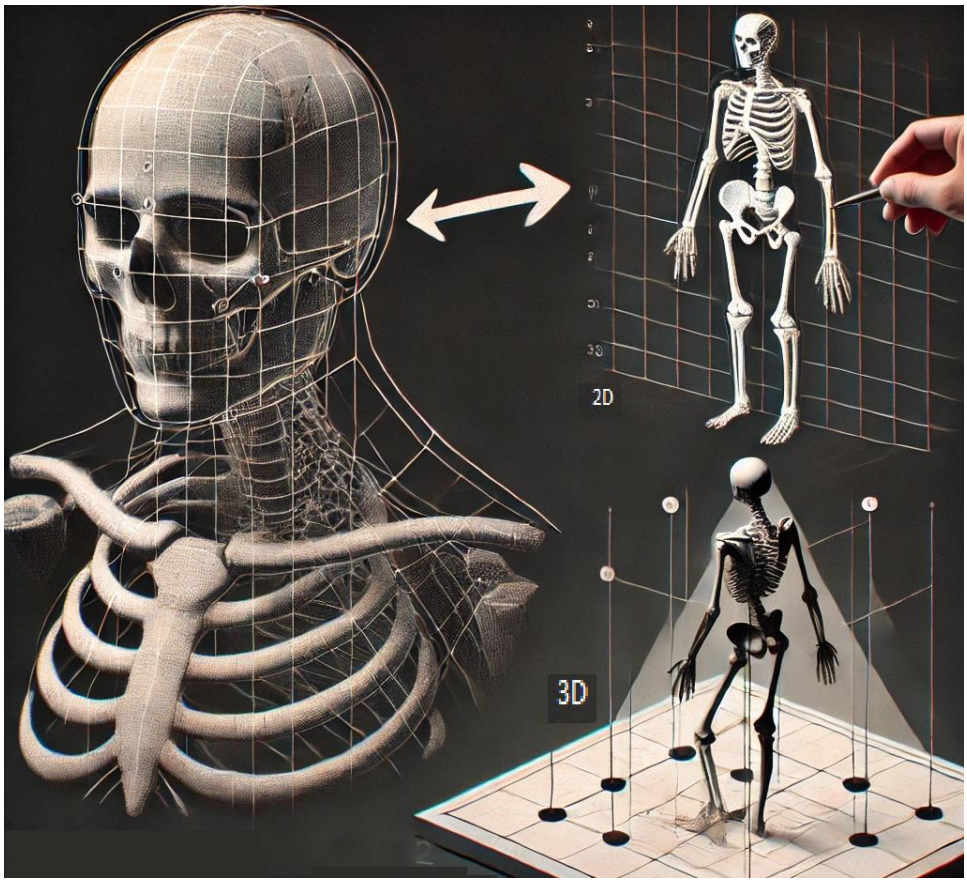

Figura 6. Transformación 3D a 2D (fuente propia).

4.3 Limpieza de datos:

La limpieza de datos es un paso crucial en cualquier análisis de captura de movimiento, ya que garantiza la precisión y confiabilidad de los resultados. En este proyecto, la Liga de Tenis de Caldas nos proporcionó una base de datos meticulosamente preparada, concediéndonos los permisos necesarios para su uso como lo hemos expresado a lo largo de este documento los datos son abiertos al público. Este dataset fue capturado utilizando un software especializado en captura de movimiento que emplea avanzadas técnicas de filtrado y calibración para minimizar errores y asegurar la integridad de los datos.

El proceso de captura incluyó la eliminación de ruidos y la corrección de posibles desviaciones, lo que resultó en un conjunto de datos libre de atípicos. Gracias a estas herramientas avanzadas y al riguroso proceso de limpieza aplicado por la Liga, el conjunto de datos recibido ofrece una representación precisa y confiable de los patrones de movimiento en el tenis, facilitando un análisis detallado y robusto. Esta colaboración ha sido fundamental para obtener resultados significativos en nuestra investigación sobre los movimientos técnicos y tácticos en el tenis de alto rendimiento, destacando la importancia de la colaboración entre instituciones deportivas y la investigación académica en el avance del conocimiento en este campo.

4.4 Preparación datos:

La librería PYMO se ha configurado previamente y contiene las librerías PANDAS [56], NUMPY [57], SKLEARN [58], entre otras que poseen configuración de las articulaciones o JOINTS como se muestra en la descripción de los datos, estos tienen una posición inicial y varios canales que especifican sus grados de libertad en términos de posición y rotación.

Los JOINTS que como hemos hablado se componen de la sección MOTION en la estructura del archivo BVH, y que, por otro lado, contiene la secuencia de datos de movimiento, especificando la posición y rotación de cada articulación en cada fotograma de la animación. Esta estructura jerárquica y detallada permite una representación precisa y manipulable del movimiento, esencial para aplicaciones en animación, videojuegos y análisis biomédico.

Por tanto, en la (celda No.16) de COLAB podemos observar la codificación necesaria para extraer su contenido, que incluye la estructura del esqueleto con las articulaciones como se muestra en la siguiente tabla 2. que traduce los JOINT en su nombre respectivo en español.

Tabla 2 JOINT Articulaciones (fuente propia).

JOINT	ARTICULACION
Hips	Caderas
Chest	Pecho
Neck	Cuello
Head	Cabeza
Head_Nub	Extremo de la cabeza
LeftCollar	Clavícula izquierda
LeftShoulder	Hombro izquierdo
LeftWrist	Muñeca izquierda
LeftElbow	Codo izquierdo
LeftWrist_Nub	Extremo de la muñeca izquierda
RightCollar	Clavícula derecha
RightShoulder	Hombro derecho
RightElbow	Codo derecho
RightWrist	Muñeca derecha
RightWrist_Nub	Extremo de la muñeca derecha
LeftHip	Cadera izquierda
LeftKnee	Rodilla izquierda
LeftAnkle	Tobillo izquierdo
LeftAnkle_Nub	Extremo del tobillo izquierdo
RightHip	Cadera derecha
RightKnee	Rodilla derecha
RightAnkle	Tobillo derecho
RightAnkle_Nub	Extremo del tobillo derecho

Como parte de la preparación de los datos de captura de movimiento (MOCAP), hemos realizado un análisis comparativo de la articulación del "Pecho" (Chist) entre dos atletas, Orozco y JJMarin, durante el golpe de derecha en tenis. Este proceso involucra la extracción de las posiciones en los ejes X, Y, Z para cada fotograma de la secuencia de movimiento, lo que nos permite observar las diferencias biomecánicas entre ambos jugadores. Los datos fueron graficados en la Figura 3. (Comparación CHEST celda No. 17) del cuaderno de COLAB donde se visualiza el comportamiento de esta articulación a lo largo del tiempo, proporcionando una visión clara de las variaciones en la ejecución del movimiento.

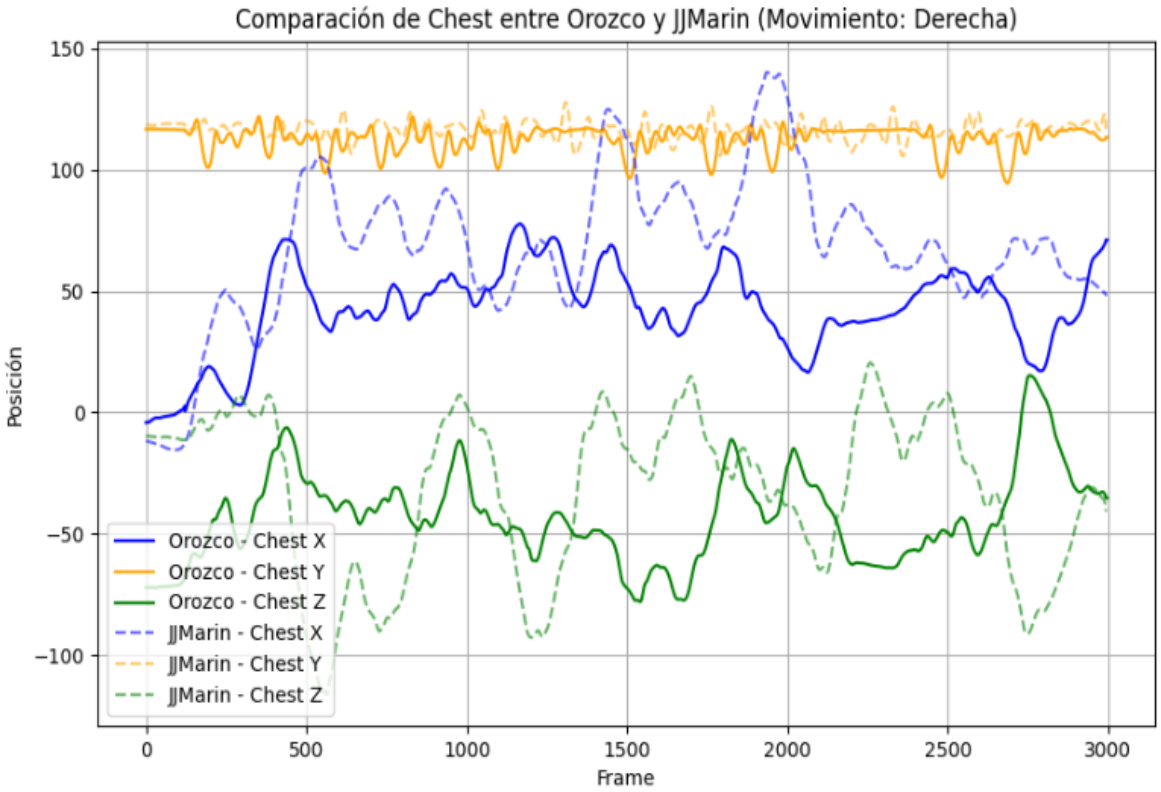

Figura 7. Comparación CHEST (fuente propia).

En la Figura 7. se pueden observar las trayectorias de la articulación "Pecho" para ambos jugadores en los tres ejes. Las líneas continuas representan los movimientos de Orozco, mientras que las líneas discontinuas corresponden a JJMarin. Cada color representa un eje de movimiento: azul para el eje X, naranja para el eje Y, verde para el eje Z. A lo largo de los más de 3000 fotogramas analizados, se nota una diferencia significativa en la amplitud y frecuencia de los movimientos entre los dos atletas. En el eje X, por ejemplo, JJMarin presenta oscilaciones más acentuadas que Orozco, mientras que en el eje Z se observan diferencias notables en las posiciones iniciales y la amplitud del movimiento. Asimismo, en el eje Y, los datos de Orozco muestran una trayectoria más lineal, lo que sugiere que su postura se mantiene más erguida durante el golpe, una característica que podría ser vital en la estabilidad y eficacia del golpe en tenis.

Esta mayor linealidad en el eje Y podría estar asociada con una postura corporal más firme y erguida, lo cual es esencial en el tenis, ya que permite un mejor control del centro de gravedad y facilita movimientos rápidos y precisos. JJMarin, por otro lado, muestra mayores oscilaciones en el eje Y, lo que podría indicar variaciones en su postura durante el golpe, afectando su equilibrio. Estos resultados sugieren diferencias en la técnica de golpeo entre los dos jugadores, y el análisis comparativo nos permite obtener información valiosa sobre las diferencias biomecánicas, lo que puede ser utilizado en futuros estudios de rendimiento deportivo y entrenamiento personalizado.

4.5 Visualización datos:

En el contexto de esta investigación sobre la captura de movimiento (MOCAP), los sujetos participantes se encuentran en un laboratorio equipado con tecnología avanzada y sensores especializados, bajo la supervisión de profesionales en deporte y rehabilitación. Cada sujeto ejecuta una serie de golpes estándar de tenis, incluyendo saques, golpes de derecha, revés, voleas normales, voleas de revés y smash. Estos movimientos son capturados continuamente utilizando un sistema de captura de movimiento como lo hemos aclarado antes en este documento, asegurando así la precisión y fiabilidad de los datos obtenidos. Un ejemplo lo podemos ver en la Figura 8 un esqueleto con sus articulaciones para un atleta de tenis que ejecuta un golpe de derecha.

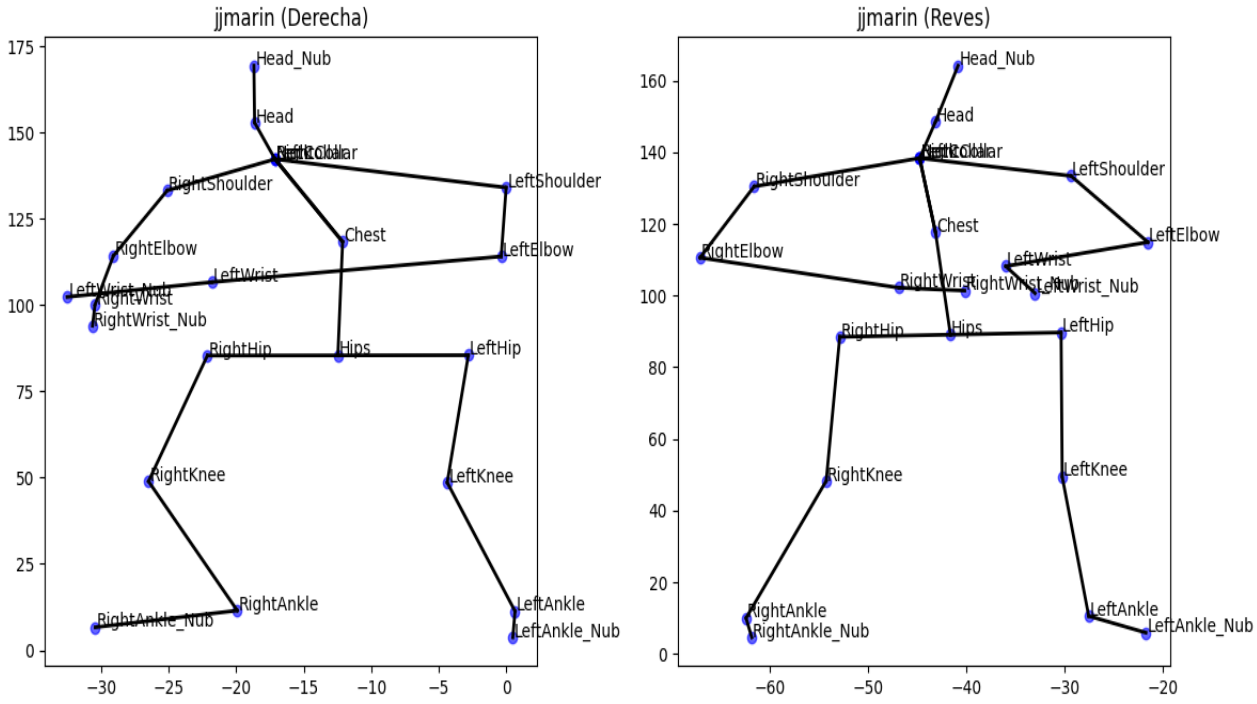

Figura 8. Visualización de categorías de movimiento (fuente propia).

Para analizar y visualizar los datos de captura de movimiento de los atletas, en el cuaderno de COLAB en las (celdas 20-21) encontramos los archivos BVH previamente procesados que contienen información detallada de las posiciones y movimientos de las articulaciones del cuerpo humano, lo que permite representar con precisión la biomecánica de los atletas durante la ejecución de golpes de tenis.

El código automatiza el proceso de lectura de los archivos y genera una visualización gráfica de los movimientos clave, como el golpe de derecha y el servicio. Para cada atleta, se accede a los archivos correspondientes a estos movimientos desde directorios separados, y se extraen los datos para representar

los Joint (articulaciones) en forma de esqueleto simplificado. Este esqueleto se grafica en una grilla utilizando MATPLOTLIB [59], lo que permite comparar lado a lado los movimientos de derecha y revés de cada atleta.

También se muestra las etiquetas de cada Joint en la visualización, lo que facilita el análisis detallado de la biomecánica del movimiento. Las etiquetas indican las posiciones relativas de las principales articulaciones, tales como los hombros, codos, muñecas, caderas y rodillas, lo que proporciona un contexto visual para el análisis biomecánico. El resultado final es una figura que muestra los movimientos de todos los atletas participantes, organizados en columnas para comparar los diferentes tipos de golpes.

El procesamiento automatizado no solo acelera el análisis de los datos, sino que también asegura la consistencia en la representación visual de los movimientos, permitiendo que los investigadores identifiquen patrones biomecánicos comunes o diferencias clave entre los atletas.

5. CLASIFICACION MOCAP

Tras un exhaustivo preprocesamiento de los datos obtenidos mediante captura de movimiento (MOCAP) de jugadores de tenis, este capítulo se centra en la clasificación de estos datos. La clasificación de datos MOCAP es una herramienta crucial en el análisis deportivo, ya que permite el reconocimiento de actividades humanas (HAR) mediante la identificación y etiquetado de diferentes movimientos realizados por los jugadores. Este proceso es esencial para el análisis biomecánico, facilitando la distinción entre diversos tipos de movimientos como golpes de derecha, servicios y remates, proporcionando una comprensión más profunda de los patrones de movimiento y la técnica de los deportistas.

El flujo de trabajo seguido en este proyecto comienza con la transformación de los datos crudos en formato BVH. Este paso incluye el análisis de la estructura BVH y la extracción de articulaciones. Posteriormente, los datos se normalizan con respecto a las caderas para garantizar consistencia en las mediciones. A continuación, se lleva a cabo la ingeniería de características, donde se aplica la proyección en un espacio de Hilbert (RKHS) para generar una matriz de disimilaridad. Esta matriz representa nuestro nuevo conjunto de datos, optimizado para las técnicas de aprendizaje automático.

El uso de un sistema automatizado para clasificar los datos permite evaluar de manera eficiente los golpes de los jugadores en el tenis. Esta automatización no solo reduce la necesidad de un análisis manual por parte de los entrenadores, sino que también ofrece retroalimentación rápida y objetiva. Gracias a la alta precisión de los datos MOCAP, es posible realizar una clasificación detallada de los movimientos, detectando incluso las diferencias más sutiles en la técnica de los jugadores.

Las técnicas de aprendizaje automático empleadas incluyen métodos como Support Vector Machines (SVM), Random Forest, k-Nearest Neighbors (k-NN) y redes neuronales. Estas herramientas permiten modelar y analizar los patrones de movimiento con gran precisión, facilitando la personalización de los entrenamientos en función de las necesidades específicas de cada jugador. Además, la clasificación de movimientos también contribuye a la prevención de lesiones. Al identificar patrones de movimiento asociados con un mayor riesgo de lesiones, los entrenadores pueden implementar cambios preventivos en la técnica o en la carga de entrenamiento, mejorando la seguridad y efectividad de las sesiones.

Desde una perspectiva investigativa, este proyecto tiene un impacto significativo en el campo del análisis deportivo. Los resultados obtenidos no solo benefician a entrenadores y jugadores, sino que también contribuyen al conocimiento científico, permitiendo estudios futuros que optimicen las técnicas de entrenamiento y estrategias de prevención de lesiones en deportes como el tenis.

En conclusión, la clasificación de datos MOCAP mediante el uso de modelos de aprendizaje automático, en combinación con la representación en RKHS y la matriz

de disimilaridad. Este enfoque proporciona un análisis biomecánico riguroso y detallado, posicionándose a la vanguardia del análisis deportivo y abriendo nuevas oportunidades para la investigación y el desarrollo en el ámbito del deporte.

5.1 NORMALIZACIÓN.

En el procesamiento de datos de captura de movimiento, para preparar estos datos es necesario la (NORMALIZACIÓN), esto es un paso crucial para garantizar la consistencia y la comparabilidad de las posiciones del esqueleto capturado a lo largo del tiempo. Es importante la normalización para garantizar la consistencia al centrar las posiciones del esqueleto en las caderas, esto es particularmente importante cuando se combinan datos de múltiples sesiones de captura o diferentes sujetos.

Durante la normalización también se elimina las variaciones debidas al movimiento global del cuerpo, como el desplazamiento o la rotación, permitiendo que el análisis se enfoque en el movimiento relativo de las extremidades. Al trabajar con datos normalizados, las técnicas de análisis y modelado, como el clustering o el aprendizaje automático, pueden operar de manera más efectiva, ya que las variaciones innecesarias se minimizan.

La normalización se realiza para hacer que las posiciones de las articulaciones sean relativas a las caderas. Esto se hace restando las coordenadas de las caderas (la articulación central del cuerpo) de todas las otras articulaciones en cada fotograma. Esta es una técnica estándar en análisis biomecánico, porque la posición absoluta de una articulación no es tan relevante como su posición relativa a un punto de referencia, que generalmente es el centro del cuerpo (las caderas).

Sea $\mathbf{X}_{i,j}$ la posición de la articulación **j** en el fotograma **i**, entonces la normalización respecto a las caderas es:

$$\mathbf{Z}_{i,j} = \mathbf{X}_{i,j} - \mathbf{X}_{i,0}$$

Donde $\mathbf{X}_{i,0}$ representa la posición de las caderas (que está en la primera posición de cada fotograma). Esto asegura que las posiciones finales sean relativas al movimiento del cuerpo en torno a las caderas.

Esta fórmula se aplica a todas las articulaciones **j** y a todas las coordenadas espaciales **X, Y, Z** de la posición.

Importancia de la normalización:

- Permite que las articulaciones se expresen en relación con el centro del cuerpo, eliminando traslaciones absolutas en el espacio.
- Facilita la comparación entre diferentes secuencias de movimiento, ya que elimina desplazamientos globales.
- En biomecánica, la normalización es crucial para analizar la simetría, los rangos de movimiento y las diferencias entre atletas.

El conjunto de datos se debe representar como una matriz tridimensional de forma (96, 23, 69), que describe secuencias de movimiento capturadas por un sistema MOCAP (Motion Capture).

Descripción de los términos:

- **N = 96**: Es el número de iteraciones o secuencias de movimiento. En este caso, se tiene 16 atletas que ejecutan 6 movimientos cada uno, lo que da un total de 96 secuencias o iteraciones.
- **T = 23**: Representa el número de articulaciones o "Joint" en el cuerpo capturadas en los archivos BVH de los atletas. Las articulaciones pueden incluir caderas, rodillas, tobillos, hombros, codos, muñecas, etc.
- **69 = 23 * 3**: El valor 69 proviene del número total de coordenadas espaciales necesarias para describir las posiciones de 23 articulaciones en 3 dimensiones (X, Y, Z).

Estructura de los datos:

- Cada secuencia o iteración es una matriz bidimensional de tamaño (23, 3), donde cada fila representa las coordenadas 3D de una articulación en un fotograma específico.
- Cuando haces la normalización y el procesamiento, reorganizas los datos en una forma **(N, T, 69),** que es la estructura que te permite trabajar con las secuencias de movimiento en cada iteración de forma efectiva.

Importancia de tener la estructura (N, T, 69).

- **Análisis biomecánico**: Tener los datos estructurados como (N, T, 69) te permite analizar cómo varían las posiciones de las articulaciones en cada fotograma para cada atleta y comparar las secuencias de movimiento.
- **Clasificación y Modelos de Aprendizaje Automático**: Esta estructura es adecuada para alimentar modelos de aprendizaje automático, donde se

pueden aplicar algoritmos como redes neuronales o técnicas de clustering para analizar patrones y diferencias entre atletas, tipos de movimientos, etc.

- **Comparación entre atletas**: Puedes hacer comparaciones más claras entre los movimientos de diferentes atletas y detectar patrones biomecánicos o anomalías.

En resumen, la normalización de las posiciones con respecto a las caderas es importante para analizar el movimiento de los atletas de manera coherente y comparativa. La estructura (96, 23, 69) refleja un dataset diseñado para capturar secuencias tridimensionales de movimiento de los atletas en detalle.

5.2 CLÚSTER.

Se realiza un proceso de agrupamiento (clustering) de datos MOCAP durante una jugada de tenis, utilizando técnicas como KMEANS [60] o clustering espectral que son especiales para agrupar fotogramas (FRAMES) de un video que representan distintas posiciones durante un movimiento de tenis. La idea es identificar patrones comunes entre estas posiciones para diferenciar entre jugadores expertos y amateurs. Estas técnicas permiten encontrar centros de clústeres que representan posiciones corporales típicas o comunes durante una secuencia de movimientos. Estos centros de clústeres se pueden interpretar como las "poses clave" que definen la calidad del movimiento.

La elección de KMEANS se basa en su eficiencia y simplicidad, especialmente cuando se trabaja con un número grande de datos como FRAMES de video. Además, KMEANS es particularmente útil cuando los clústeres tienen forma esférica o compacta en el espacio de características, lo cual es una suposición razonable para los datos de posiciones del cuerpo en un espacio vectorial de características.

En el proceso de clustering, cada punto de datos se asigna al clúster cuyo centroide esté más cercano, utilizando como medida la distancia euclidiana [61] es una medida geométrica que calcula la longitud de una línea recta entre dos puntos en un espacio multidimensional.

En términos matemáticos, para dos puntos p = (p_1, p_2, …, p_n) y q = (q_1, q_2, …, q_n) en un espacio de n-dimensiones, la distancia euclidiana se define como:

$$D_{(p,q)} = \sqrt{\{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \ldots + (p_n - q_n)^2\}}$$

La distancia euclidiana es fundamental en el proceso de clustering, ya que KMEANS busca minimizar la distancia total entre los puntos de datos y los centroides de los clústeres a los que se asignan. Cada punto se asocia al centroide más cercano, y a medida que el algoritmo avanza, los centroides se recalculan iterativamente como la media de los puntos asignados a cada clúster. Esto reduce progresivamente la varianza dentro de los clústeres, ya que el objetivo del algoritmo es minimizar la suma de las distancias cuadradas entre los puntos de datos y los centroides.

La distancia euclidiana interviene en cada iteración para determinar cómo deben reagruparse los puntos. A medida que aumentan las dimensiones, las distancias entre puntos se vuelven más homogéneas, lo que puede dificultar la capacidad del algoritmo para distinguir adecuadamente los clústeres. En estos casos, podrían considerarse otras métricas de distancia, como la distancia coseno o Mahalanobis, dependiendo de las características de los datos.

El (siguiente enlace) muestra el código de Python en la (celda No 23) del libro de Google COLAB donde en primera instancia se inicializa el cronómetro para medir el tiempo de ejecución del proceso de clustering y se registra el tiempo actual para poder calcular la diferencia como se muestra en la siguiente Figura 9.

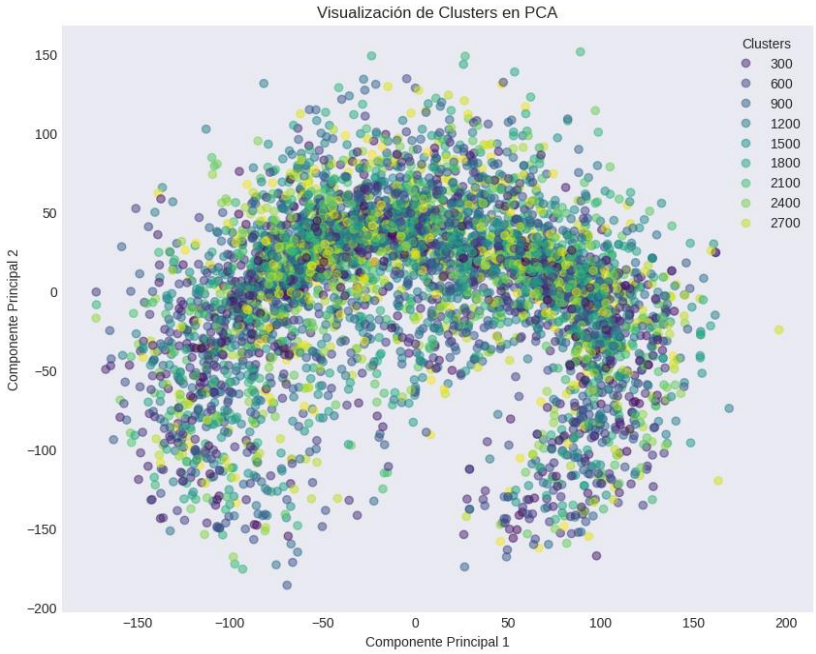

Figura 9. Resultado clúster (fuente propia).

La Figura 9. muestra una visualización de clústeres obtenidos mediante KMEANS aplicados a datos de captura de movimiento (MOCAP), utilizando PCA para reducir la dimensionalidad. Los ejes representan las dos principales componentes, facilitando el análisis visual. Los clústeres, identificados por diferentes colores, **no muestran una clara separación**, lo que sugiere que los movimientos de los atletas pueden ser similares entre grupos o que hay un solapamiento considerable entre los diferentes tipos de golpes como derecha, revés y servicio. La amplia dispersión de puntos indica una alta variabilidad en la ejecución de los movimientos entre los atletas.

Esta variabilidad podría reflejar diferencias en la técnica de ejecución de los mismos golpes, lo cual es relevante para el análisis de experticia deportiva. La falta de una separación clara entre clústeres sugiere la complejidad intrínseca de los movimientos, posiblemente debido a características biomecánicas complejas que

no se agrupan fácilmente. Los siguientes pasos deberían enfocarse en un análisis más detallado para identificar las características específicas que influyen en la agrupación, con el objetivo de mejorar la comprensión de los patrones en los datos de MOCAP.

Interpretación de los Resultados

1. **Centroides de Clústeres**: Los números en cada fila representan las coordenadas de los centroides después de aplicar el algoritmo K-MEANS. Cada centroide se interpreta como el "centro" de un grupo de puntos de datos que se encuentran más cercanos entre sí en el espacio multidimensional. Este centroide actúa como un representante del clúster al que pertenece.

2. **Agrupación de Movimientos Similares**: La presencia de diferentes centroides sugiere que el algoritmo K-MEANS ha identificado distintos grupos en los datos. En el contexto de análisis de movimientos de tenis, esto puede indicar diferentes tipos de movimientos o fases dentro de un mismo movimiento que son similares entre sí. Por ejemplo, un grupo podría representar todos los momentos del golpe de derecha, mientras que otro podría corresponder a los movimientos de servicio.

3. **Dimensiones Altamente Variables**: Las variaciones significativas en los valores de las coordenadas (por ejemplo, de valores positivos a negativos) reflejan la complejidad de los movimientos de tenis. Algunas dimensiones tienen valores más dispersos que otras, lo que indica que esas características tienen una mayor variabilidad en el conjunto de datos.

4. **Potencial Identificación de Patrones de Movimiento**: Los centroides con valores similares en múltiples dimensiones pueden indicar patrones comunes en los movimientos de los jugadores. Por ejemplo, un centroide con coordenadas similares podría indicar que ciertos movimientos del tenis, como un golpe de derecha y un remate, tienen elementos técnicos similares que los agrupan en el mismo clúster.

5. **Aplicación en Mejoras de Entrenamiento**: Este análisis es crucial para los entrenadores y analistas, ya que permite identificar qué movimientos son técnicamente similares y cuáles difieren, ayudando a ajustar estrategias de entrenamiento personalizadas para cada jugador. Por ejemplo, si se observa que ciertos movimientos (representados por clústeres específicos) están asociados con errores o menos eficiencia, se puede trabajar en esos movimientos específicos para mejorar en el atleta.

El clustering con K-MEANS aplicado a los datos de MOCAP ha permitido una clasificación efectiva de los movimientos de tenis, facilitando la identificación de patrones de comportamiento y similitudes entre los diferentes tipos de movimientos.

Análisis de componente principales (PCA):

El Análisis de Componentes Principales (PCA) es una técnica de reducción de dimensionalidad que transforma un conjunto de variables posiblemente correlacionadas en un conjunto de variables linealmente no correlacionadas, denominadas componentes principales.

Esta transformación ortogonal permite reducir la complejidad del dataset mientras se retiene la mayor parte de la variabilidad de los datos. En el contexto de la captura de movimiento (MOCAP), PCA se aplica para simplificar los datos de movimientos capturados, focalizándose en las dos dimensiones más representativas. Se seleccionan los vectores propios correspondientes a los valores propios más grandes, que representan las direcciones de mayor varianza.

A continuación, en la (celda No.26) de nuestro libro de Google COLAB se muestra cómo aplicar PCA para visualizar datos de movimiento. El resultado se expone en la Figura 10.

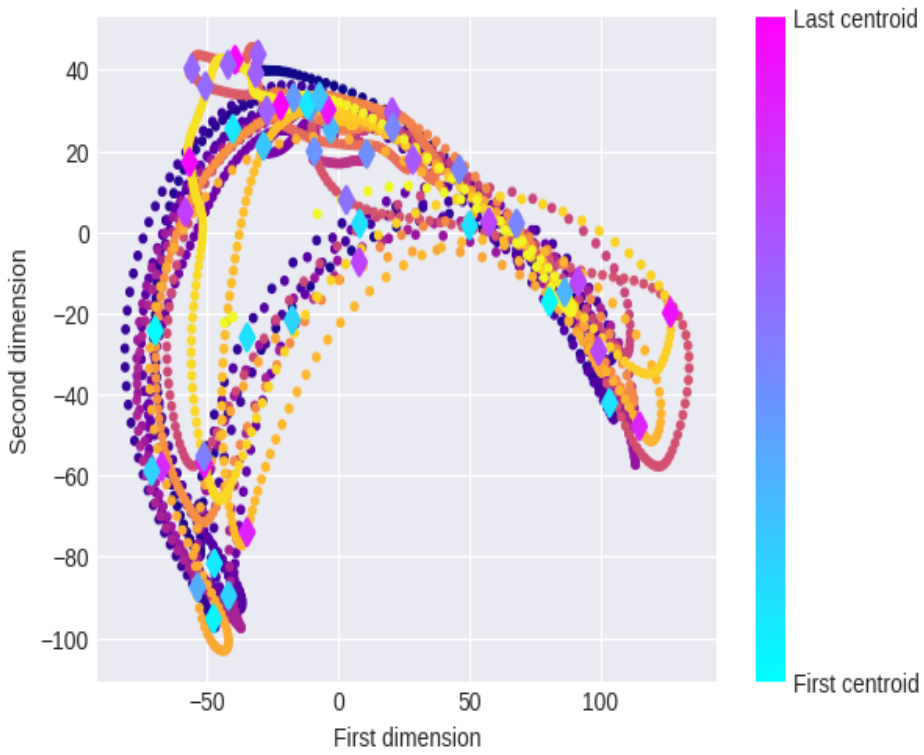

Figura 10. Visualización PCA (fuente propia).

Como se muestra en la Figura 10. cada punto representa una muestra individual de los datos de MOCAP correspondientes a diferentes tipos de movimientos de tenis, como golpes de derecha, remates, o servicios. Los puntos están coloreados para reflejar diferentes centroides, que podrían representar diferentes clases de movimientos o momentos específicos dentro de la secuencia de cada movimiento.

Los centroides marcados en la visualización indican puntos de agrupamiento de los datos. La trayectoria entre los puntos y los centroides podría sugerir la transición o evolución de los movimientos de los jugadores de tenis a lo largo del tiempo o durante diferentes fases del golpeo. Además, el color del punto en el mapa varía desde púrpura hasta amarillo, lo que podría representar diferentes fases del movimiento o la cantidad de datos acumulados en esas posiciones específicas.

La dispersión y la forma de los puntos sugieren que hay una cierta estructura o patrón en los movimientos, con algunas regiones más densas, lo que indica movimientos repetitivos o posiciones comunes y otras más dispersas indicando variabilidad en el movimiento.

En términos prácticos, la visualización del PCA ayuda a identificar las características clave de los movimientos de tenis capturados, resalta las similitudes y diferencias en los patrones de movimiento, y puede ser utilizada para clasificar y analizar la eficiencia o estilo de los jugadores de tenis basándose en sus datos de MOCAP.

Esta interpretación de los datos de PCA también podría ser útil para mejorar los algoritmos de clasificación que se utilizan en los análisis posteriores, como el aprendizaje supervisado, para diferenciar entre diferentes tipos de movimientos o mejorar las técnicas de entrenamiento deportivo.

5.3 Matriz de disimilitudes:

En la (celda No. 34) de nuestro libro de Google COLAB se muestra la creación y visualización de una matriz de disimilitud para datos de captura de movimiento. Para esto se sigue una serie de pasos que lleva la organización del desarrollo hasta llegar a la visualización de la matriz.

Para la construcción de esta matriz, el código recorre diferentes carpetas de datos, donde cada carpeta contiene las secuencias de movimientos para cada atleta. Estas secuencias de movimiento se procesan y agrupan en la variable Xa, la cual contiene las características de posición que fueron previamente extraídas utilizando técnicas de análisis como PCA (Análisis de Componentes Principales) y KMEANS. Las distancias entre estas secuencias de movimiento se calculan utilizando la función pairwise_distances [61], que mide la diferencia entre todas las secuencias y crea la matriz de disimilitud. Este cálculo proporciona una visión global sobre cómo se comparan entre sí los diferentes movimientos realizados por los atletas. A continuación, se muestra el mapa de calor para la Figura 11.

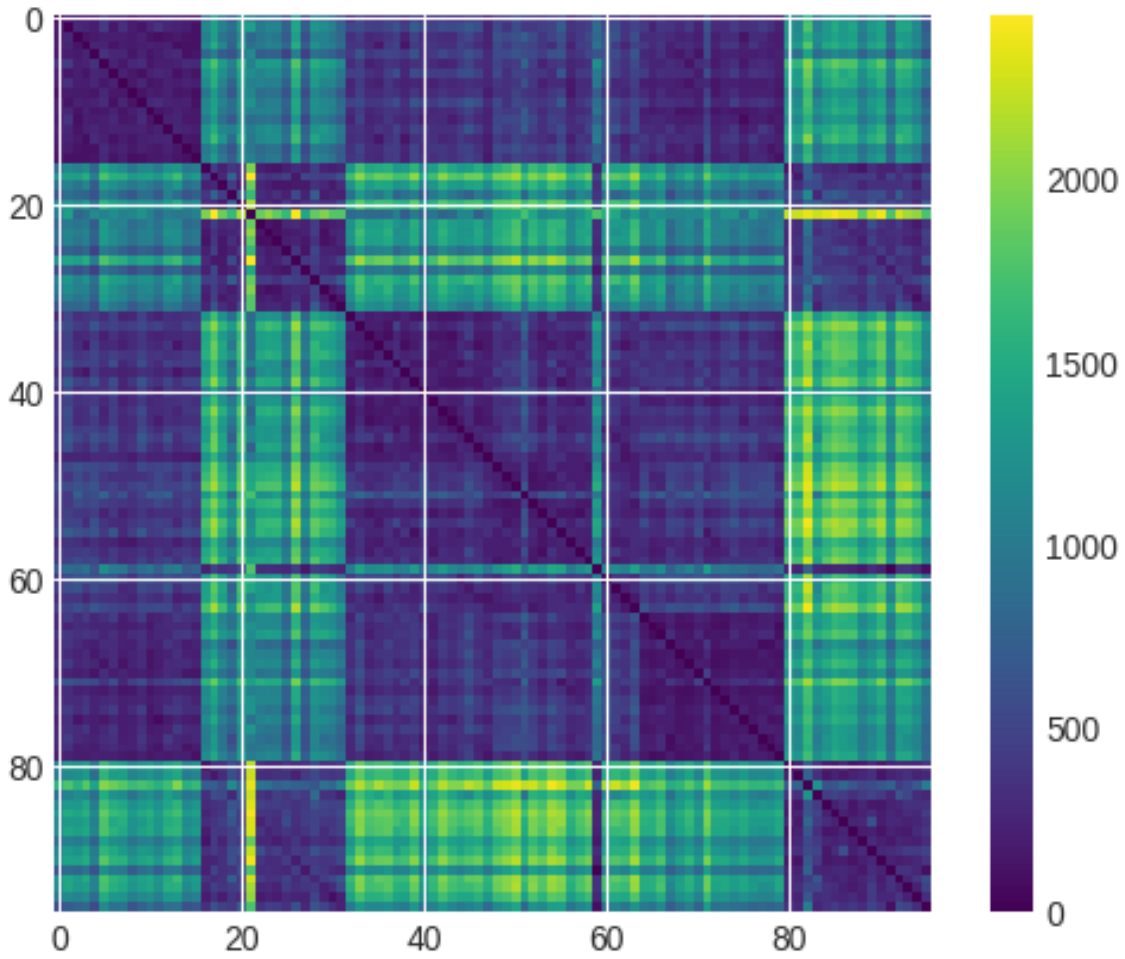

Figura 11. Matriz de disimilitud (fuente propia).

En la Figura 11. Se cuantifica las diferencias entre distintas secuencias de movimiento realizadas por los atletas. En este caso, se ha utilizado un mapa de colores que va desde los tonos más oscuros, que indican baja disimilitud (alta similitud), hasta los tonos más claros y brillantes, que indican mayor disimilitud (baja similitud) entre las secuencias de movimiento. Cada celda en la matriz representa la distancia o disimilitud entre dos secuencias de movimiento en el conjunto de datos. Esta matriz tiene aplicaciones clave en el análisis y la clasificación de secuencias de datos de movimiento.

observando las regiones de color claro y oscuro. Las áreas cercanas a la diagonal principal, que suelen ser más oscuras, indican que las secuencias de movimiento dentro del mismo grupo o tipo de movimiento son similares entre sí. Mientras tanto, las áreas más alejadas de la diagonal y de colores más brillantes sugieren que los movimientos pertenecientes a diferentes clases de actividad (por ejemplo, "Derecha" frente a "Remate") son más diferentes entre sí, es decir, tienen una mayor disimilitud. Esto se debe a que el cálculo de disimilitud cuantifica el grado en el cual las características posicionales difieren entre las distintas clases de movimiento.

Las áreas que presentan colores intermedios en la matriz de disimilitud indican una disimilitud moderada entre las secuencias de movimiento. Esto sugiere que algunos movimientos comparten características similares, pero no idénticas. Por ejemplo, "Derecha" y "VDerecha" podrían estar más cercanos entre sí en comparación con "Revés" y "Servicio", lo cual se reflejaría en la matriz con tonos más suaves en esas intersecciones. Este tipo de análisis permite identificar patrones en los datos que ayudan a distinguir qué movimientos son más similares entre sí, y qué movimientos son claramente diferentes.

5.4 TSNE

En la (celda No. 35) del libro de Google Colab se implementa la técnica t-SNE (t-distributed Stochastic Neighbor Embedding) para reducir la dimensionalidad de datos de movimientos (MOCAP), representados por una matriz de distancias precomputada D, que es utilizada como entrada al modelo t-SNE.

La técnica proyecta los datos en un espacio bidimensional para visualizar las similitudes y diferencias entre distintos movimientos. Los movimientos están codificados en una lista labels, que se mapea a nombres específicos:

- Derecha – Folder 01
- Remate – Folder 02
- Revés – Folder 03
- Servicio – Folder 04
- VDerecha – Folder 05
- VRevés – Folder 06

Mediante el diccionario label_map. Se realizan múltiples visualizaciones t-SNE ajustando el parámetro de "perplexity" para explorar cómo afecta a la agrupación de los datos.

El bucle prueba tres valores de perplexity: 5, 50 y 95. Cada ejecución genera una proyección t-SNE, donde los datos se agrupan visualmente en la Figura 12. según su semejanza. Luego, los puntos resultantes se colorean según el tipo de movimiento, y se genera una leyenda que asocia cada color con un movimiento específico. El resultado se guarda en archivos PDF para su posterior análisis.

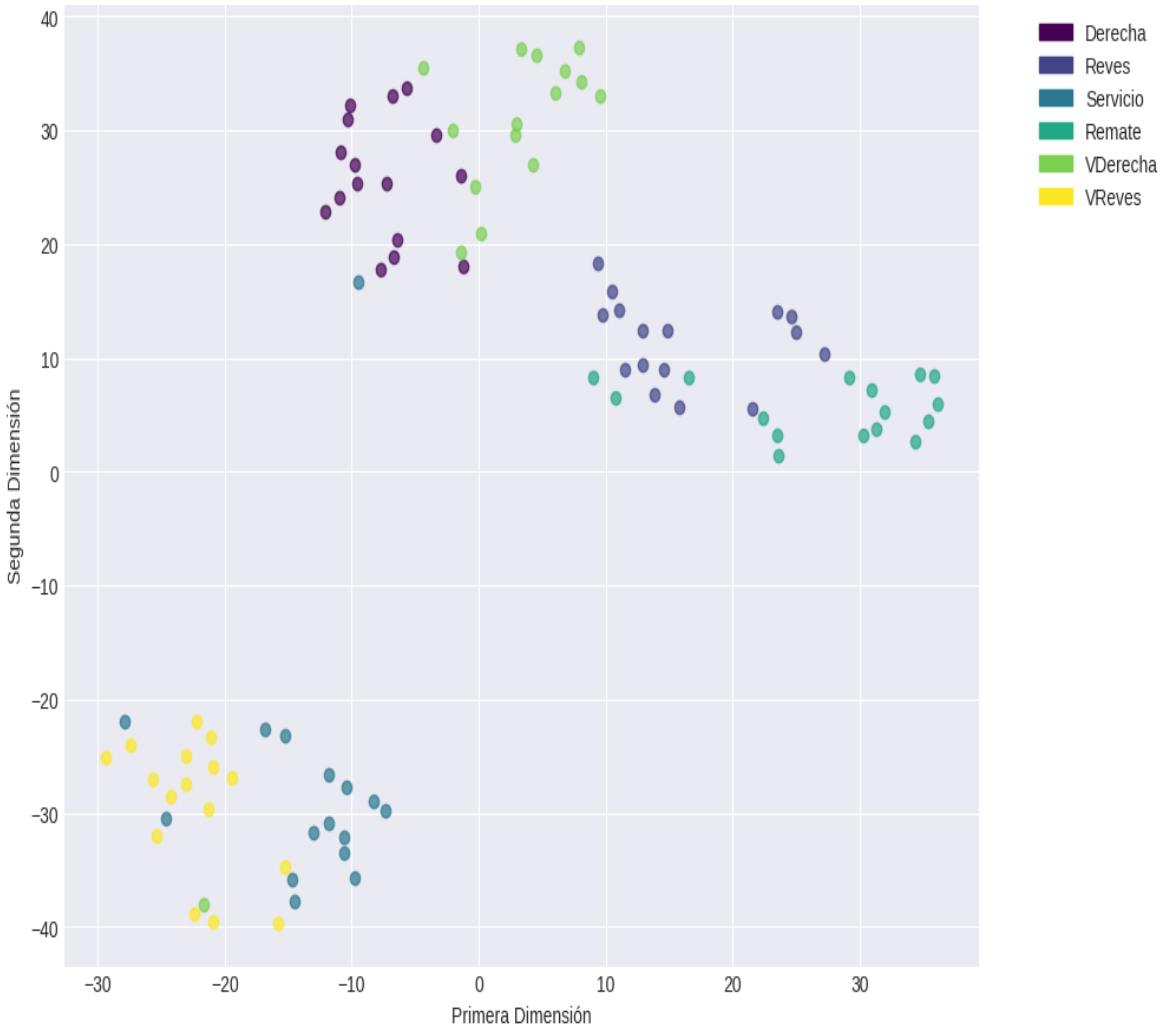

Figura 12. Visualización TSNE (fuente propia).

En la Figura 12. Se muestra una representación bidimensional de los datos de movimientos generada por t-SNE con una "perplexity" de 5. Cada punto en la gráfica representa una secuencia de movimiento y está coloreado según el tipo de movimiento al que pertenece (Derecha, Revés, Servicio, etc.).

Los diferentes colores permiten visualizar cómo los movimientos similares tienden a agruparse. Por ejemplo, los movimientos de VReves y VDerecha (en amarillo y azul claro) se agrupan claramente en la parte inferior izquierda, mientras que Derecha y Revés (morado y azul oscuro) se agrupan en la parte superior central. Esto indica que estos movimientos tienen características comunes que t-SNE ha capturado, mostrando su proximidad en el espacio de menor dimensionalidad.

5.6 Selección del Modelo

El aprendizaje automático se ha convertido en una herramienta fundamental en la ciencia de datos, brindando soluciones avanzadas para analizar grandes volúmenes de información. En el contexto deportivo, su aplicación ha permitido transformar la manera en que se evalúa y optimiza el rendimiento de los atletas.

En este proyecto, después de un extenso preprocesamiento de datos de captura de movimiento (MOCAP) y la implementación de técnicas de reducción de dimensionalidad como PCA (Análisis de Componentes Principales) y algoritmos de agrupamiento como KMEANS, hemos llegado a la etapa final: la clasificación automatizada. Esta última fase es clave, ya que nos permitirá convertir los datos preprocesados y estructurados en predicciones precisas que clasifican los movimientos de los atletas según su tipo y técnica.

El uso de técnicas como PCA y KMEANS en las fases anteriores fue crucial para limpiar, reducir la complejidad de los datos y encontrar patrones relevantes en los movimientos. PCA permitió reducir la dimensionalidad del conjunto de datos MOCAP, facilitando la identificación de las características más importantes sin perder información crítica sobre la biomecánica del atleta. KMEANS, por su parte, ayudó a agrupar movimientos similares, permitiendo una visión más clara de cómo ciertos tipos de golpes o acciones se relacionan entre sí.

Sin embargo, estas técnicas solo nos proporcionaron una visión preliminar del comportamiento de los datos, siendo necesarias para preparar el terreno para el siguiente paso: la clasificación supervisada. En este punto, podemos aprovechar los patrones identificados para entrenar modelos de aprendizaje automático que realicen predicciones específicas.

Es aquí donde entra en juego el uso de algoritmos de clasificación como Support Vector Machines (SVM) [62], Random Forest [63], K-Nearest Neighbors (KNN) [64] y Redes Neuronales [65]. Estas técnicas permiten que, a partir de los datos preprocesados, se puedan clasificar los movimientos MOCAP en diferentes categorías, como golpes de derecha, servicios y remates.

La selección del modelo adecuado es crítica, y en este proyecto, SVM ha sido elegido el modelo base de implementación. Esta fase de clasificación representa la culminación del proceso analítico, ya que ahora podemos entrenar modelos que identificarán automáticamente los movimientos de los atletas, permitiendo el análisis técnico deportivo.

5.6.1 **Support Vector Machines (SVM)**.

Este algoritmo es una de las opciones más potentes para la clasificación de datos MOCAP en nuestro proyecto. SVM funciona encontrando el hiperplano óptimo que separa distintas clases en un espacio multidimensional, lo que lo hace ideal para diferenciar movimientos como el golpe de derecha, revés, servicio y remate en los datos obtenidos de los 16 jugadores de la liga de tenis caldense.

Al tratarse de un problema no lineal, SVM es particularmente efectivo, ya que utiliza espacios de Hilbert para transformar los datos originales a un espacio de mayor dimensión donde las clases se pueden separar de manera más clara. La ventaja clave de SVM en este contexto es su capacidad para manejar datos complejos con características biomecánicas, como las posiciones y movimientos de las articulaciones. Sin embargo, este algoritmo puede ser computacionalmente intensivo, especialmente con grandes volúmenes de datos MOCAP, lo que podría alargar el tiempo de procesamiento. A pesar de esto, su precisión en la clasificación hace que valga la pena considerarlo como el modelo base para nuestro proyecto. En la (celda No. 36) del libro de Google COLAB, se muestra como aplicamos SVM.

El modelo SVM fue implementado utilizando un **pipeline** con las siguientes etapas:

- **Estandarización de los datos**: Se aplicó StandardScaler para normalizar los datos de entrada, asegurando que todas las características tuvieran una media de 0 y una desviación estándar de 1. Esto es crucial para los modelos basados en SVM, ya que son sensibles a la escala de las características.

- **Clasificador SVM con kernel RBF**: El SVM se configuró con un kernel radial (RBF), adecuado para problemas no lineales como el análisis de datos de movimiento.

- **Optimización de hiperparámetros**: Se usó GridSearchCV para buscar la mejor combinación de los hiperparámetros **C** (que controla la penalización de errores) y **gamma** (que determina la influencia de cada muestra en el modelo).

Se definieron los siguientes parámetros para ajustar el modelo:

- **C**: [1, 10, 100, 1000, 10000] Este parámetro regula la compensación entre maximizar el margen del hiperplano y minimizar el error de clasificación en los datos de entrenamiento.

- **gamma**: [0.01, 0.1, 1, 100, 1000] Controla el alcance de la influencia de una muestra de entrenamiento. Valores altos de gamma generan curvas más complejas que pueden sobre ajustarse, mientras que valores bajos pueden resultar en un modelo más simple.

5.6.2 **Random Forest**.

Random Forest es un algoritmo de aprendizaje supervisado que emplea un enfoque basado en múltiples árboles de decisión para realizar la clasificación final mediante un sistema de votación. En el contexto de los datos de movimiento MOCAP, Random Forest es una herramienta poderosa debido a su capacidad para manejar datos ruidosos y variaciones inherentes en las repeticiones de movimientos entre jugadores.

En el caso de los movimientos como el servicio, el revés o el remate, que pueden diferir ligeramente en su ejecución, Random Forest utiliza su estructura de múltiples árboles para promediar estas diferencias y ofrecer una clasificación robusta. Además, este modelo permite identificar la importancia relativa de las características, lo que puede ser clave para determinar qué articulaciones o segmentos del cuerpo son más relevantes en la ejecución de cada tipo de golpe.

Aunque Random Forest es más rápido que SVM en términos de tiempo de entrenamiento, el uso de grandes conjuntos de árboles puede aumentar los requerimientos de memoria y procesamiento, especialmente con datos de alta dimensionalidad como los obtenidos en los análisis MOCAP.

En la (celda No. 47) de tu libro de Google Colab, se detalla cómo implementamos el modelo Random Forest:

La implementación de Random Forest se realizó utilizando un pipeline con las siguientes etapas:

1. **Clasificador Random Forest**:
    - Utilizamos el clasificador RandomForestClassifier de scikit-learn, el cual combina múltiples árboles de decisión entrenados en diferentes subconjuntos de datos para mejorar la precisión y reducir el riesgo de sobreajuste.
2. **Optimización de Hiperparámetros**:
    - Para encontrar los mejores parámetros del modelo, se utilizó GridSearchCV con validación cruzada de 5 particiones. Esto permitió evaluar múltiples combinaciones de hiperparámetros.

Se definieron los siguientes parámetros para ajustar el modelo:

- **Número de árboles en el bosque (n_estimators)**: [50, 100, 200] Este parámetro controla cuántos árboles se crean en el modelo. Más árboles generalmente mejoran la precisión, pero aumentan el costo computacional.
- **Profundidad máxima de los árboles (max_depth)**: [None, 10, 20, 30] Este parámetro limita la profundidad de cada árbol. Árboles muy profundos

pueden sobre ajustarse, mientras que árboles poco profundos podrían no capturar suficientes patrones en los datos.

- **Mínimo número de muestras para dividir un nodo (min_samples_split)**: [2, 5, 10] Esto controla cuántas muestras deben estar presentes en un nodo antes de dividirlo en dos.

- **Mínimo número de muestras en una hoja (min_samples_leaf)**: [1, 2, 4] Este parámetro asegura que cada hoja final de un árbol tenga al menos este número de muestras, reduciendo la complejidad del modelo.

- **Uso de muestreo bootstrap (bootstrap)**: [True, False] Este parámetro define si los árboles se entrenan con diferentes subconjuntos de datos utilizando bootstrap (muestreo con reemplazo).

Ventajas:

- Maneja datos ruidosos y variaciones entre repeticiones.
- Permite identificar características relevantes para la clasificación.
- Es menos sensible a los valores atípicos y al sobreajuste debido a su enfoque de promediado.

Limitaciones:

- Puede consumir más memoria y tiempo de procesamiento al trabajar con muchos árboles y datos de alta dimensionalidad.
- Su capacidad de generalización puede verse afectada si no se ajustan correctamente los hiperparámetros.

5.6.3 **K-Nearest Neighbors (KNN)**.

En el contexto de nuestro proyecto, KNN es una técnica de clasificación que se basa en la cercanía de los movimientos capturados. Es decir, para clasificar un nuevo golpe de tenis (como el de derecha o el servicio), el algoritmo busca los golpes más cercanos en el conjunto de datos y toma su decisión en función de la mayoría.

La simplicidad de KNN lo hace fácil de implementar, pero también presenta desafíos, especialmente con los datos MOCAP, ya que puede ser muy sensible a la escala de los datos, como las diferentes longitudes o velocidades en los golpes. Además, dado que KNN no requiere un entrenamiento formal previo, puede adaptarse rápidamente a datos nuevos.

Sin embargo, el tiempo de predicción tiende a ser mayor que el de otros algoritmos, ya que se necesita comparar cada nuevo dato con todos los ejemplos existentes, lo que puede ser un problema cuando se clasifica en tiempo real grandes volúmenes

de datos MOCAP. En la (celda No. 52) del libro de Google COLAB, se muestra como aplicamos KNN.

Se definieron los siguientes hiperparámetros para ajustar el modelo KNN:

- **Número de vecinos (n_neighbors)**: [3, 5, 7, 9] Este parámetro controla la cantidad de vecinos a considerar para la clasificación. Más vecinos suavizan las decisiones, mientras que menos vecinos pueden hacer el modelo más sensible a ruidos.

- **Pesos de los vecinos (weights)**: ['uniform', 'distance']

    - uniform: Todos los vecinos tienen el mismo peso en la clasificación.

    - distance: Vecinos más cercanos tienen mayor influencia en la predicción.

- **Métrica de distancia (p)**: [1, 2]

    - 1: Utiliza la distancia de Manhattan (suma de diferencias absolutas).

    - 2: Utiliza la distancia Euclidiana (distancia raíz cuadrada).

Ventajas:

- **Simplicidad**: KNN es fácil de implementar y comprender, ya que no requiere un proceso de entrenamiento formal.

- **Adaptabilidad**: Es dinámico, lo que significa que puede ajustarse rápidamente a nuevos datos sin necesidad de reentrenar el modelo completo.

- **Efectividad en datos bien distribuidos**: Si los movimientos tienen patrones claros en el espacio de características, KNN puede proporcionar buenos resultados.

Limitaciones:

- **Escalabilidad**: Puede ser computacionalmente intensivo para grandes volúmenes de datos MOCAP, ya que evalúa todas las distancias para cada predicción.

- **Sensibilidad a la escala de los datos**: Diferencias en las longitudes, velocidades o amplitudes de los golpes pueden influir significativamente en las predicciones, por lo que la normalización es crucial.

- **Sensibilidad al ruido**: Datos ruidosos o atípicos pueden afectar la clasificación.

5.6.4 **Redes Neuronales**.

Las Redes Neuronales Artificiales (ANN), como el Perceptrón Multicapa (MLP), son herramientas altamente efectivas para identificar patrones complejos en grandes conjuntos de datos. En el contexto de nuestro proyecto, estas redes pueden capturar las sutiles diferencias biomecánicas entre los movimientos de los jugadores, como la inclinación del cuerpo, la rotación de la muñeca o la velocidad relativa de las extremidades.

Ventajas y Limitaciones en el Análisis de Datos MOCAP

1. **Ventajas**:
    - **Aprendizaje jerárquico**: Las primeras capas de la red pueden identificar características básicas (posición de articulaciones), mientras que las capas más profundas detectan patrones más abstractos (fluidez y coordinación del movimiento).
    - **Flexibilidad**: Las redes neuronales pueden ajustarse para manejar tanto datos lineales como no lineales.
    - **Capacidad para grandes volúmenes de datos**: Son ideales para trabajar con datos de alta dimensionalidad, como los obtenidos en MOCAP.
2. **Limitaciones**:
    - **Costo computacional**: Entrenar redes neuronales requiere mayor poder de procesamiento y tiempo que otros algoritmos, como KNN o SVM.
    - **Requiere preprocesamiento adecuado**: Es necesario escalar y normalizar los datos para garantizar una convergencia eficiente durante el entrenamiento.
    - **Riesgo de sobreajuste**: Sin una regularización adecuada, pueden aprender patrones específicos de los datos de entrenamiento en lugar de generalizar.

Implementación de Redes Neuronales

En la (celda No. 57) de tu libro de Google Colab, implementamos un clasificador MLP utilizando un pipeline que incluye la estandarización de datos y la búsqueda de hiperparámetros con GridSearchCV.

Configuración de la Red Neuronal

El modelo de red neuronal está diseñado con la siguiente configuración:

1. **Capas ocultas (hidden_layer_sizes)**:
    - [(50,), (100,), (100, 50)]:
        - Una configuración con una sola capa de 50 o 100 neuronas.
        - Otra configuración con dos capas: una con 100 neuronas seguida de otra con 50.
          La elección de estas configuraciones busca un equilibrio entre la capacidad de aprender patrones complejos y evitar sobreajuste.
2. **Funciones de activación (activation)**:
    - tanh: Permite modelar relaciones complejas, ya que es adecuada para datos centrados en 0.
    - relu: Ideal para problemas de alta dimensionalidad, ya que mejora la convergencia durante el entrenamiento.
3. **Optimizadores (solver)**:
    - adam: Algoritmo eficiente que combina adaptabilidad y velocidad en problemas con grandes volúmenes de datos.
    - sgd: Descenso de gradiente estocástico, que puede ser más lento, pero es útil en datos con mucho ruido.
4. **Regularización (alpha)**:
    - [0.0001, 0.001, 0.01]:
        - Este parámetro controla la regularización L2 para evitar sobreajuste. Valores más altos penalizan redes más complejas.
5. **Tasa de aprendizaje inicial (learning_rate_init)**:
    - [0.001, 0.01]:
        - Controla la velocidad a la que el modelo ajusta los pesos. Se probaron valores estándar para asegurar estabilidad y rapidez en la convergencia.

6. VALIDACIÓN Y ENTRENAMIENTO

6.2 Entrenamiento del Modelo.

Una vez seleccionado el modelo de clasificación, el siguiente paso es el proceso de entrenamiento. En esta fase, se emplea un conjunto de datos etiquetado para que el modelo aprenda a identificar patrones y características relevantes en los movimientos capturados.

Durante el entrenamiento, el modelo ajusta sus parámetros internos con el objetivo de minimizar el error en sus predicciones. En el caso de SVM y otros algoritmos utilizados, el proceso consiste en encontrar el mejor margen de separación entre las distintas clases de movimientos, permitiendo así clasificar nuevos datos con precisión.

En la celda No.38 del cuaderno de Google Colab, se muestra el proceso de entrenamiento y validación del modelo. Para garantizar un ajuste óptimo, se emplea el método de validación cruzada (*cross-validation*) [66], que permite evaluar el rendimiento del modelo en diferentes particiones de los datos y seleccionar los mejores hiperparámetros en función de su desempeño. En este caso, se utiliza la métrica de precisión (*accuracy*) [67] como medida de evaluación del desempeño del clasificador.

División de los Datos

El procedimiento de validación cruzada aplicado en este trabajo se basa en *StratifiedShuffleSplit* [68], que divide los datos en múltiples iteraciones asegurando que cada conjunto de entrenamiento y prueba contenga una representación balanceada de todas las clases. Para cada iteración:

- **80% de los datos se destinan al entrenamiento**
- **20% de los datos se utilizan para la validación**

La distribución de estos datos se realizó sobre el conjunto de secuencias esqueléticas generadas a partir de los videos. Inicialmente, todos los videos fueron procesados para extraer los datos de movimiento, los cuales fueron posteriormente sometidos a técnicas de reducción de dimensionalidad como PCA y agrupamiento mediante clustering. La estructura resultante de los datos es:

- **Xa shape**: (96, 50, 69) → Representación de las secuencias de movimiento.
- **Dx shape**: (50, 50) → Matriz de disimilitud entre las muestras.
- **Z shape**: (3000, 69) → Datos transformados en un espacio latente de menor dimensión.
- **Sigx shape**: (96,) → Valores de dispersión asociados a cada muestra.

- **Sigma_x, Sigma_y**: 135.42 → Parámetros de dispersión en los ejes X e Y.

Este enfoque permite evaluar el modelo en múltiples subconjuntos de datos, proporcionando una medida más robusta del rendimiento promedio del clasificador.

Optimización de Hiperparámetros

Además de la validación cruzada, se emplea una búsqueda en cuadrícula (*GridSearchCV*) [69], para explorar distintas combinaciones de hiperparámetros y seleccionar la configuración que maximice la precisión del modelo. Esta optimización es fundamental para mejorar la capacidad generalizadora del clasificador y evitar problemas como el sobreajuste (*overfitting*) [70].

Para medir el rendimiento del modelo, se utiliza la métrica de precisión, que representa el porcentaje de predicciones correctas sobre el total de predicciones realizadas. No obstante, para obtener una evaluación más detallada, se emplea también la matriz de confusión [71]. Esta matriz permite analizar el comportamiento del clasificador en cada clase, identificando tanto los aciertos como los errores de clasificación. Finalmente, los resultados de las matrices de confusión y las precisiones obtenidas en todas las iteraciones se promedian para obtener una evaluación más confiable del desempeño del modelo.

6.3 Resultados de los Modelos.

- **SVM**

- **Accuracy promedio**: (acc = 87.5 ± 6.8%) Esto indica que el modelo clasifica correctamente el 87.5% de las instancias en promedio, con una desviación estándar del 6.8%. Esto es un rendimiento sólido, especialmente considerando la complejidad de los datos biomecánicos MOCAP.

- **Matriz de confusión**:

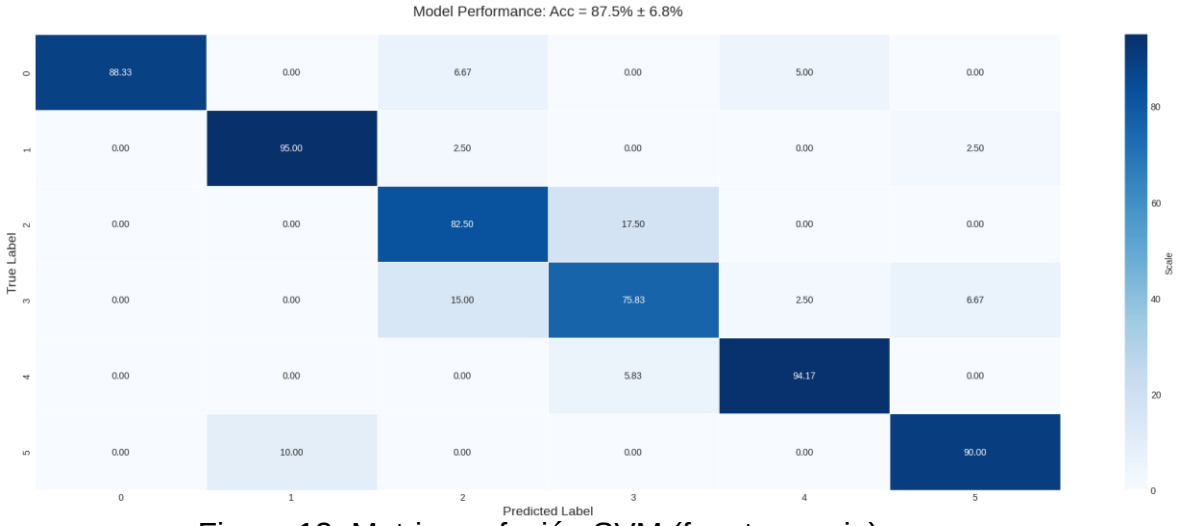

Figura 13. Matriz confusión SVM (fuente propia).

La Figura 13 muestra los valores en la diagonal principal, resaltados con colores oscuros que indican las clasificaciones correctas, mientras que los valores fuera de la diagonal reflejan errores de clasificación. Por ejemplo, el modelo clasifica correctamente el 88.33% de los ejemplos de la clase 0, el 95.00% de la clase 1, y así sucesivamente, mientras que en algunos casos confunde ejemplos de la clase 0 con la clase 2 (6.67%) y la clase 3 (5%). Esta confusión puede deberse a la similitud en las características de las clases involucradas. Un patrón destacado es la agrupación de confusiones entre las clases 2 y 3, donde un 17.50% de los ejemplos de la clase 2 se clasifican erróneamente como clase 3. Esto podría indicar que estas clases comparten características similares, dificultando la diferenciación por parte del modelo. Este comportamiento sugiere la necesidad de explorar más a fondo las características de estas clases, ya sea mediante técnicas de reducción de dimensionalidad como PCA o t-SNE, o ajustando el modelo para optimizar su capacidad de distinguir estas categorías. A pesar de estas limitaciones, el desempeño general del modelo es sólido y adecuado para la tarea propuesta.

➢ RANDOM FOREST

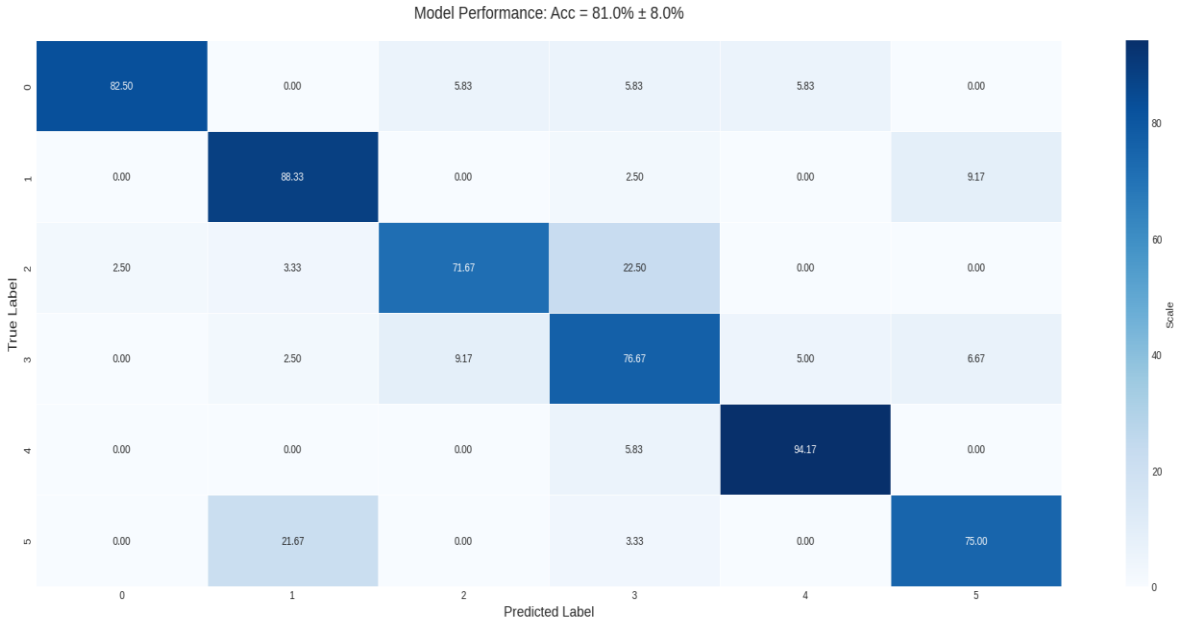

Figura 14. Matriz confusión Random Forest (fuente propia).

La matriz de confusión que muestra la Figura 14. indica un desempeño promedio del modelo Random Forest con una precisión general del **81.0% ± 8.0%**, lo que indica un rendimiento aceptable en la clasificación de datos MOCAP. Sin embargo, se observan áreas de mejora en ciertas clases. Por ejemplo, la clase 0 tiene una alta tasa de aciertos (82.50%), pero presenta confusión con las clases 2 y 3 (5.83% cada una). Por otro lado, la clase 1 destaca con un excelente desempeño (88.33%) y mínima confusión, lo que refleja que está bien representada en el modelo. En contraste, la clase 2, aunque con un rendimiento moderado (71.67%), se confunde principalmente con la clase 3 (22.50%), lo que sugiere similitudes entre sus movimientos.

La clase 3 tiene una precisión de 76.67%, pero con confusión hacia las clases 2 (9.17%) y 5 (6.67%), lo que indica que sus características no están claramente diferenciadas. La clase 4, con una precisión del 94.17%, es la más precisa, con una mínima confusión hacia la clase 3 (5.83%). Finalmente, la clase 5 muestra un rendimiento moderado (75.00%), pero su confusión con la clase 1 (21.67%) es notable, lo que podría deberse a características compartidas entre estos movimientos. Estas confusiones reflejan que las clases 2, 3 y 5 son las más problemáticas para el modelo, posiblemente debido a la superposición en sus representaciones en el espacio de características.

➢ **KNN**

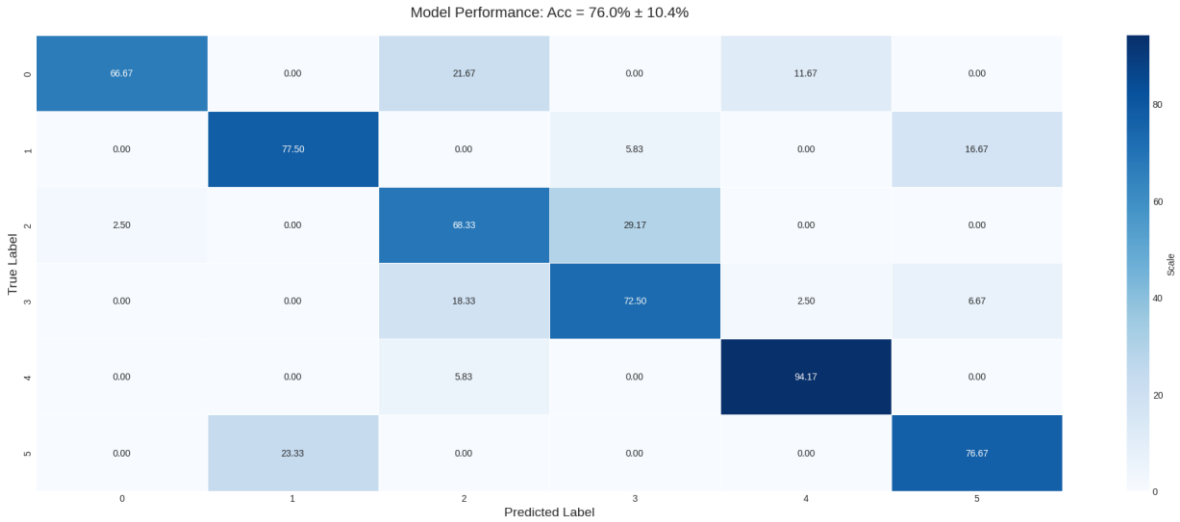

Figura 15. Matriz confusión KNN (fuente propia).

La matriz de confusión en la Figura 15 muestra el desempeño del modelo evaluando su capacidad para predecir etiquetas de clase específicas (0 a 5). Los valores diagonales representan los porcentajes de instancias correctamente clasificadas para cada clase, mientras que los valores fuera de la diagonal indican errores de clasificación. Por ejemplo, para la clase 0, el modelo clasificó correctamente el 66.67% de las instancias, pero un 21.67% fueron clasificadas erróneamente como clase 2 y un 11.67% como clase 3. Esto sugiere que, aunque el modelo identifica correctamente la mayoría de las instancias para algunas clases, existen confusiones importantes entre ciertas clases, como entre las clases 2 y 3.

En términos generales, el modelo logra una precisión promedio del 76.0% ± 10.4%, lo cual indica un desempeño aceptable, aunque con variaciones significativas entre clases. Por ejemplo, la clase 4 alcanza el mayor porcentaje de aciertos (94.17%), mientras que otras clases, como la 0 y la 2, tienen errores más notables en sus predicciones. Esto podría indicar que ciertas características de los datos MOCAP son más distintivas para algunas clases que para otras, sugiriendo la necesidad de mejorar la representatividad de las características o ajustar el modelo para minimizar estas confusiones.

➢ REDES NEURONALES

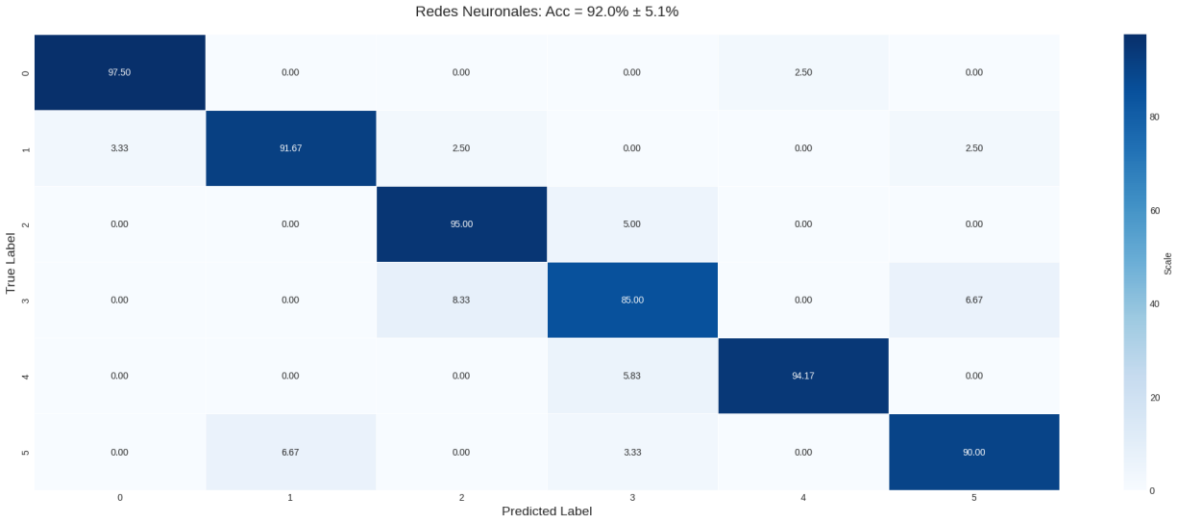

Figura 16. Matriz confusión Redes Neuronales (fuente propia).

La matriz de confusión en la Figura 16. ilustra un modelo de redes neuronales que clasifica seis movimientos específicos en el tenis con una precisión promedio del 92.0% ± 5.1%. Los valores en la diagonal principal muestran un alto nivel de acierto para todas las categorías, destacando especialmente las clases 0 (derecha), 2 (servicio) y 4 (remate), con tasas de clasificación correctas de 97.50%, 95.00% y 94.17%, respectivamente. Esto sugiere que el modelo ha capturado de manera efectiva las características distintivas de estos movimientos en los datos MOCAP.

Sin embargo, se observan algunos errores en las clases 1 (revés), 3 (otro movimiento) y 5 (posiblemente un saque específico o una variación de otro movimiento). Por ejemplo, un 3.33% de las instancias de la clase 1 fueron clasificadas erróneamente como clase 0, y un 6.67% de las instancias de la clase 5 fueron clasificadas como clase 1. Estas confusiones podrían atribuirse a similitudes en las características biomecánicas entre ciertos movimientos, como la posición del cuerpo o los ángulos de articulación, que el modelo no pudo distinguir completamente.

En términos prácticos, este nivel de precisión es excelente para aplicaciones como el análisis deportivo o la retroalimentación en tiempo real para los jugadores, aunque el modelo podría beneficiarse de un ajuste fino para reducir las confusiones restantes, especialmente entre movimientos que comparten similitudes biomecánicas o contextuales.

6.4 Optimización del Modelo.

La optimización del modelo es un proceso continuo que busca mejorar su rendimiento. Utilizando técnicas como la búsqueda en cuadrícula (Grid Search) o la optimización bayesiana, ajustaremos los hiperparámetros del modelo SVM para maximizar su precisión y eficiencia. Esta etapa es crucial, ya que un modelo bien optimizado puede ofrecer predicciones más confiables y robustas.

6.6 Validación del Modelo.

Después de entrenar el modelo, es esencial evaluarlo para medir su rendimiento. Utilizaremos métricas como la precisión accuracy para determinar qué tan bien clasifica los datos MOCAP. La precisión indica el porcentaje de predicciones correctas. En este proyecto, la ventaja de utilizar estos cuatro algoritmos radica en su capacidad para abordar diferentes aspectos de los datos MOCAP. Mientras que SVM puede ser ideal para capturar las relaciones complejas entre las características biomecánicas de los atletas, Random Forest y KNN ofrecen soluciones rápidas y robustas frente a variaciones entre los jugadores. Finalmente, las redes neuronales tienen el potencial de ofrecer la mayor precisión al capturar patrones profundos y no evidentes en los movimientos como se muestra en la (celda No.63) y en la Figura 17. Mejor Precisión.

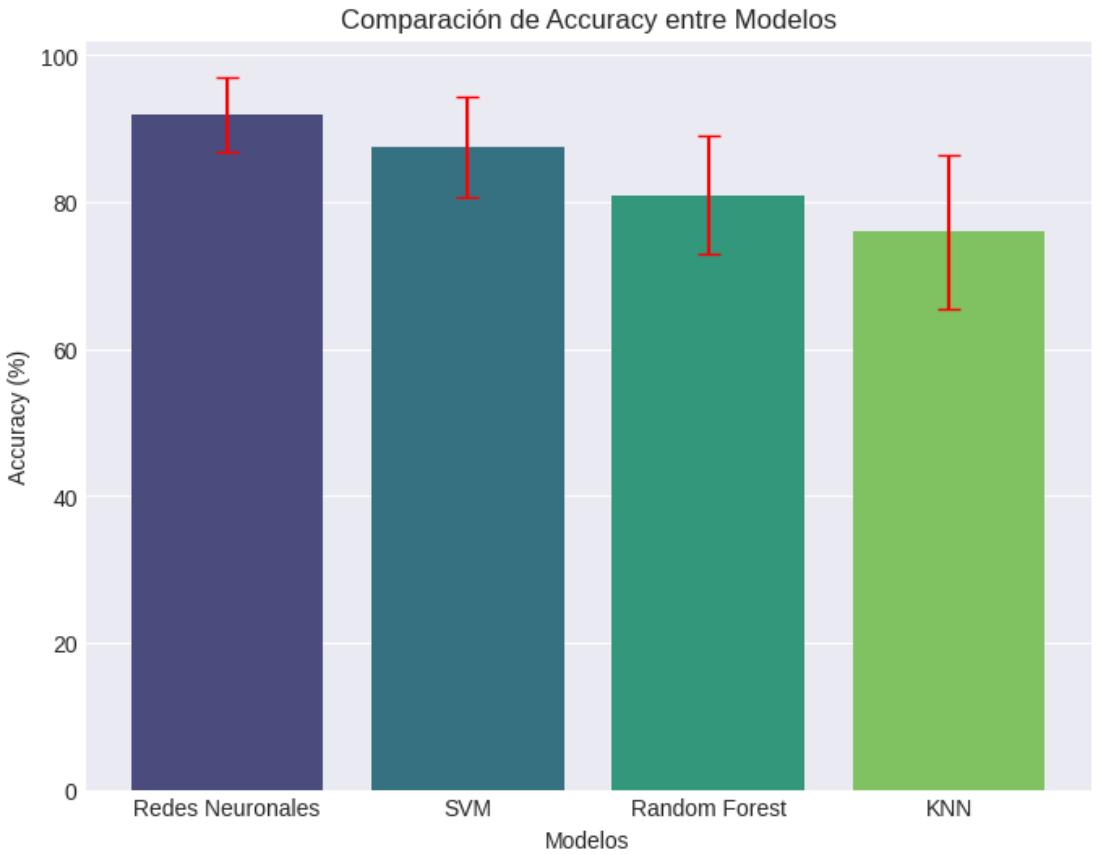

Figura 17. Comparación precisión de modelos (fuente propia).

7. CONCLUSIONES Y TRABAJOS FUTUROS

7.1 CONCLUSIONES

El preprocesamiento de los datos fue un paso crucial para garantizar la calidad de los resultados en la clasificación de los movimientos. A través de un proceso riguroso de limpieza y normalización de los datos de captura de movimiento (MOCAP), se logró eliminar las inconsistencias y el ruido inherente a la recolección de datos biomecánicos. La normalización de las posiciones en función de las caderas permitió una representación más coherente de las articulaciones en relación con el cuerpo central, lo que facilitó el análisis comparativo entre diferentes atletas y movimientos. Además, la visualización de estos datos mediante representaciones esqueléticas en 2D y 3D permitió observar de manera detallada la técnica de cada jugador, posibilitando un análisis visual antes de pasar a las etapas de modelado. Este enfoque de preprocesamiento fue fundamental no solo para garantizar la integridad de los datos, sino también para permitir que los algoritmos de Machine Learning funcionaran de manera eficiente y precisa.

La implementación de técnicas de clasificación no supervisada, como KMEANS y PCA (Análisis de Componentes Principales), resultó ser muy efectiva para agrupar y entender los diferentes patrones de movimiento de los atletas. KMEANS permitió agrupar los datos en función de las similitudes entre los movimientos, destacando las diferencias biomecánicas entre jugadores y tipos de golpe, como el servicio, la derecha y el revés. A través del análisis de componentes principales, se logró reducir la dimensionalidad de los datos, lo que facilitó su visualización y permitió identificar las variables más relevantes para cada tipo de movimiento. Estas técnicas revelaron la existencia de variaciones sutiles entre los atletas, proporcionando una mejor comprensión de las características clave que definen la calidad y la eficiencia técnica de los movimientos. Esto no solo permitió agrupar los datos en clases significativas, sino que también abrió nuevas posibilidades para mejorar la personalización del entrenamiento deportivo.

El uso de algoritmos avanzados de Machine Learning, como Support Vector Machines (SVM), mostró una alta capacidad para clasificar los movimientos capturados mediante MOCAP con precisión. Los modelos entrenados fueron capaces de identificar patrones en los movimientos de los atletas, lo que permitió una segmentación clara entre los diferentes tipos de golpes y técnicas utilizadas en el tenis. Además, el análisis cuantitativo de las disimilitudes entre las secuencias de movimiento ayudó a destacar diferencias importantes entre jugadores de diferentes niveles de habilidad, lo que podría ser útil para el diseño de programas de entrenamiento personalizados. El uso de estos algoritmos no solo permitió la clasificación efectiva de los movimientos, sino que también proporcionó información valiosa sobre la biomecánica deportiva, lo que puede influir directamente en la mejora técnica y la prevención de lesiones. En resumen, el enfoque basado en Machine Learning aplicado a los datos MOCAP demostró ser una herramienta poderosa para el análisis biomecánico y la optimización del entrenamiento en deportes competitivos como el tenis.

A pesar de los resultados obtenidos, es importante destacar que el tamaño de la muestra (n=16) limita la capacidad de generalización de los modelos utilizados. En el caso de Random Forest (RF), la generación de árboles de decisión específicos para los datos de entrenamiento aumenta el riesgo de sobreajuste en muestras pequeñas. Por su parte, Support Vector Machines (SVM) requiere una cantidad adecuada de datos para establecer un margen óptimo de separación entre clases, y un tamaño reducido puede afectar su capacidad para definir correctamente los límites de decisión. Finalmente, las redes neuronales necesitan grandes volúmenes de datos para entrenarse correctamente y evitar el sobreajuste, ya que con solo 16 muestras es posible que el modelo aprenda patrones espurios en lugar de relaciones generales aplicables a nuevos datos.

7.2 TRABAJOS FUTUROS

Aplicación a otros deportes: Una posible extensión de este trabajo sería aplicar las mismas técnicas de captura de movimiento y clasificación a otros deportes, como el fútbol, el baloncesto o el atletismo. Cada deporte tiene su propio conjunto de movimientos específicos que podrían beneficiarse de un análisis biomecánico detallado mediante modelos de Machine Learning. Además, el estudio de diferentes tipos de movimientos y su relación con la prevención de lesiones podría ofrecer un enfoque integral para mejorar el rendimiento de los atletas y reducir el riesgo de problemas físicos a largo plazo.

Mejoras en la captura y análisis de movimientos: Otra dirección futura podría enfocarse en mejorar la precisión y el detalle de la captura de movimiento utilizando tecnologías más avanzadas, como sistemas de captura en 4D o la incorporación de inteligencia artificial para detectar automáticamente anomalías en tiempo real. Esto permitiría a los entrenadores ajustar estrategias de entrenamiento durante la práctica. Asimismo, se podrían explorar nuevas técnicas de aprendizaje profundo, como redes neuronales recurrentes, para modelar secuencias temporales de manera más efectiva, mejorando aún más la capacidad de predicción de los modelos en deportes como el tenis u otras disciplinas atléticas.

BIBLIOGRAFIA

[1] U. Martínez-Iranzo, E. Medina Ripoll, G. Utrilla Redondo, C. Garcia Bermell, I. Bermejo Bosch, y J. Lopez Pascual, "Aplicación de la Inteligencia Artificial al análisis biomecánico," Innovación biomecánica en Europa, no. 9, pp. 1-7, 2020.

[2] E. Hovad, T. Hougaard-Jensen y L. K. H. Clemmensen, "Classification of Tennis Actions Using Deep Learning," arXiv preprint arXiv:2402.02545, 2024.

[3] L. L. Gómez Echeverry et al., "Sistemas de captura y análisis de movimiento cinemático humano: una revisión sistemática," Prospectiva, vol. 16, no. 2, pp. 24-34, 2018.

[4] STT Systems, "Captura de movimiento y análisis biomecánico en tenis," [En línea]. Disponible en: https://motio.stt-systems.com/es/casos-de-exito/motion-capture-and-biomechanical-analysis-in-tennis/. [Accedido: 10-feb-2025].

[5] A. Aguado, "Clasificación de actividades humanas en tiempo real a partir de representaciones en esqueleto," Universidad del País Vasco, 2016.

[6] Y. Arrieta y R. Rivera, "Algoritmo de *Machine Learning* para detectar movimientos técnicos en el tenis de campo," Trabajo de grado, Fundación Universitaria Los Libertadores, Bogotá, Colombia, 2019.

[7] MINTIC (2019) Aspectos básicos de la industria 4.0 Carlos Gustavo Suarez (1 ed.) [Online]. Available: https://colombiatic.mintic.gov.co/679/articles-124767_recurso_1.pdf

[8] BIGDATA (2017) JS McDonald y LS Ross, Big Data Fundamentals: Concepts, Drivers & Techniques . 2.ª ed. Nueva York, NY, EE. UU.: Wiley.

[9] IOT (2024) ETendencias de investigación en el uso de Internet de las cosas en prácticas de sostenibilidad: una revisión sistemática [Online]. Available: https://www.mdpi.com/2071-1050/16/7/2663

[10] The Bridge, "Algoritmos de aprendizaje automático y su aplicación en la detección de fraudes," The Bridge Blog, 2023. [Online]. Disponible en: https://thebridge.tech/blog/algoritmos-aprendizaje-automatico

[11] Clínica MEDS (1992) Biomecánica deportiva Equipo Unidad Médica (1 ed.) [Online]. Available: https://www.meds.cl/programas-meds/meds-healthy/centro-de-innovacion-meds/unidad-de-biomecanica-deportiva/#:~:text=La%20Biomec%C3%A1nica%20Deportiva%20es%20un,o%20influencian%20los%20movimientos%20deportivos

[12] Top Doctors, "Maximizando el rendimiento deportivo a través del análisis biomecánico," [En línea]. Disponible en: https://www.topdoctors.es/articulos-medicos/maximizando-el-rendimiento-deportivo-a-traves-del-analisis-biomecanico/.

[13] ADOBE (2023) MOTION CAPTURE (1 ed.) [Online]. Available: https://www.adobe.com/es/creativecloud/animation/discover/motion-capture.html

[14] SISTEMAS ÓPTICOS (2018) Sistemas de captura y análisis de movimiento cinemático humano: una revisión sistemática (1 ed.) [Online]. Available: http://www.scielo.org.co/pdf/prosp/v16n2/1692-8261-prosp-16-02-00024.pdf

[15] SISTEMAS INERCIALES (2017) Caracterización de unidades de medición inercial (IMUs) en estática y dinámica (1 ed.) [Online]. Available: http://revistas.ustatunja.edu.co/index.php/ingeniomagno/article/view/1391

[16] SISTEMAS ELECTROMAGNETICOS (2017) SISTEMA DE CAPTURA DE MOVIMIENTO PARA ANIMACIÓN DE PERSONAJES 3D Y PRESENTACIONES DE ALTO IMPACTO (1 ed.) [Online]. Available: http://repositoriodspace.unipamplona.edu.co/jspui/bitstream/20.500.12744/3861/1/Garc%C3%A9s_2017_TG.pdf

[17] El análisis exploratorio de datos (2020) Análisis EDA. Albert Padró - Solanet [Online]
Available:https://openaccess.uoc.edu/bitstream/10609/149990/1/AnalisisExploratorioDeDatos.pdf

[18] Universidad Pontificia Bolivariana (2019) Reconocimiento de actividades humanas usando redes de gran memoria de corto plazo Javier Fernando Villamizar Torres (1 ed.) [Online]. Available: https://repository.upb.edu.co/handle/20.500.11912/8499#:~:text=El%20reconocimiento%20de%20actividades%20humanas,de%20aprendizaje%20autom%C3%A1tico%20y%20profundo

[19] Oracle Cloud (2023) ¿Qué es la IA? Conoce la inteligencia artificial (1 ed.) [Online]. Available: https://www.oracle.com/co/artificial-intelligence/what-is-ai/

[20] Only Tenis (2022 ene.) ¿Tipos de Golpe en el tenis? [Online]. Available: https://www.onlytenis.com/blog/tipos-de-golpes-en-tenis/

[21] Iberdrola (2023) ¿Qué es el 'machine Learning' y para qué sirve? Grupo Iberdrola (2 ed.) [Online]. Available: https://www.iberdrola.com/innovacion/machine-learning-aprendizaje-automatico#:~:text=El%20Machine%20Learning%20es%20una,elaborar%20predicciones%20(an%C3%A1lisis%20predictivo)

[22] Universidad de Valladolid, Máster Ingeniería (2019) Utilización de Machine Learning canalización D. Alberto Maisueche Cuadrado (1 ed.) [Online]. Available: https://core.ac.uk/download/pdf/228074134.pdf

[23] IBM ¿Qué es Deep Learning? (1 ed.) [Online]. Available: https://www.ibm.com/es-es/topics/deep-learning

[24] Universidad Tecnológica de Pereira (2022) Métricas entre procesos aleatorios usando el método de embebimiento de distribuciones de probabilidad en un espacio de Hilbert con kernel reproductivo. Edgar Alirio Valencia A. (1 ed.) [Online]. Available: https://repositorio.utp.edu.co/items/ab8c93aa-efe5-4497-9f3b-6723d2935fe4

[25] National Center for Biotechnology Information, "StatPearls: Your PubMed and medical reference," National Library of Medicine, Oct. 2020. [Online]. Available: https://www.ncbi.nlm.nih.gov/books/NBK583975/.

[26] B. K. Sriperumbudur, A. Gretton, K. Fukumizu, B. Schölkopf, y G. R. G. Lanckriet, "Hilbert space embeddings and metrics on probability measures," *Journal of Machine Learning Research*, vol. 11, pp. 1517–1561, 2010. [Online]. Available: https://www.jmlr.org/papers/volume11/sriperumbudur10a/sriperumbudur10a.pdf

[27] T. Zheng, "Reproducing Kernel Hilbert Space," *Statistical Machine Learning Resource*, Sep. 2023. [Online]. Available: https://teazrq.github.io/SMLR/reproducing-kernel-hilbert-space.html.

[28] The MathWorks, Inc (1994-2023) Super Vector Machine SVM. (1 ed.) [Online]. Available: https://la.mathworks.com/discovery/support-vector-machine.html

[29] DataScientest (2017) Machine Learning & Clustering: el algoritmo DBSCAN (1 ed.) [Online]. Available: https://datascientest.com/es/machine-learning-clustering-dbscan#:~:text=El%20clustering%20es%20una%20disciplina,clientes%20para%20detectar%20comportamientos%20particulares

[30] Konfuzio (2017), "La LSTM: un tipo de red neuronal recurrente para aprender dependencias a largo plazo", Konfuzio, [En línea]. Disponible en: https://konfuzio.com/es/lstm/#:~:text=La%20LSTM%20es%20un%20tipo,periodos%20de%20tiempo%20m%C3%A1s%20largos

[31] Transformer (2023) The Fourier Transform and its Application in Machine Learning [En línea]. Disponible en: https://medium.com/the-modern-scientist/the-fourier-transform-and-its-application-in-machine-learning-edecfac4133c

[32] PCA (2024). Qué es la reducción de la dimensionalidad. IBM Doctor Jacob Murel, Eda Kavlakoglu Disponible en: https://www.ibm.com/es-es/topics/dimensionality-reduction

[33] TSNE (2024) Introducción al TSNE. DatacaMP. Disponible en: https://www.datacamp.com/es/tutorial/introduction-t-sne

[34] SCIKIT LEARN (2024) Lenguaje de Programación Python PIPELINE [Online]. Available: https://scikitlearn.org/stable/modules/generated/sklearn.pipeline.Pipeline.html

[35] Curso de programación en C++ (1995 jul.) Lenguaje de Programación C++ Sergio Talens Oliag (1 ed.) [Online]. Available: https://www.uv.es/~sto/cursos/c++/curso95.pdf

[36] Introducción a MATLAB (2016) Lenguaje de Programación MATLAB. Julio Benítez López [Online]. Available: https://personales.upv.es/jbenitez/data/matlab.pdf

[37] Introducción a R (2000) Lenguaje de Programación R [Online]. Available: https://cran.r-project.org/doc/contrib/R-intro-1.1.0-espanol.1.pdf

[38] terceto comunicación (2019) Qué es el MOCAP, o captura de movimiento para un vídeo en 3D (1 ed.) [Online]. Available: https://tercetocomunicacion.es/que-es-el-mocap-o-captura-de-movimiento-para-un-video-en-3d/

[39] btsbioengineering (2022) Datos MOCAP en medicina. Viale Forlanine (1 ed.) [Online]. Available: https://www.btsbioengineering.com/products/smart-dx-evo/?gad_source=1&gclid=CjwKCAiAx_GqBhBQEiwAlDNAZh7634lPVhZSpSP_8FmgDjlgLi0fQeO_KXyjTklFcEkM2MjS1wzq1BoC1NoQAvD_BwE

[40] btsbioengineering (2022) Datos MOCAP en deporte. Viale Forlanine (1 ed.) [Online]. Available: https://www.btsbioengineering.com/products/smart-dx-evo/?gad_source=1&gclid=CjwKCAiAx_GqBhBQEiwAlDNAZh7634lPVhZSpSP_8FmgDjlgLi0fQeO_KXyjTklFcEkM2MjS1wzq1BoC1NoQAvD_BwE

[41] Jedliˇcka, P.; Krˇ noul, Z.; Kanis, J.; Železn` y, M. Sign Language Motion Capture Dataset for Data-driven Synthesis. In Proceedings of the LREC2020 9th Workshop on the Representation and Processing. France, 11–16 May 2020; pp. 101–106.

[42] Sun, C.; Junejo, I.; Foroosh, H. Motion retrieval using low-rank subspace decomposition of motion volume. 30, pp. 1953–1962.

[43] CMU Graphics Lab Motion Capture Database (2017) Datos MOCAP en deporte baloncesto. Viale Forlanine (1 ed.) [Online].

Available: http://mocap.cs.cmu.edu/search.php?subjectnumber=6&trinum=2

[44] Singh, A.; Principe, J. Information theoretic learning with adaptive kernels. Signal Process. 2011, 91, 203–213.

[37] Signos Studio S.A.S. (2000) Productora de animación 3D que aplicamos el uso de la tecnología de Captura de Movimiento (MoCap). [Online]. Available: https://www.linkedin.com/company/signos-studio-s.a.s./?originalSubdomain=co

[45] Crisal studios (2016) estudio-taller de producción creativa (MoCap). [Online]. Available: https://www.crisalidastudios.com/

[46] SINERMED (2016) Soluciones [Online]. Available: https://www.sinermed.com.co/gracias

[47] Captura de movimiento utilizando el Software Arena (2007) control de una plataforma robótica. Leandro [Online]. Available: https://www.optitrack.com/public/newsletters/2007-12.html

[48] BVH Motion Capture Data Animated (2001) BVH (Biovision Hierarchy) [Online]. Available: https://www.cs.cityu.edu.hk/~howard/Teaching/CS4185-5185-2007-SemA/Group12/BVH.html

[49] DATA TENNIS (2017) Datos MOCAP de la liga caldense de tenis. Pulgarín-Giraldo JD, Álvarez-Meza AM, Melo-Betancourt LG, Ramos-Bermúdez S., Castellanos-Domínguez G [Online]. Available: https://github.com/jdpulgarin/Tennis-MoCap

[50] Motion Capture Using Joint Skeleton Tracking and Surface Estimation (2017) Estructura de JOINT. Juergen Gall [Online]. Available: https://www.tnt.uni-hannover.de/papers/data/773/773_1.pdf

[51] Sistemas de captura (2018) Formato BVHParser. Lesly Lisbeth Gómez Echeverry1 [Online]. Available:http://www.scielo.org.co/pdf/prosp/v16n2/1692-8261-prosp-16-02-00024.pdf

[52] PYMO Python Motion Análisis Library (2021) MocapParameterizer. OMIMO [Online]. Available: https://github.com/omimo/PyMO

[53] PYMO Python Motion Análisis Library (2021) FIT_TRANSFORM. OMIMO [Online]. Available: https://github.com/omimo/PyMO

[54] PYMO Python Motion Análisis Library (2021) DRAW_SCKITFIGURE. OMIMO [Online]. Available: https://github.com/omimo/PyMO

[55] PYMO Python for Data Analysis (2017) Data Wrangling with Pandas, NumPy, and IPython Sebastopol, CA: O'Reilly Media

[56] T. E. Oliphant, Guide to NumPy, 2nd ed. USA: CreateSpace Independent Publishing Platform, 2015.

[57] F. Pedregosa, G. Varoquaux, A. Gramfort, et al., "Scikit-learn: Machine Learning in Python," Journal of Machine Learning Research, vol. 12, pp. 2825–2830, 2011.

[58] Matplotlib Release 2.0.2 (2017) MATPLOTLIB. John Hunter, [Online]. Available: https://matplotlib.org/2.0.2/Matplotlib.pdf

[59] KMEANS (2006.) C.M. Bishop, *Pattern Recognition and Machine Learning*, 1st ed. New York: Springer.

[60] DISTANCIA EUCLIDIANA (2001) R. O. Duda, P. E. Hart, y D. G. Stork, *Pattern Classification*, 2nd ed. New York, NY, USA: Wiley, pp. 33-34.

[61] *Aprendizaje profundo*. (2016) Goodfellow, Y. Bengio y A. Courville, 1nd ed. New York, NY, USA: Wiley, pp. 33-34.

[62] LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs) (2005) SVM Gustavo Betancourt [Online]. Available: https://www.researchgate.net/publication/49588125_LAS_MAQUINAS_DE_SOPORTE_VECTORIAL_SVMs

[63] Random Forest con Python (2024) Joaquín Amat Rodrigo, [Online]. Available: https://cienciadedatos.net/documentos/py08_random_forest_python

[64] Introducción al Procesamiento de Imágenes CON PYTHON (2020) KNN. Carlos Bustillo. [Online]. Available: https://eventos.python.org.ar/media/talks/Carlos_Bustillo_-PyAr_2020.pdf

[65] https://eventos.python.org.ar/media/talks/Carlos_Bustillo_-PyAr_2020.pdf (2020) Redes Neuronales [Online]. Available: https://torres.ai/wp-content/uploads/2020/02/Empieza_a_leer_Python_Deep_Learning.pdf

[66] Validación Cruzada (2022) Cross-Validation : definición e importancia en Machine Learning [Online]. Available: https://datascientest.com/es/2022/05/13

[67] accuracy (2024) Accuracy vs. precision vs. recall in machine learning: what's the difference? [Online]. Available: https://www.evidentlyai.com/classification-metrics/accuracy-precision-recall#:~:text=them%20in%20detail!-,What%20is%20accuracy%3F,the%20total%20number%20of%20predictions.

[68] overfitting [Online]. Available: https://protecciondatos-lopd.com/empresas/overfitting/

[69] StratifiedShuffleSplit (2017) [Online]. Available: https://qu4nt.github.io/sklearn-doc-es/modules/generated/sklearn.model_selection.StratifiedShuffleSplit.html

[70] GridSearchCV [Online]. Available: https://scikit-learn.org/dev/modules/generated/sklearn.model_selection.GridSearchCV.html

[71] Matriz de confusión (2019) La matriz de confusión y sus métricas [Online]. Available: https://www.juanbarrios.com/la-matriz-de-confusion-y-sus-metricas/