

Evaluación del monitoreo y corrección técnica en ejercicios de powerlifting mediante modelos de
inteligencia artificial

Autores:

Dorian Sebastián Bolaños Coral

Johan David Toro Ortiz

Informe final de trabajo de grado presentado como requisito para optar al título de Ingeniero de
Sistemas, en modalidad investigación.

Asesor:

Héctor Andrés Mora Paz, Magister en Inteligencia Artificial

PROGRAMA DE INGENIERÍA DE SISTEMAS

FACULTAD DE INGENIERÍA

UNIVERSIDAD CESMAG

2025

Nota de aceptación

NOMBRE JURADO 1

NOMBRE JURADO 2

Nota de exclusión

El autor de esta obra es el único responsable de las ideas expresadas en ella, y no compromete el pensamiento e ideología de la Universidad CESMAG.

DEDICATORIA

Dedicamos este trabajo, ante todo, a nuestras familias, verdadero sostén y base de nuestras vidas. A ustedes, que con amor, paciencia, comprensión y apoyo constante nos han acompañado en cada etapa de este camino. Gracias por creer en nosotros incluso cuando las circunstancias no fueron favorables. Este logro les pertenece tanto como a nosotros.

A nuestros seres queridos, quienes son fuente permanente de inspiración y motivación. Sus palabras de ánimo, su ejemplo de perseverancia y su confianza en nuestras capacidades nos impulsaron a avanzar con determinación y entusiasmo.

Extendemos esta dedicatoria a todas las personas que, de una u otra forma, nos ofrecieron su apoyo, compartieron su conocimiento o nos brindaron su tiempo durante este proceso. Cada aporte, por pequeño que pareciera, fue esencial para hacer posible la culminación de este proyecto.

Finalmente, dedicamos este logro a nosotros mismos, por la constancia, el esfuerzo y la entrega demostrados en cada etapa. Por no desistir ante las dificultades y mantener siempre la convicción de alcanzar nuestras metas. Hoy celebramos con orgullo el fruto de esa dedicación compartida.

AGRADECIMIENTOS

Expresamos nuestro más profundo agradecimiento a todas las personas que, de una u otra forma, nos brindaron su apoyo, acompañamiento y confianza a lo largo de este proceso académico.

En primer lugar, queremos destacar y agradecer sinceramente al Magíster Héctor Andrés Mora Paz, nuestro Tutor de trabajo de grado. Su compromiso, orientación y constancia fueron pilares esenciales para la culminación de este proyecto. Valoramos profundamente su disposición para guiarnos, compartir sus conocimientos y ofrecernos siempre palabras de motivación que nos impulsaron a continuar con determinación y confianza.

Extendemos nuestro reconocimiento a la Universidad CESMAG, por ofrecernos una formación integral que fortaleció tanto nuestras competencias profesionales como nuestro crecimiento humano. Agradecemos los espacios, recursos y oportunidades que nos permitieron desarrollar esta investigación con responsabilidad y sentido ético.

A nuestras familias y amigos, les dedicamos un agradecimiento muy especial. Su cariño incondicional, paciencia y respaldo permanente fueron la base que nos sostuvo en los momentos de mayor desafío. Su fe en nosotros y su constante apoyo hicieron posible alcanzar esta meta.

Finalmente, a todas las personas que, de manera directa o indirecta, aportaron a la realización de este proyecto, les extendemos nuestra más sincera gratitud. Para expresarles que este logro no podría haberse cumplido sin ellos.

Resumen analítico de estudio RAE

Facultad: Ingeniería

Programa: Ingeniería de Sistemas

Fecha de elaboración: 2025

Autores de la investigación: Dorian Sebastián Bolaños Coral, Johan David Toro Ortiz

Asesor: Magister en Inteligencia Artificial Héctor Andrés Mora Paz

Título de la investigación: Evaluación del monitoreo y corrección técnica en ejercicios de powerlifting mediante modelos de inteligencia artificial

Palabras clave: Powerlifting, inteligencia artificial, visión por computadora, corrección técnica, redes neuronales, análisis postural

Resumen:

La presente investigación aborda el desarrollo y evaluación de un sistema basado en inteligencia artificial y visión por computadora para el monitoreo y corrección técnica en ejercicios de powerlifting. El estudio se enfoca en los tres movimientos fundamentales de esta disciplina: sentadilla, press de banca y peso muerto, los cuales requieren una ejecución precisa para evitar lesiones y optimizar el rendimiento. Ante la dificultad de contar siempre con supervisión humana, se plantea un sistema que utilice modelos de redes neuronales convolucionales y algoritmos de aprendizaje automático para detectar errores posturales en tiempo real.

El proyecto integra un conjunto de videos de entrenamiento, los cuales fueron analizados y procesados para crear un dataset balanceado que permitiera entrenar diferentes modelos de inteligencia artificial. A partir de ello, se comparó el desempeño de varios algoritmos mediante métricas como accuracy, F1-score, AUC y tiempo de predicción, con el fin de determinar el modelo más eficiente para la detección de errores técnicos. Los resultados demuestran que la visión artificial es una herramienta eficaz para asistir a los deportistas en la mejora de su técnica, ofreciendo retroalimentación inmediata y reduciendo el riesgo de lesiones derivadas de la ejecución incorrecta.

Objetivo general: Evaluar la eficiencia de un grupo de algoritmos de visión artificial para la clasificación de errores en la ejecución de ejercicios de powerlifting mediante la relación entre el área bajo la curva ROC y el tiempo de predicción.

Objetivos específicos:

- Generar un dataset compuesto por videos de ejecuciones de ejercicios multiarticulares de powerlifting etiquetados mediante expertos.
- Preprocesar el conjunto de datos para eliminar componentes espaciales y temporales que causen ruido mediante técnicas de image cleaning.
- Estructurar una matriz comparativa de modelos de visión artificial implementados con redes neuronales artificiales y sus métricas de calidad (accuracy, F1-score, AUC), con el fin de determinar la eficiencia de cada modelo en la detección de errores técnicos.

Conclusión:

El desarrollo de un sistema inteligente de monitoreo técnico representa un avance relevante para la integración de la inteligencia artificial en el ámbito deportivo. Este proyecto demuestra que el uso de modelos de visión artificial puede contribuir significativamente a la corrección de errores técnicos en powerlifting, ofreciendo un apoyo tecnológico a los entrenadores y atletas. La automatización de la observación y corrección técnica permite no solo optimizar el rendimiento físico, sino también prevenir lesiones derivadas de una ejecución inadecuada. En conjunto, esta investigación sienta las bases para el desarrollo de herramientas inteligentes que integren análisis biomecánico y retroalimentación personalizada en tiempo real, impulsando la evolución del entrenamiento deportivo hacia entornos más seguros, precisos y eficientes.

TABLA DE CONTENIDO

	Pág.
INTRODUCCIÓN	15
I. PROBLEMA DE INVESTIGACIÓN	16
A. OBJETO O TEMA DE INVESTIGACIÓN	16
B. LÍNEA DE INVESTIGACIÓN.....	16
C. SUBLÍNEA DE INVESTIGACIÓN	16
D. PLANTEAMIENTO DEL PROBLEMA.....	16
E. FORMULACIÓN DEL PROBLEMA.....	19
F. OBJETIVOS	19
1) Objetivo general.....	19
2) Objetivos específicos	19
G. JUSTIFICACIÓN.....	20
H. DELIMITACIÓN.....	22
II. MARCO TEÓRICO	23
A. ANTECEDENTES	23
1) Internacionales	23
2) Nacionales.....	25
3) Regional	28
B. SUPUESTOS TEÓRICOS DE LA INVESTIGACIÓN	33
1) Powerlifting.....	33
2) Metodologías para el monitoreo y técnica de ejercicios de powerlifting	36
3) Inteligencia artificial	39
4) Visión artificial	40
5) Redes neuronales y aprendizaje profundo	40

6) Procesamiento de video e imágenes	41
7) Modelos clásicos de aprendizaje automático.....	42
8) Métricas de evaluación en IA	43
9) Generación de informes personalizados	44
10) Redes neuronales	45
11) Procesamiento de video e imágenes	46
C. VARIABLES DE ESTUDIO	47
1) Variables independientes	47
2) Variables dependientes	48
D. FORMULACIÓN DE HIPÓTESIS	53
1) Hipótesis de investigación	53
2) Hipótesis nula.....	53
3) Hipótesis alterna.....	54
III. METODOLOGÍA	55
A. PARADIGMA.....	55
B. ENFOQUE.....	55
C. MÉTODO	55
D. TIPO DE INVESTIGACIÓN.....	56
E. DISEÑO DE INVESTIGACIÓN	56
F. POBLACIÓN.....	56
G. MUESTRA.....	56
H. TÉCNICAS DE RECOLECCIÓN DE LA INFORMACIÓN	57
I. VALIDEZ DE LAS TÉCNICAS DE RECOLECCIÓN DE LA INFORMACIÓN.....	58
J. CONFIABILIDAD DE LAS TÉCNICAS DE RECOLECCIÓN	58
K. INSTRUMENTOS DE RECOLECCIÓN DE INFORMACIÓN	59

IV. RESULTADOS DE LA INVESTIGACIÓN	60
A. METODOLOGÍA (CRISP-DM)	60
B. RECOPIACIÓN DE INFORMACIÓN	60
1) Escenario de grabación	60
2) Participantes	61
3) Distribución de los ejercicios grabados	62
4) Material complementario de internet	63
5) Validación por expertos	64
6) Aspectos técnicos de grabación	64
C. CREACIÓN DE DATA SET	65
1) Organización inicial del material	66
2) Estandarización de formatos	66
3) Control de balance entre clases	68
4) Validación de la data set	68
D. MODELO DE INTELIGENCIA ARTIFICIAL	69
1) Proceso de entrenamiento	69
2) Comparación de resultados	73
3) Discusión de resultados	76
4) Conclusión del modelo	76
V. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS	79
CONCLUSIONES	82
RECOMENDACIONES	84
BIBLIOGRAFÍA	86

LISTA DE TABLAS

	Pág.
TABLA I. VIDEOS REALIZADOS CORRECTOS Y INCORRECTOS PROPIOS CON PROMEDIO DE REPETICIONES POR VIDEO	63
TABLA II. DIVISION DEL DATASET	65
TABLA III. NOMBRE DE CADA ARCHIVO Y SUS OBSERVACIONES CORRESPONDIENTES.....	68
TABLA IV. VIDEOS POR CADA UNO DE LOS EJERCICIOS.....	68
TABLA V. PARÁMETROS RELEVANTES UTILIZADOS EN EL PROYECTO FINAL	71
TABLA VI. OBJETIVOS VS PRODUCTO Y EVIDENCIA.....	77
TABLA VII. LIMITACIONES Y RECOMENDACIONES	78

LISTA DE FIGURAS

	Pág.
Fig. 1. Ejercicios de powerlifting	33
Fig. 2. Ejercicio powerlifting press de banca	34
Fig. 3. Ejercicio de powerlifting sentadilla	35
Fig. 4. Ejercicio de powerlifting peso muerto	36
Fig. 5. Monitoreo de diferentes ejercicios	36
Fig. 6. Detección de objetos y videos.....	37
Fig. 7. Análisis de postura	38
Fig. 8. Inteligencia artificial en dispositivos	39
Fig. 9. Visión artificial	41
Fig. 10. Ejemplo de estimación de pose para la detección de ángulos articulares en ejercicios de fuerza.....	42
Fig. 11. Comparación conceptual entre modelos clásicos de aprendizaje automático y redes neuronales profundas.....	43
Fig. 12. Curvas de medición del sobreajuste.....	44
Fig. 13. Registros de informes	45
Fig. 14. Arquitectura general de una red neuronal convolucional (CNN) utilizada en visión por computadora	46
Fig. 15. Inteligencia artificial en la ayuda de los ejercicios	47
Fig. 16. Foto del set de grabación mostrando la disposición de la cámara y la zona de levantamiento	61
Fig. 17. Comparación de videos correctos e incorrectos.....	62
Fig. 18. Material complementario de internet	64
Fig. 19. Diagrama de flujo de videos propios y externos paso a paso	65
Fig. 20. Carpeta de Data set	67
Fig. 21. Verificación de cada ejercicio y sus respectivas observaciones	69
Fig. 22. Curvas de entrenamiento y validación (accuracy y loss vs. épocas)	72
Fig. 23. Comparación de modelos.....	73
Fig. 24. Métricas de la CNN	74

Fig. 25. Comparación de los últimos 2 modelos de mejores para el tratamiento de videos y correcciones.....74

Fig. 26. Curva ROC de la data set único75

Fig. 27. Matriz de confusión en valores absolutos y matriz de confusión normalizada76

INTRODUCCIÓN

El powerlifting es una disciplina que demanda un control total y exactitud en cada uno de los movimientos. Cada aspecto técnico afecta la prevención de lesiones y el rendimiento, así que una correcta ejecución se vuelve un componente fundamental para el avance del deportista. Sin embargo, incluso los atletas más experimentados pueden equivocarse con su técnica, lo que evidencia la relevancia de una supervisión especializada y constante durante el entrenamiento.

Históricamente, la observación directa de los entrenadores, que desempeñan un papel fundamental al identificar fallos y rectificar la posición o el movimiento de los deportistas, ha sido la base de la corrección técnica. No obstante, no siempre es posible contar con la presencia de un entrenador de manera continua, lo que limita la posibilidad de ofrecer una retroalimentación precisa e inmediata. Esta situación requiere que se creen herramientas tecnológicas que apoyen el trabajo humano y garanticen una evaluación permanente del desempeño.

En este contexto, la inteligencia artificial (IA) y la visión por computadora ofrecen alternativas innovadoras para analizar el desempeño de los ejercicios en tiempo real. Con estas tecnologías es factible registrar, procesar y examinar movimientos complejos con un nivel de precisión que excede lo que el ojo humano puede percibir; esto posibilita una corrección técnica más rápida, imparcial y adecuada a cada situación.

El proyecto actual sugiere la creación y puesta en funcionamiento de un sistema de seguimiento y ajuste técnico para ejercicios de powerlifting, fundamentado en modelos de inteligencia artificial. La finalidad de este sistema es detectar fallos en la realización de movimientos multiarticulares y proporcionar retroalimentación instantánea, con el objetivo de disminuir el peligro de lesiones y optimizar la eficacia del entrenamiento.

Este trabajo se desarrolla en distintas fases: primero, el problema investigado y los fundamentos teóricos que lo respaldan; después, la metodología utilizada para recolectar y procesar datos; y por último, los resultados obtenidos, el análisis de modelos de inteligencia artificial y las conclusiones del estudio.

I. PROBLEMA DE INVESTIGACIÓN

A. OBJETO O TEMA DE INVESTIGACIÓN

Desempeño de modelos de inteligencia artificial en la detección de errores técnicos en ejercicios de powerlifting.

B. LÍNEA DE INVESTIGACIÓN

Inteligencia artificial.

C. SUBLÍNEA DE INVESTIGACIÓN

Visión artificial.

D. PLANTEAMIENTO DEL PROBLEMA

En el deporte del powerlifting, los ejercicios multiarticulares como la sentadilla, el press de banca y el peso muerto son fundamentales para desarrollar fuerza y rendimiento. No obstante, su ejecución incorrecta es una problemática recurrente que afecta a los deportistas, generando consecuencias negativas tanto en su salud como en su progreso deportivo.

Las malas posturas y los movimientos incorrectos, causados por la falta de precisión técnica, generan lesiones comunes en las articulaciones, la columna vertebral y los músculos. Estas lesiones, acumuladas con el tiempo, pueden comprometer la carrera deportiva de los atletas [1]. Los patrones de movimiento incorrectos limitan el progreso en fuerza y habilidades, Debido a que los atletas no logran maximizar su potencial físico. Esto genera frustración y, en muchos casos, desmotivación para continuar entrenando [2].

Los entrenadores no siempre pueden detectar y corregir errores en tiempo real debido a limitaciones humanas y tecnológicas. Como resultado, los atletas repiten movimientos incorrectos, perpetuando los problemas de técnica [3]. Este problema tiene diversas raíces que complican la correcta ejecución de los ejercicios:

Los ejercicios de powerlifting implican el uso simultáneo de múltiples articulaciones y músculos, requiriendo una coordinación precisa entre fuerza, estabilidad y movilidad. Esto los hace difíciles de ejecutar correctamente, incluso para atletas experimentados [4].

Los entrenadores, aunque capacitados, no siempre logran identificar errores técnicos en tiempo real debido a factores como la velocidad de los movimientos, la atención a múltiples atletas o el detalle de las posturas [5].

Los métodos tradicionales de monitoreo dependen exclusivamente de la observación humana y no cuentan con sistemas automatizados capaces de analizar y corregir errores técnicos de manera inmediata y precisa si no se implementan soluciones efectivas, las consecuencias pueden ser graves [6].

Los errores técnicos que se producen de manera reiterada en los entrenamientos no únicamente disminuyen la efectividad del trabajo físico, sino que también pueden causar una acumulación de lesiones por sobreuso, lo cual pone en peligro la salud del deportista y su permanencia en el deporte. Como apuntan Forteza y Ramírez (2007), la planificación del entrenamiento debe incluir no únicamente el aumento progresivo de las cargas, sino también la corrección continua de la técnica. Esto ocurre porque un gesto equivocado que se repite de manera sistemática puede, a la larga, originar micro lesiones que pueden transformarse en problemas crónicos. En el powerlifting, las articulaciones y la zona lumbar son las áreas donde con frecuencia aparecen estas dolencias, lo que tiene un impacto negativo en la capacidad para entrenar y en el rendimiento competitivo a largo plazo[7].

Cuando los deportistas no reciben correcciones a tiempo y eficaces en su técnica, enfrentan ineludiblemente un estancamiento de su desempeño. Según Calleja y Lorenzo (s. f.), la calidad del entrenamiento, el método utilizado y la continua corrección de errores son determinantes para el desarrollo deportivo, Debido a que sin ellos es difícil obtener la mejora progresiva que distingue a los procesos de alto rendimiento. En este contexto, la falta de adecuada retroalimentación técnica provoca que los deportistas entrenen con patrones ineficientes, lo que restringe su habilidad para incrementar la fuerza, la resistencia y la potencia. Esto no solo impide el progreso en las marcas personales, sino que además disminuye la motivación del atleta cuando no ve resultados evidentes de sus esfuerzos[8].

La falta de progreso o la reaparición de lesiones tienen un efecto psicológico que no se puede subestimar, Debido a que pueden resultar en frustración y, en circunstancias más graves, en el abandono del deporte. Vélez (2023) manifiesta que los atletas que entrenan sin una supervisión técnica apropiada pueden experimentar sensaciones de desmotivación, en particular cuando no

obtienen los resultados esperados. En disciplinas de alta exigencia como el powerlifting, donde la técnica es crucial para lograr el éxito y evitar lesiones, repetir errores sin corregir puede dar lugar a un círculo vicioso en el que se estanca uno y se frustra. Esto incrementa la posibilidad de que los deportistas pierdan interés en el entrenamiento, se alejen del deporte o busquen otras opciones deportivas con requisitos menos exigentes[9].

Por otro lado, la implementación de modelos de inteligencia artificial (IA) para el monitoreo y la corrección técnica ofrece una solución innovadora y transformadora

Implementar modelos de inteligencia artificial (IA) se muestra, frente a esta problemática, como una alternativa transformadora para monitorear y mejorar la técnica. Camacho, Chicaiza, Ghose y Castro (2023) subrayan que las aplicaciones de IA permiten el análisis de información en tiempo real y la creación de feedback instantáneo, lo cual supone una transformación drástica en los procedimientos de aprendizaje y enseñanza. En el contexto del powerlifting, esta perspectiva permitiría detectar de manera inmediata fallos en la ejecución y brindar instrucciones precisas al deportista para corregirlos antes de que se transformen en una rutina dañina. Así pues, los adelantos tecnológicos se utilizan para apoyar la labor de los entrenadores y elevar la calidad del entrenamiento[10].

La adecuada realización técnica no solo evita lesiones, sino que además optimiza las ventajas del entrenamiento, lo que posibilita a los atletas avanzar en fuerza y habilidades de forma eficaz y segura. De acuerdo con Campuzano (2014), los métodos de entrenamiento de la resistencia y la fuerza se optimizan notablemente cuando se llevan a cabo siguiendo parámetros técnicos específicos. Esto garantiza que los grupos musculares se activen correctamente y que la energía se utilice de manera apropiada. Por lo tanto, supervisar de manera continua la técnica asegura que los deportistas no malgasten esfuerzos en movimientos que se ejecutan incorrectamente y que alcancen un desarrollo balanceado; así, el rendimiento deportivo se optimiza sin poner en riesgo su salud[11].

En el campo deportivo, la incorporación de herramientas de inteligencia artificial permite la posibilidad de crear un nuevo estándar para la supervisión y corrección técnica. La IA posibilita la personalización del análisis de rendimiento y la adecuación de los entrenamientos a las particularidades individuales de cada deportista, lo cual, según Cejudo (s. f.), democratiza el acceso a programas profesionales de alta calidad. Esto implica que en el powerlifting, los deportistas de

diferentes niveles tendrán acceso a un soporte tecnológico avanzado, incluso cuando no haya un entrenador presente físicamente, lo cual disminuirá errores y propiciará el progreso constante[12].

La meta de este proyecto es satisfacer estas necesidades mediante la creación y ejecución de un sistema que, apoyándose en inteligencia artificial, pueda supervisar y corregir la técnica en tiempo real. De acuerdo con Cejudo (s. f.), emplear inteligencia artificial para personalizar la formación posibilita una experiencia más eficaz y adaptada a las demandas particulares de cada persona, lo cual no solo propicia el aumento del rendimiento, sino que además garantiza seguridad durante todo el proceso. La meta es fomentar una formación más profesional y asequible, enfocada en lograr resultados sostenibles y utilizando las ventajas que ofrece la tecnología para cambiar la práctica del powerlifting [13].

E. FORMULACIÓN DEL PROBLEMA

¿Cuál de los modelos de inteligencia artificial basados en visión por computador presenta la mayor eficiencia de predicción en la detección de errores durante la ejecución de ejercicios de powerlifting?

F. OBJETIVOS

1) Objetivo general

Evaluar la eficiencia de un grupo de algoritmos de visión artificial para la clasificación de errores en la ejecución de ejercicios de powerlifting mediante la relación entre el área bajo la curva ROC y el tiempo de predicción.

2) Objetivos específicos

- Generar un data set compuesto por videos de ejecuciones de ejercicios multi articulares de powerlifting etiquetados mediante expertos.
- Preprocesar el conjunto de datos para eliminar las componentes espaciales y temporales que causen ruido mediante técnicas de imagen cleaning.
- Estructurar una matriz comparativa de modelos de visión artificial implementados con redes neuronales artificiales y sus correspondientes métricas de calidad (Accuracy, F1, AUC) en cuanto

a la detección de errores en ejercicios de powerlifting en un data set de videos previamente preprocesados para determinar la eficiencia de cada modelo.

G. JUSTIFICACIÓN

El powerlifting es una disciplina de alta exigencia técnica, donde la correcta ejecución de los movimientos no solo mejora el rendimiento, sino que también reduce significativamente el riesgo de lesiones [14]. No obstante, el análisis de la técnica en este tipo de ejercicios puede ser complejo y, a menudo, requiere la presencia de entrenadores experimentados para detectar y corregir errores. Dado el creciente número de atletas que entrenan de manera autónoma o sin supervisión constante, se vuelve cada vez más necesario contar con herramientas tecnológicas que permitan supervisar y corregir la técnica de forma precisa y eficiente [15]. La automatización de este proceso a través del uso de inteligencia artificial (IA) y visión artificial responde a esta necesidad, ofreciendo una solución innovadora que no solo optimiza el rendimiento, sino que también previene posibles lesiones. De acuerdo con estudios previos se espera encontrar patrones que puedan servir como base para otros tipos de ejercicios, el uso de IA en deportes ha demostrado ser prometedor en la mejora de la técnica y el rendimiento de los atletas [16]. Por tanto, esta investigación resulta pertinente, Debido a que introduce una solución tecnológica adaptada a las necesidades actuales del powerlifting, proporcionando un enfoque novedoso y práctico para mejorar la seguridad y eficiencia en el entrenamiento [17].

Este estudio se diferencia de investigaciones previas en su enfoque específico hacia el powerlifting, una disciplina que involucra movimientos multiarticulares complejos y el manejo de cargas pesadas. Aunque existen trabajos sobre el análisis de técnicas en deportes como el fútbol o el atletismo, pocos abordan los desafíos técnicos del powerlifting, donde la precisión en cada movimiento es esencial para evitar lesiones graves [18]. La mayoría de los sistemas actuales utilizan modelos generales de análisis de postura que no están adaptados a la particularidad de los movimientos y la intensidad de los ejercicios en el powerlifting [19]. Este estudio introduce un modelo especializado que, mediante el uso de redes neuronales convolucionales (CNN) y visión computacional, no solo identifica errores de postura, sino que también los corrige en tiempo real, permitiendo la personalización de los entrenamientos según las necesidades individuales de cada atleta. Además, el sistema propuesto no depende de la presencia constante de un entrenador, lo que lo hace más accesible y útil para una mayor cantidad de deportistas [20].

De este modo, la novedad radica en que este estudio se distingue por su enfoque específico hacia el powerlifting, un deporte que requiere precisión en movimientos multiarticulares y manejo de cargas pesadas. A diferencia de los sistemas tradicionales, que utilizan modelos generales de análisis de postura, este estudio introduce un modelo especializado con redes neuronales convolucionales (CNN) y visión computacional para detectar y corregir errores en tiempo real, adaptándose a las necesidades de cada atleta. Esto permite una retroalimentación personalizada sin la intervención constante de un entrenador, lo que lo hace más accesible. A diferencia del estado del arte, que no se ajusta a la complejidad del powerlifting, este modelo de IA ofrece una solución autónoma que mejora la técnica, reduce el riesgo de lesiones y optimiza el rendimiento de los atletas de manera más eficiente y sostenible [14].

El principal aporte de esta investigación a la disciplina de la ingeniería de sistemas y a la línea de investigación en visión artificial radica en el desarrollo de un sistema autónomo y preciso para el análisis y corrección de la técnica en powerlifting [21]. Desde un punto de vista técnico, el sistema propuesto integrará diversas tecnologías avanzadas de IA, como redes neuronales profundas y algoritmos de visión computacional, para analizar y corregir movimientos de forma automática. Este enfoque no solo contribuirá al avance en la automatización del análisis de técnica deportiva, sino que también abrirá nuevas posibilidades para la personalización de entrenamientos en función de las características físicas y habilidades de cada atleta [22]. Desde una perspectiva teórica, este trabajo aportará conocimientos valiosos sobre cómo aplicar modelos de IA en contextos deportivos complejos, lo que puede inspirar nuevas investigaciones en otras áreas del deporte. A nivel práctico, el sistema generado podrá ofrecer retroalimentación instantánea y personalizada, lo que permitirá mejorar tanto el rendimiento deportivo como la seguridad en los entrenamientos, sin la necesidad de supervisión constante [23]. Este avance en la automatización del análisis técnico es un paso importante hacia la integración de la inteligencia artificial en el ámbito deportivo, haciendo que el entrenamiento sea más eficiente, accesible y seguro para los deportistas [24].

Uso del proyecto

La Inteligencia Artificial es esencial Debido a que nos brinda la posibilidad de enseñar a las máquinas a comprender y aprender de los movimientos de los atletas, un proceso que resultaría muy complicado de realizar únicamente con el ojo humano. Mediante la Inteligencia Artificial, tenemos la capacidad de desarrollar un sistema que no solo estudie los movimientos, sino que

también adquiriera conocimientos y se ajuste conforme los deportistas mejoran o transforman su estilo. En esta situación, se emplearán redes neuronales para identificar y rectificar los fallos en el método de cada actividad física, asistiendo a los atletas en la optimización de su desempeño y en la disminución del peligro de sufrir daños.

El sistema de visión por computadora actúa como los "ojos" del sistema, permitiendo al "entrenador virtual" ver instantáneamente todo lo que hace el atleta. La cámara es como un ojo vigilante, siempre pendiente de cada acción sin perderse ni un solo detalle. Los atletas son como un mentor invisible que nunca parpadea. Al interpretar algoritmos de captura de imágenes, la visión por computadora se convierte en un observador preciso capaz de detectar los movimientos más pequeños. Luego, esta información se envía a la inteligencia artificial, que reacciona instantáneamente, como un entrenador, haciendo ajustes y ajustes según sea necesario.

La inteligencia artificial y la visión por computadora forman un dúo poderoso, del mismo modo que el cerebro y los ojos trabajan juntos. Se complementan perfectamente y forman un sistema que no sólo observa, sino que también comprende y adapta el entrenamiento de forma independiente. El resultado es un entrenamiento continuo y personalizado, como si el atleta tuviera siempre una guía experta sin la presencia física de un entrenador.

H. DELIMITACIÓN

Este proyecto se desarrollará mediante experimentos con bases de datos obtenidos de herramientas de repositorio. Los modelos serán entrenados utilizando Redes Neuronales (ANN) y utilizaremos modelos para la detección de imágenes utilizados en transferir learning y detección de posturas como los son: YOLO, OpenPose, HRNet. Para la evaluación de los modelos, se utilizarán métricas de clasificación enfocadas en la exactitud y el tiempo de ejecución [28].

El proyecto se desarrollará en un tiempo estimado de 18 meses, comenzando en el periodo B del año 2024 y finalizando en el periodo B de 2025.

II. MARCO TEÓRICO

A. ANTECEDENTES

1) *Internacionales*

“Sistema electrónico de monitoreo para la detección y área”. Autor Rodrigo Palacios Sánchez, Año: 2021, UTA- Universidad técnica de Ambato.

Este proyecto presenta un sistema innovador que utiliza tecnología de visión artificial y sensores para ayudar a los deportistas a mejorar su técnica en el levantamiento de peso muerto y prevenir lesiones. Mediante el análisis de videos y el monitoreo del ritmo cardíaco, el sistema proporciona retroalimentación en tiempo real sobre la postura y el movimiento del atleta. Al combinar software de programación como Python con hardware como una Raspberry Pi, se ha desarrollado una herramienta útil para cualquier persona interesada en optimizar su entrenamiento y reducir el riesgo de lesiones relacionadas con este ejercicio [29].

El anterior proyecto aporta una solución tecnológica innovadora que aborda los problemas asociados con la ejecución incorrecta del levantamiento de peso muerto. Al utilizar visión artificial, sensores y hardware accesible, ofrece un enfoque práctico para proporcionar retroalimentación en tiempo real sobre la postura y el movimiento del atleta. Esto resulta relevante para el documento, Debido a que plantea herramientas que pueden reducir el riesgo de lesiones, optimizar la técnica y compensar la falta de supervisión constante en los ejercicios de powerlifting.

“Automatic Wireless Mapping and Tracking System for Indoor Location”. Autores: André Sales Mendes - Gabriel Villarrubia - Javier Caridad - Daniel H. De La Iglesia - Juan F. De Paz, Año: 2019, “Sciencedirect”

Esta tesis doctoral explora la aplicación de la inteligencia artificial en tres escenarios distintos, aprovechando el avance de las redes de sensores inalámbricas y la potencia de procesamiento actual. Se presentan soluciones innovadoras para la localización en interiores, la rehabilitación asistida por exoesqueletos y la monitorización de espacios públicos. Estas soluciones se basan en técnicas como el aprendizaje automático, la minería de datos y la inteligencia artificial distribuida, demostrando cómo la tecnología puede resolver problemas cotidianos de manera eficiente [30].

El anterior proyecto es relevante para el documento, Debido a que demuestra cómo la inteligencia artificial, aplicada en diversos escenarios, puede ofrecer soluciones innovadoras y eficientes. Esto respalda la viabilidad de incorporar tecnologías avanzadas, como aprendizaje automático y sensores, en el desarrollo de herramientas para mejorar la técnica en el powerlifting. Además, aporta un marco conceptual sobre cómo la tecnología puede abordar problemas cotidianos, incluyendo la prevención de lesiones y la optimización del rendimiento deportivo.

“Aplicación en Android para la medida de la velocidad en el entrenamiento deportivo con peso”. Autores: Aragó Palero J, Año: 2022, “Universidad Politécnica de Valencia”.

Este proyecto propone desarrollar una aplicación móvil para Android que permita medir la velocidad de ejecución de ejercicios de levantamiento de pesas utilizando la cámara del dispositivo. La aplicación se basará en técnicas de visión por computadora para realizar un seguimiento preciso de la pesa a lo largo de toda la trayectoria del movimiento, y posteriormente calcular la velocidad y aceleración instantáneas. Los resultados se presentarán de forma gráfica, proporcionando al usuario una herramienta valiosa para optimizar su entrenamiento y rehabilitación [26].

El anterior proyecto es útil para el documento, Debido a que propone el uso de visión por computadora para medir parámetros clave en la ejecución de ejercicios de levantamiento de pesas, como la velocidad y la aceleración. Esto demuestra cómo las tecnologías móviles pueden ser aplicadas para ofrecer retroalimentación precisa y accesible. Su enfoque en la optimización del entrenamiento y la rehabilitación refuerza la importancia de desarrollar herramientas prácticas para mejorar la técnica y prevenir lesiones en el powerlifting.

“Nutricore: la aplicación fitness impulsada por la psicología y la inteligencia artificial”. Autores: Espadas Ñíguez D, Año: 2023, “Universidad Miguel Hernández”

Este proyecto de investigación propone un enfoque innovador para abordar los problemas sociales relacionados con los estándares de belleza irreales y el estigma asociado al fitness y el culturismo. A través de un análisis psicológico profundo, se buscará comprender los factores que contribuyen a estas percepciones negativas y desarrollar una estrategia comunicativa efectiva para promover un cambio de mentalidad [31].

El anterior proyecto es relevante para el documento al ofrecer un enfoque innovador que aborda cuestiones sociales relacionadas con el fitness, como los estándares de belleza irreales y el estigma

asociado al culturismo. Aunque se centra en el ámbito psicológico y comunicativo, su importancia radica en cómo puede contribuir a cambiar la percepción pública sobre el entrenamiento y el físico ideal. Esto complementa tu investigación, al ofrecer una perspectiva integral que no solo se centra en la técnica y prevención de lesiones, sino también en la dimensión social y mental del deporte.

“PowerLog Móvil. Una aplicación móvil para la gestión de entrenamientos con componentes sociales para atletas y entrenadores”. Autores: T. Fin de Grado - M. Tamarit, Año: 2023, “Universidad Politécnica de Valencia”

Este trabajo de investigación documenta el proceso completo de desarrollo de una aplicación móvil y su sistema backend asociado. La idea surgió de la necesidad de crear una herramienta para gestionar entrenamientos de atletas de manera más eficiente. El documento detalla cada etapa del proyecto, desde la concepción inicial hasta las pruebas con usuarios reales. Se incluyen aspectos como el diseño, la implementación, el despliegue y la evaluación de la aplicación. Finalmente, se presentan propuestas para futuras mejoras y se extraen conclusiones sobre todo el proceso [32].

El anterior proyecto es útil para el documento, Debido a que presenta el desarrollo de una aplicación móvil diseñada para gestionar entrenamientos de manera eficiente. Esta experiencia es valiosa, Debido a que proporciona un enfoque estructurado para la creación de herramientas tecnológicas que pueden ser aplicadas en el ámbito del powerlifting, como en el caso de una aplicación que permita monitorear la técnica y progresión de los deportistas. Además, el enfoque en la evaluación y mejora continua del sistema puede ser clave para el desarrollo de herramientas de retroalimentación que optimicen la técnica y reduzcan el riesgo de lesiones en el entrenamiento.

2) Nacionales

“La inteligencia artificial como herramienta para la toma de decisiones en el deporte: "casos de éxito”. Autores: Juan Camilo Rubiano Rojas, Año: 2024, “Universidad Distrital Francisco José de Caldas”

El documento analiza el potencial de la Inteligencia Artificial (IA) para revolucionar el ámbito deportivo en Colombia. Se resalta la necesidad de un enfoque estratégico que considere las particularidades del contexto nacional y promueva la colaboración entre diversas instituciones. La implementación exitosa de la IA en el deporte colombiano requiere una inversión significativa en capacitación de profesionales, el fomento de la innovación a través de startups y la adopción

gradual de tecnologías. Los beneficios potenciales incluyen la mejora del rendimiento deportivo, la identificación de nuevos talentos y la obtención de una ventaja competitiva a nivel internacional. No obstante, se advierte sobre los desafíos asociados a esta transformación, como la escasez de recursos económicos, la necesidad de garantizar la ética y la privacidad en el manejo de datos, así como la adaptación de las normativas existentes. En conclusión, el texto presenta un panorama completo de las oportunidades y desafíos que plantea la integración de la IA en el deporte colombiano, subrayando la importancia de una implementación responsable y estratégica para aprovechar al máximo su potencial [33].

El anterior proyecto es relevante para el documento, Debido a que subraya el potencial de la Inteligencia Artificial (IA) en el ámbito deportivo, un concepto que puede ser clave para mejorar la técnica y la prevención de lesiones en el powerlifting. Al resaltar la necesidad de una implementación estratégica de la IA, este enfoque ofrece un marco que podría ser adaptado a tu investigación, permitiendo el uso de tecnologías avanzadas para optimizar el entrenamiento y el rendimiento deportivo. Además, plantea desafíos importantes como la capacitación profesional y la adaptación de normativas, aspectos que también son esenciales al integrar nuevas tecnologías en el entrenamiento deportivo.

“Seguimiento y evaluación de personas en ambientes cerrados / abiertos”. Autores: Cruz Ángel - Bryan Santiago, Año: 2021, “Escuela Colombiana de Ingeniería Julio Garavito”.

El presente trabajo propone un sistema de vigilancia automatizado basado en inteligencia artificial para centros de salud y ancianatos. Utilizando los algoritmos YOLOv3 y DeepSORT, se busca desarrollar un programa en Python capaz de detectar y rastrear personas en tiempo real, evaluando su actividad física. Esta solución, que presenta ventajas como ser no invasiva, de bajo costo y altamente eficiente, permitiría un monitoreo más constante de pacientes con condiciones neurológicas. No obstante, se identifican desafíos como la oclusión de personas en las imágenes y la alta demanda computacional para procesar un gran número de personas simultáneamente [34].

El anterior proyecto es relevante para el documento, Debido a que propone un sistema basado en inteligencia artificial para el monitoreo en tiempo real, un concepto que puede adaptarse al seguimiento de la técnica en el powerlifting. Al utilizar algoritmos avanzados como YOLOv3 y DeepSORT, se establece un enfoque tecnológico para la detección y el análisis de movimientos, lo cual es aplicable a la corrección de la postura y la prevención de lesiones en los ejercicios de

levantamiento de pesas. Además, los desafíos identificados, como la demanda computacional, pueden ser considerados al desarrollar soluciones accesibles y eficientes para entrenamientos deportivos.

“Detección de FOD por medio de inteligencia artificial con inspecciones por UAV”. Autores: Duvan Forero – Andres Albarracín, Año: 2022, “Fundación Universitaria Los Libertadores”

El proyecto aborda el problema de los objetos extraños (FOD) en pistas de aterrizaje, una amenaza significativa para la seguridad aérea. Se propone una solución innovadora que utiliza drones equipados con cámaras y algoritmos de inteligencia artificial para detectar de forma autónoma estos objetos. Mediante el entrenamiento de una red neuronal convolucional con miles de imágenes, el sistema logra identificar los FOD con una alta precisión. Las pruebas de campo realizadas en un aeropuerto demostraron la eficacia de la solución, determinando la altitud óptima de vuelo para obtener los mejores resultados. Esta tecnología tiene el potencial de revolucionar las inspecciones de pistas de aterrizaje, mejorando la seguridad y reduciendo costos [35].

El anterior proyecto es relevante para el documento al presentar el uso de drones y algoritmos de inteligencia artificial para la detección autónoma de objetos, un concepto que podría adaptarse para monitorear la técnica en ejercicios de powerlifting. Al emplear redes neuronales convolucionales para analizar imágenes, el sistema demuestra cómo la IA puede mejorar la precisión en la identificación de errores técnicos, similar a cómo se podrían detectar fallos en la postura durante los levantamientos. Además, la eficiencia demostrada en las pruebas de campo resalta el potencial de las tecnologías avanzadas para optimizar el seguimiento y la corrección de la técnica en tiempo real.

“Desarrollo de una plataforma tecnológica para la publicación de objetos de aprendizaje personalizados, aplicados al uso correcto de los gimnasios al aire libre, en dispositivos móviles”. Autores: Ingrid Torres - Santiago Román - Jaime Guzmán-Luna, Año: 2018, “Universidad De Antioquia”

El estudio propone el desarrollo de una aplicación móvil basada en inteligencia artificial para mejorar la experiencia de los usuarios en gimnasios públicos al aire libre. Esta herramienta, denominada PublicGym, personaliza las rutinas de ejercicio según el perfil de cada usuario, considerando factores como su condición física, estado de salud y objetivos. La aplicación utiliza

objetos de aprendizaje y un sistema de reglas para recomendar ejercicios adecuados y seguros, además de ofrecer instrucciones claras y motivacionales. A través de una encuesta a usuarios de gimnasios públicos en Medellín, se identificó una necesidad significativa de orientación y supervisión durante el entrenamiento, especialmente en personas con condiciones de salud preexistentes. Los resultados del estudio resaltan la importancia de brindar información precisa y personalizada sobre la ejecución correcta de los ejercicios y los beneficios del ejercicio físico para diferentes poblaciones [36].

El anterior proyecto es útil para el documento, Debido a que presenta el desarrollo de una aplicación móvil basada en inteligencia artificial que personaliza rutinas de ejercicio y proporciona supervisión en tiempo real, lo cual puede ser adaptado al ámbito del powerlifting. Su enfoque en la personalización de los entrenamientos según el perfil del usuario y la corrección de la técnica resalta cómo las tecnologías pueden abordar la falta de supervisión y mejorar la ejecución correcta de los ejercicios. Además, el énfasis en la seguridad y la salud de los usuarios es clave para prevenir lesiones en deportes de alta exigencia, como el powerlifting.

“Un sistema recomendado móvil de rutinas de ejercicio basado en el perfil del usuario”. Autores: Jaime Guzmán-Luna, Ingrid-Durley Torres, Sebastián Vallejo, Año: 2019, “Universidad Nacional de Colombia, Medellín, Colombia”

Este artículo, describe la investigación y el desarrollo de un sistema recomendado móvil que usando técnicas de Inteligencia Artificial (IA), permite sugerir rutinas de ejercicio, orientadas a fortalecer la calidad de vida del usuario basándose en su perfil antropomórfico y patológico [37].

El anterior proyecto es relevante para el documento, Debido a que propone un sistema basado en inteligencia artificial para recomendar rutinas de ejercicio personalizadas, adaptadas al perfil del usuario. Este enfoque puede ser aplicado al powerlifting para ajustar entrenamientos según las necesidades individuales, como condiciones físicas o posibles limitaciones. La utilización de IA para optimizar las rutinas y prevenir lesiones proporciona un modelo útil para mejorar la ejecución técnica y la seguridad de los deportistas, abordando problemas similares a los identificados en tu investigación.

3) Regional

“Implementación De una red neuronal para la clasificación de imágenes histológicas de cáncer de mama”. Autores: José David Guaquez Tulcán - Julieth Villarreal Celis, Año: 2024, “Universidad Mariana”

Este estudio se centra en mejorar la clasificación de imágenes histológicas de biopsias de mama teñidas con hematoxilina y eosina utilizando redes neuronales convolucionales (CNN). El objetivo es optimizar la detección temprana del cáncer de mama, superando las limitaciones de precisión y rapidez de los métodos de diagnóstico convencionales. Se seleccionó el conjunto de datos BACH por su alta calidad y relevancia clínica. Para facilitar el procesamiento, las imágenes se transformaron de formato TIFF a PNG y se redujo su resolución, manteniendo la información esencial. Este enfoque no solo mejoró la eficiencia del análisis, sino que también contribuyó al desarrollo de tecnologías más robustas para el diagnóstico automatizado por imágenes médicas, impulsando futuras investigaciones en la detección temprana del cáncer [38].

El anterior proyecto es útil para el documento al demostrar cómo las redes neuronales convolucionales (CNN) pueden mejorar la precisión y eficiencia en el análisis de imágenes, un enfoque que podría aplicarse para monitorear la técnica en el powerlifting. Aunque el contexto es médico, el uso de técnicas avanzadas de procesamiento de imágenes para detectar patrones puede adaptarse al análisis de la postura y el movimiento en los ejercicios. Este estudio resalta la importancia de la automatización y el procesamiento eficiente de datos visuales, principios que son fundamentales para el desarrollo de herramientas que mejoren la ejecución técnica y la prevención de lesiones en el ámbito deportivo.

“Sistema de escaneo 3d para desarrollo de férulas posturales de antebrazo, muñeca y mano para la Universidad Mariana.” Autores: Kevin Adam Mora Solarte, Año: 2021, “Universidad Mariana”

Se desarrolló un sistema para escanear extremidades superiores, especialmente antebrazos, muñecas y manos con discapacidades, utilizando el escáner 3D Sense™2. Este sistema permite obtener un registro digital de la extremidad y, mediante programas CAD, diseñar férulas estáticas personalizadas que se pueden imprimir en 3D con materiales como PLA o ABS. El objetivo es digitalizar con alta precisión las medidas de la mano, facilitando la creación de férulas para patologías como el síndrome del túnel carpiano y tenosinovitis de Quervain. Este enfoque mejora el proceso de fabricación, reduciendo el tiempo de digitalización a solo 5 minutos y permitiendo la creación de férulas adaptadas a las necesidades específicas de cada paciente. Se eligió el escáner

3D Sense™2 por su relación costo-beneficio, ofreciendo alta precisión en la digitalización y un software de procesamiento eficiente. El proyecto busca optimizar recursos en tratamientos médicos y mejorar el bienestar de la comunidad afectada [39].

El anterior proyecto es relevante para el documento, Debido a que presenta un sistema de escaneo 3D que utiliza tecnología avanzada para obtener registros digitales precisos, lo cual podría adaptarse al análisis de la técnica en ejercicios de powerlifting. Aunque se enfoca en la creación de férulas personalizadas, el principio de digitalización precisa de extremidades puede trasladarse al seguimiento y corrección de la postura en los levantamientos. Además, el uso de tecnología accesible y eficiente para optimizar recursos en el ámbito médico es un modelo aplicable para mejorar la accesibilidad y efectividad en la corrección de la técnica deportiva.

“Desarrollo de un rostro animatrónica que identifique y emule las micro expresiones del rostro humano para la divulgación científica de la ingeniería mecatrónica mediante inteligencia artificial.”
Autores: Juan David Martínez Bermúdez - Nelson Ricardo Caicedo Rivera, Año: 2021
“Universidad Mariana”.

El proyecto se centró en el desarrollo de un rostro animatrónica capaz de identificar y replicar micro expresiones humanas, con el objetivo de promover la comprensión de la ingeniería mecatrónica mediante la divulgación científica. Se utilizó una metodología de investigación experimental cuantitativa, que incluyó una revisión sistemática en bases de datos como Scopus y ScienceDirect, enfocándose en mecanismos faciales, micro expresiones y algoritmos de detección facial. El análisis cinemático en SolidWorks ayudó a entender el movimiento de los mecanismos, mientras que se evaluó la funcionalidad del algoritmo de reconocimiento facial basado en MediaPipe y OpenCV mediante pruebas iterativas. Para medir la eficacia de la divulgación científica, se implementó un grupo de control, resultando en una aceptación del 92% en el aprendizaje de conceptos de ingeniería mecatrónica [40].

El anterior proyecto es útil para el documento, Debido a que demuestra el desarrollo de un sistema capaz de identificar y replicar expresiones faciales utilizando tecnología avanzada de reconocimiento y animatrónica. Aunque el enfoque es en la ingeniería mecatrónica, los principios de análisis de movimientos y la integración de algoritmos para mejorar la precisión en la detección de expresiones pueden ser aplicados al seguimiento de la técnica en powerlifting. La utilización de tecnologías como MediaPipe y OpenCV ofrece un marco para desarrollar sistemas de

retroalimentación visual que puedan mejorar la ejecución técnica y la corrección de la postura en tiempo real.

“Proceso de sanación mediante arte terapia. espacio para el entendimiento de la huida del cuerpo”.
Autores: Delgado, Mario Fernando, Año:2019, “Universidad de Nariño”

Muchas personas se sienten inconformes con su apariencia física, lo que puede llevar al rechazo de su propio cuerpo y a una baja autoestima. Esta situación a menudo resulta en aislamiento y desprecio personal. Para abordar este problema, se propone un espacio terapéutico enfocado en el arte, utilizando técnicas como el dibujo y la pintura. El objetivo es ofrecer a los afectados un camino hacia la sanación y la aceptación de sus condiciones, redefiniendo su percepción físico-emocional. La propuesta busca mantener el equilibrio entre mente y cuerpo, reduciendo o superando las afecciones causadas por la autopercepción negativa. Comienza con el deseo de superación y el reconocimiento corporal, avanza hacia la reconstrucción de la imagen a través del arte y culmina en la redefinición del ser mediante imágenes pictóricas abstractas [41].

El anterior proyecto es relevante para el documento, Debido a que aborda la importancia de la percepción corporal y el bienestar emocional, temas que también son fundamentales en el contexto del entrenamiento deportivo. Al proponer un espacio terapéutico que utiliza el arte para mejorar la autopercepción, este enfoque puede complementar la investigación sobre la ejecución de ejercicios en powerlifting, Debido a que la autoconfianza y la aceptación del cuerpo son claves para una ejecución técnica óptima y la prevención de lesiones. Además, el equilibrio entre cuerpo y mente que promueve el proyecto puede ser fundamental para ayudar a los deportistas a mantener una mentalidad positiva y mejorar su rendimiento físico.

“Diseño e implementación de un sistema neuro-difuso de obtención y clasificación general de curvas de luz de cuerpos celestes para el observatorio astronómico de la Universidad de Nariño.”
Autores: Romo Moreno - Nathalie Portilla; Cabrera - María Ximena, Año:2021, “Universidad de Nariño”

Este trabajo de investigación presenta el diseño e implementación de un sistema que utiliza técnicas de fotometría diferencial e inteligencia artificial para obtener la curva de luz de objetos celestes y clasificarlos en patrones establecidos, como constantes, asteroides, eclipsantes y otras estrellas variables, a partir de un conjunto de imágenes astronómicas. El sistema, denominado LCC (Light

Curve Classification) UDENAR, se desarrolla como una herramienta de apoyo para las investigaciones del Observatorio Astronómico de la Universidad de Nariño. Además, se introducen diversas técnicas de clustering, incluyendo FCART (Fuzzy Classification And Regression Trees), FCM (Fuzzy C-Means) y Subtractive Clustering, así como conceptos de sistemas neuro-difusos como ANFIS (Adaptive Neural Fuzzy Inference System) y SFAM (Simplified Fuzzy ARTMAP), que son utilizados para crear y entrenar sistemas de clasificación de curvas de luz de cuerpos celestes [42].

El anterior proyecto es relevante para el documento al presentar el uso de técnicas avanzadas de clasificación e inteligencia artificial para analizar patrones y realizar clasificaciones precisas, lo cual podría aplicarse a la detección de errores en la ejecución de ejercicios de powerlifting. Al igual que el sistema LCC para clasificar objetos celestes, un sistema similar basado en IA y técnicas de clustering podría analizar y clasificar la técnica de los levantamientos, ayudando a identificar patrones de movimiento incorrectos o ineficientes. Esto permitiría una retroalimentación más precisa y objetiva para mejorar la técnica y prevenir lesiones.

B. SUPUESTOS TEÓRICOS DE LA INVESTIGACIÓN

1) Powerlifting

Esta sección desglosa los aspectos técnicos de tres ejercicios fundamentales en powerlifting: press de banca, sentadilla libre y peso muerto. Para cada ejercicio, se consideran distintos elementos críticos para la ejecución correcta, que el sistema de monitoreo observará y evaluará [43].



Fig. 1. Ejercicios de powerlifting

Fuente: Panorama Perspectives Blog [44]

Press de banca:

Posición inicial: Evalúa la postura correcta del levantador en el banco, el agarre de la barra y la alineación corporal antes de comenzar el movimiento.

Trayectoria de la barra: Analiza el recorrido de la barra desde el inicio hasta el final del levantamiento, asegurando que se mantenga en la trayectoria óptima para evitar lesiones y mejorar la eficiencia.

Rodillas: Observa la posición y estabilidad de las rodillas, Debido a que estas deben mantenerse firmes y en el ángulo adecuado durante el ejercicio.

Posición final: Verifica que el levantador haya alcanzado una posición final adecuada, con los brazos extendidos y la barra alineada correctamente [45].



Fig. 2. Ejercicio powerlifting press de banca

Fuente: Saleh [46]

Sentadilla libre:

Posición inicial: Examina la colocación de los pies, la postura de la espalda y la posición de la barra al inicio del ejercicio.

Trayectoria de la barra: Monitorea el desplazamiento vertical de la barra, asegurando que siga una línea recta o ligeramente curva que permita una ejecución eficiente.

Rodillas: Controla la alineación y el movimiento de las rodillas para evitar que se desplacen hacia adentro o hacia afuera de forma inapropiada.

Posición final: Valida que el levantador haya vuelto a la posición inicial con la barra en equilibrio y una postura adecuada [47].



Fig. 3. Ejercicio de powerlifting sentadilla

Fuente: Pinterest [48]

Peso muerto:

Posición inicial: Revisa la postura de la espalda, la posición de los pies y el agarre en la barra al inicio.

Trayectoria de la barra: Supervisa el movimiento de la barra durante el levantamiento, asegurando una trayectoria que minimice la distancia recorrida y maximice la eficiencia.

Rodillas: Evalúa el ángulo de las rodillas y su posición en relación con los pies, asegurando un correcto impulso desde las piernas.

Posición final: Comprueba que el levantador esté completamente erguido con la barra en las manos y que se mantenga el equilibrio [49].



Fig. 4. Ejercicio de powerlifting peso muerto

Fuente: Pinterest [50]

2) Metodologías para el monitoreo y técnica de ejercicios de powerlifting

Este componente utiliza tecnologías avanzadas para capturar y analizar el movimiento y la postura en tiempo real. Las metodologías principales son la detección de objetos y el análisis de postura [51].




Fig. 5. Monitoreo de diferentes ejercicios

Fuente: García [52]

Detección de objetos. Seguimiento de objeto en tiempo real: Utiliza algoritmos de visión por computadora para identificar y rastrear la barra y las principales articulaciones (hombros, codos, rodillas, caderas) del levantador. Esto permite monitorear cómo se mueve cada componente del cuerpo en relación con el equipo, proporcionando datos en tiempo real sobre la técnica de ejecución [53].

El seguimiento de objetos en tiempo real es clave en aplicaciones de visión por computadora para analizar ejercicios físicos. En el caso del powerlifting, los algoritmos identifican y rastrean elementos como la barra y articulaciones críticas (hombros, codos, rodillas, caderas). Se pueden usar modelos como YOLO (You Only Look Once) o DeepSORT, que combinan detección de objetos con algoritmos de seguimiento eficiente. Estos modelos permiten determinar trayectorias y patrones de movimiento, comparando en tiempo real con referencias ideales y facilitando la retroalimentación instantánea.



Fig. 6. Detección de objetos y videos

Fuente: OMES [53]

Análisis de postura. Seguimiento de movimientos en tiempo real: Se emplea para observar el alineamiento y el ángulo de las distintas partes del cuerpo durante el ejercicio. Mediante el seguimiento en tiempo real, se pueden corregir desalineaciones y mejorar la postura.

Análisis de video: Permite revisar la ejecución del ejercicio en detalle tras su realización. Esto puede incluir la generación de visualizaciones gráficas que muestren ángulos, trayectorias y otros parámetros críticos. Es una herramienta útil para el análisis post-ejercicio y para la mejora progresiva del usuario [54]. El seguimiento en tiempo real evalúa el alineamiento del cuerpo durante el ejercicio. Esto se logra mediante herramientas como OpenPose o MediaPipe, que generan mapas de calor de las posiciones articulares, calculando ángulos y distancias entre puntos clave. La capacidad de monitorear estos aspectos permite prevenir lesiones al corregir desalineaciones antes de que se agraven.




Fig. 7. Análisis de postura

Fuente: Canal 10 Uruguay [55]

3) *Inteligencia artificial*

La inteligencia artificial (IA) es un área interdisciplinaria cuyo propósito fundamental es crear sistemas que puedan imitar procesos de pensamiento humano, como la toma de decisiones, el aprendizaje, la identificación de patrones y la solución de problemas. En el campo del deporte, la inteligencia artificial ha pasado a ser un instrumento estratégico para analizar el movimiento, detectar fallos técnicos y producir retroalimentación personalizada en tiempo casi real. La inteligencia artificial se emplea, principalmente, a través de la visión por computadora y los métodos de aprendizaje automático en esta investigación. Estos permiten que se analice y procese el material audiovisual de levantamientos en powerlifting. A continuación, se describen los componentes conceptuales más importantes que apoyan su ejecución. [56]




Fig. 8. Inteligencia artificial en dispositivos

Fuente: Google AI [57]

4) Visión artificial

El análisis de video en tiempo real se fundamenta en la visión artificial. Su función es convertir secuencias visuales en información que pueda ser cuantificada y que sea beneficiosa para el diagnóstico técnico. Entre sus métodos más destacados están:

Identificación de patrones: Los algoritmos de IA comparan los patrones en el movimiento del levantador con un estándar ideal, lo que posibilita la detección de errores técnicos que se repiten.

Segmentación de imágenes: Consiste en dividir la imagen en áreas concretas (como por ejemplo la barra, las rodillas o los hombros) para ayudar a analizar la postura y encontrar anomalías.

Modelos convolucionales sofisticados: arquitecturas como ResNet o EfficientNet tienen la capacidad de ser entrenadas con datos etiquetados para identificar posiciones articulares y trayectorias, descubriendo desviaciones en el método.

Retroalimentación visual inmediata: las señales gráficas, como flechas, luces o ángulos destacados, que brinda la visión artificial permiten al usuario corregir su actuación durante el levantamiento al proveer datos en tiempo real.

5) Redes neuronales y aprendizaje profundo

El aprendizaje profundo ha revolucionado el análisis visual, particularmente con el uso de redes neuronales.

Identificación de patrones: las redes neuronales de vanguardia facilitan la detección de estilos de levantamiento y la recomendación de modificaciones técnicas para disminuir el riesgo de lesiones.

Redes neuronales convolucionales (CNN): identifican patrones biomecánicos importantes, entre los que se encuentran las posiciones articulares, las trayectorias de la barra y las secuencias de movimiento. Su fortaleza se encuentra en la habilidad de aprender automáticamente representaciones en jerarquía, sin que sea necesario diseñar manualmente las propiedades de entrada.

Estimación de pose: Procedimientos como OpenPose posibilitan el reconocimiento de la ubicación de las articulaciones y la comprobación del alineamiento corporal, lo cual es fundamental en los ejercicios de fuerza.

Aprendizaje personalizado: Las redes optimizan las sugerencias específicas de acuerdo con la biomecánica personal del usuario gracias a un entrenamiento constante [58].




Fig. 9. Visión artificial

Fuente: Iberdrola [59]

6) Procesamiento de video e imágenes

El procesamiento de video es esencial para el análisis de movimientos deportivos:

Detección de patrones: Los algoritmos de IA identifican fallas técnicas frecuentes al cotejar los movimientos del levantador con un modelo ideal.

Segmentación de fotografías: Se trata de segmentar la imagen en zonas específicas (como los hombros, las rodillas o la barra) con el fin de facilitar el análisis postural y detectar irregularidades.

Modelos convolucionales avanzados: arquitecturas como ResNet o EfficientNet pueden ser entrenadas con datos etiquetados, lo que permite encontrar ubicaciones en las articulaciones y trayectorias, así como identificar desviaciones en el procedimiento.

Retroalimentación visual inmediata: La visión artificial utiliza señales gráficas, como flechas, luces o ángulos destacados, para proporcionar información en tiempo real. Esto permite que el usuario modifique su desempeño durante el levantamiento.




Fig. 10. Ejemplo de estimación de pose para la detección de ángulos articulares en ejercicios de fuerza

7) Modelos clásicos de aprendizaje automático

Además de las redes neuronales, esta investigación considera como referencia algunos modelos clásicos de machine learning:

Con el fin de establecer una base comparativa sólida, se evaluaron cinco enfoques de modelado:

SVM (Support Vector Machine): modelo clásico de clasificación utilizado como referencia inicial.

Random Forest: algoritmo basado en árboles de decisión, seleccionado por su capacidad de clasificación en problemas no lineales.

Neural Network (red neuronal tradicional): arquitectura básica de red neuronal artificial.

Métricas base (Accuracy, F1-Score y AUC): empleadas como indicadores generales de desempeño para los modelos probados.

CNN (Convolutional Neural Network): red neuronal convolucional implementada con la librería Keras, diseñada específicamente para procesar datos visuales y reconocer patrones complejos en imágenes y videos.

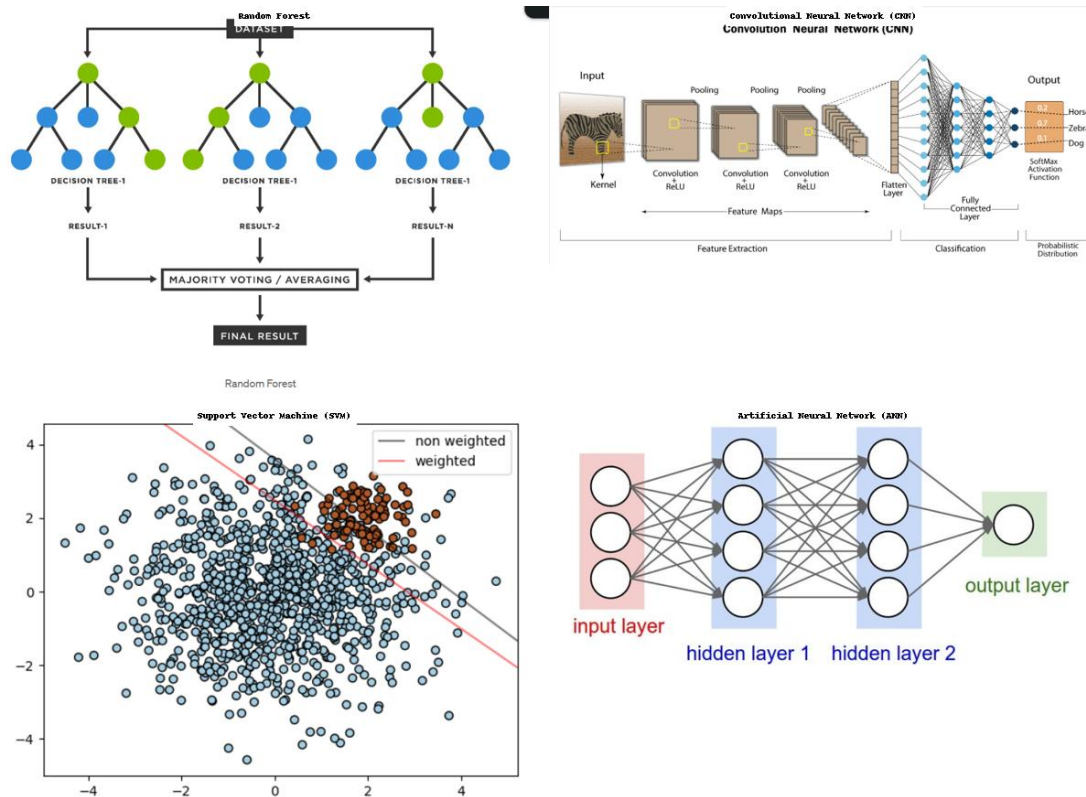


Fig. 11. Comparación conceptual entre modelos clásicos de aprendizaje automático y redes neuronales profundas

Fuente: Tomado de [61], [62], [63], [64]

8) Métricas de evaluación en IA

La evaluación de modelos de IA se fundamenta en métricas estandarizadas que permiten medir la calidad y confiabilidad de las predicciones:

Accuracy: proporción de aciertos sobre el total de casos.

Precision: proporción de verdaderos positivos entre los positivos predichos.

Recall (sensibilidad): proporción de verdaderos positivos detectados.

F1-score: balance armónico entre precisión y recall.

AUC (Área bajo la curva ROC): medida de discriminación independiente del umbral de clasificación.

Loss (pérdida): cuantificación del error durante el entrenamiento, usada para diagnosticar problemas de sobreajuste.




Fig. 12. Curvas de medición del sobreajuste

9) Generación de informes personalizados

Visualizaciones de corrección en tiempo real: Ofrece retroalimentación visual inmediata al usuario, permitiéndole ver en pantalla si está realizando correctamente el movimiento o necesita ajustar su técnica.

El reconocimiento de patrones usa redes convolucionales (CNN) para extraer características críticas del movimiento, como trayectorias y posiciones de las articulaciones. Modelos como ResNet o EfficientNet pueden entrenarse con datos etiquetados para identificar desviaciones en la técnica.

Retroalimentación visual: Proporciona señales visuales durante el ejercicio, como flechas, indicadores de ángulos o luces, para guiar al levantador en la ejecución correcta en tiempo real [64].



Fig. 13. Registros de informes

Fuente: Freepik [65]

10) Redes neuronales

Reconocimiento de patrones: Las redes neuronales avanzadas permiten identificar patrones en el estilo de levantamiento del usuario, sugiriendo ajustes específicos para mejorar la eficiencia y reducir el riesgo de lesiones.

Las redes neuronales convolucionales detectan patrones biomecánicos y ofrecen ajustes personalizados para optimizar la ejecución. Este enfoque considera características individuales, como la biomecánica del usuario, para maximizar la efectividad.

Estimación de pose: Usa técnicas avanzadas para determinar la pose corporal y asegurar que los ángulos de las articulaciones y la alineación sean óptimos para cada tipo de levantamiento [66].




Fig. 14. Arquitectura general de una red neuronal convolucional (CNN) utilizada en visión por computadora

Fuente: Esparza [67]

11) *Procesamiento de video e imágenes*

El procesamiento de video e imágenes es fundamental para el análisis de movimientos en tiempo real, especialmente en actividades como el powerlifting. A través de técnicas de visión por computadora, como la estimación de pose y la detección de objetos, se puede seguir la trayectoria de la barra y el movimiento de las articulaciones clave, como hombros, codos, rodillas y caderas. Herramientas como OpenPose y YOLO permiten identificar y rastrear estos elementos en tiempo real, proporcionando datos visuales y métricas precisas que ayudan a mejorar la ejecución del levantamiento.

En este tipo de análisis, los algoritmos de visión artificial permiten segmentar las imágenes en diferentes partes, como el cuerpo del levantador y el equipo, usando técnicas como CNN. Esto facilita un análisis detallado de cada componente, asegurando que las posturas y los ángulos sean los correctos.

El procesamiento de video e imágenes también proporciona retroalimentación visual en tiempo real, permitiendo que el levantador ajuste su técnica durante el ejercicio. Herramientas avanzadas de aprendizaje automático, como redes neuronales, pueden aprender de los movimientos pasados y hacer recomendaciones personalizadas para mejorar el rendimiento y reducir el riesgo de

lesiones. En conjunto, estas tecnologías crean un sistema eficiente y dinámico para optimizar el entrenamiento de powerlifting, proporcionando un análisis profundo y recomendaciones precisas [68].




Fig. 15. Inteligencia artificial en la ayuda de los ejercicios

Fuente: Valgo Consultoría Deportiva [69]

C. VARIABLES DE ESTUDIO

1) Variables independientes

a) Modelo de Inteligencia Artificial para el análisis de ejercicios de Powerlifting

Nominal: Método basado en redes neuronales para identificar la ejecución correcta de los movimientos compuestos del powerlifting.

Operativo: Se evaluará la **exactitud, F1** y **AUC** del modelo al clasificar correctamente las fases de cada levantamiento (sentadilla, peso muerto, prensa de banca) y detectar desviaciones en la técnica [70].

b) Redes neuronales convoluciones para el análisis de postura

Nominal: Utilización de redes neuronales convoluciones para el análisis postural en los movimientos de powerlifting.

Operativo: Se medirá el rendimiento del atleta en términos de precisión, tiempo de procesamiento y capacidad para detectar errores posturales en diferentes ejercicios [72].

c) Grabación y procesamiento de vídeo en tiempo real

Nominal: Dispositivos de captura (Cámara de teléfono móvil) para grabar y procesar los ejercicios en tiempo real.

Operativo: Se evaluará la calidad de la captura de movimiento y la capacidad de procesar el vídeo en tiempo real sin retrasos [73].

Algoritmos de preprocesamiento de video: Conjunto de técnicas aplicadas para mejorar la calidad de los videos antes de ser procesados por los modelos de IA. Estos algoritmos no son una variable independiente, sino un algoritmo complementario para realizar una extracción de datos más precisa y mejorar el modelo. Entre ellas se encuentran la estabilización de video, la reducción de ruido, la corrección de luz y la segmentación de imágenes, las cuales permiten que las redes neuronales manipulen información visual más limpia y estructurada, garantizando resultados más confiables en la detección de errores técnicos.[74].

2) Variables dependientes

d) Precisión en la detección de errores en la técnica

Nominal: El grado en que el sistema detecta errores técnicos en los movimientos de powerlifting se refiere a la capacidad del sistema para identificar fallos en la técnica, como la alineación incorrecta, la postura inadecuada o el uso incorrecto de los músculos en los levantamientos. Esta variable se evaluará de manera nominal, es decir, si el sistema detecta o no los errores.

Operativo: Se evaluará el desempeño del modelo en la **detección de errores** mediante las siguientes métricas:

AUC (Área bajo la curva): Para evaluar la capacidad del sistema para discriminar entre las clases de errores y movimientos correctos.

Puntuación F1: Para medir el equilibrio entre la precisión y el recuerdo en la detección de errores.

Accuracy (Exactitud): Para medir la proporción de predicciones correctas en relación al total de predicciones realizadas por el sistema.

Overfitting: Se evaluará si el modelo generaliza bien o si presenta un sobreajuste a los datos de entrenamiento, lo cual podría comprometer la capacidad de detectar errores en nuevos datos.

Loss (Pérdida): Medida de la diferencia entre las predicciones del modelo y las verdaderas etiquetas de los datos, lo que indica qué tan bien el modelo está aprendiendo.

Tiempo de predicción: Evaluación de la rapidez con la que el modelo realiza las predicciones, lo cual es importante para ofrecer retroalimentación en tiempo real.

e) Eficiencia del Entrenamiento Personalizado

Nominal: El grado en que el sistema permite los entrenamientos según las características del atleta se refiere a la capacidad del sistema para ajustar los ejercicios basados en las necesidades individuales del atleta, como su nivel de fuerza, limitaciones físicas o experiencia en levantamiento de pesas. Esta evaluación se realiza de manera nominal.

Operativo: La eficiencia del sistema para adaptarse a las condiciones del entorno de cada atleta se evaluará a través de las siguientes métricas:

Accuracy (Exactitud): Para medir la proporción de recomendaciones correctas dadas las condiciones específicas del atleta y su entorno para encontrarlo utilizamos la siguiente formula.

Donde:

- TP: verdaderos positivos (casos positivos correctamente clasificados).
- TN: verdaderos negativos (casos negativos correctamente clasificados).
- FP: falsos positivos (casos negativos clasificados incorrectamente como positivos).
- FN: falsos negativos (casos positivos clasificados incorrectamente como negativos).

$$Accuracy = \frac{TP + TN}{FP + FN + TP + TN}$$

Overfitting: Se evaluará si el sistema ajusta las recomendaciones correctamente sin sobre ajustarse a un solo conjunto de datos, garantizando su efectividad a lo largo del tiempo y para encontrarla se necesita de la siguiente formula.

$$\Delta AUC = AUC_{train} - AUC_{val}$$

Pérdida: Para monitorear el desempeño del modelo en función de la cantidad de error en sus recomendaciones se emplea la función de pérdida (*loss*), la cual mide la diferencia entre las predicciones generadas por el sistema y los resultados reales. Una pérdida menor indica que las predicciones del modelo están más cercanas a la realidad, lo que es esencial para mejorar la precisión en la detección de técnicas lo cual se referencia mejor en el punto La pérdida donde se obtiene las dos fórmulas.

Tiempo de predicción: Medición del tiempo que el sistema tarda en adaptar y entregar personalizadas en tiempo real, lo que es clave para un entrenamiento eficiente.

Para evaluar los modelos de aprendizaje automático utilizados para analizar las técnicas de levantamiento de pesas, es esencial confiar en varias métricas clave que miden diferentes aspectos del rendimiento.

La precisión cuantifica la frecuencia con la que el modelo clasifica correctamente tanto las instancias positivas como las negativas, pero podría no ser suficiente para conjuntos de datos desequilibrados, donde el modelo podría predecir la clase mayoritaria con mayor frecuencia. Esto podría generar una precisión engañosamente alta sin abordar errores en la detección de técnicas (como falsos positivos o falsos negativos) y para encontrarlo utilizamos la siguiente formula. [75].

Donde:

- TP: verdaderos positivos (casos positivos correctamente clasificados).
- FP: falsos positivos (casos negativos clasificados incorrectamente como positivos).

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

La puntuación F1 combina precisión y recuperación, ofreciendo un equilibrio entre la detección de errores y la prevención de falsas alarmas. Esta métrica es particularmente útil cuando existe la necesidad de priorizar tanto la detección de la mayor cantidad posible de errores (recuperación) como la identificación correcta de dichos errores (precisión) [76].

Para encontrar la puntuación F1 necesitamos encontrar el Recall (Sensibilidad o Tasa de Verdaderos Positivos).

Donde:

- TP: verdaderos positivos.
- FN: falsos negativos.

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

Con el Recall encontrado podemos continuar encontrando **la puntuación F1**

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

El AUC (área bajo la curva ROC) proporciona una visión integral del rendimiento de un modelo, especialmente al elegir umbrales para la clasificación. Un AUC más alto significa que el modelo es mejor para distinguir entre técnicas correctas e incorrectas, incluso cuando se varía el umbral de decisión y para encontrarlo utilizamos la siguiente formula. [77].

Donde:

- TPR: tasa de verdaderos positivos.
- FPR: tasa de falsos positivos, $FPR = \frac{FP}{TN+FP}$.

$$AUC = \int_0^1 TPR(FPR)d(FPR)$$

El sobreajuste es un problema crítico, en particular cuando el modelo funciona bien con datos de entrenamiento, pero no logra generalizarse a datos no vistos. Esto es especialmente relevante en el levantamiento de pesas, donde pueden ocurrir variaciones reales en la técnica [78].

La pérdida mide la diferencia entre las predicciones del modelo y los resultados reales. Una pérdida menor indica que las predicciones del modelo están más cerca de la realidad, lo que es esencial para mejorar la precisión de la detección de técnicas lo cual nos lleva a dos fórmulas la cuales son para binaria y multiclase y para encontrarlas necesitamos de las siguiente formulas [79].

Perdida Binaria

Donde:

- N : número de muestras.
- y_i : etiqueta real (0 o 1).
- \hat{y}_i : probabilidad predicha por el modelo.

$$\mathcal{L}_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \cdot \ln(\hat{y}_i) + (1 - y_i) \cdot \ln(1 - \hat{y}_i)]$$

Perdida multiclase

Donde:

- C : número de clases.
- $y_{i,c}$: valor real de la clase (1 si pertenece a la clase c , 0 en caso contrario).
- $\hat{y}_{i,c}$: probabilidad predicha para la clase c .

$$\mathcal{L}_{CCE} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \cdot \ln(\hat{y}_{i,c})]$$

El tiempo de predicción evalúa la eficiencia con la que el modelo procesa las entradas de video en tiempo real, lo que es crucial para obtener comentarios inmediatos durante el entrenamiento. Un modelo con un tiempo de predicción más rápido es más práctico para escenarios de entrenamiento en vivo y para encontrarla necesitamos de la siguiente formula [80].

Donde:

- t_i : tiempo de inferencia de la muestra i .
- \bar{t} : tiempo promedio de predicción.
- σ_t : desviación estándar del tiempo de predicción.

$$\bar{t} = \frac{1}{N} \sum_{i=1}^N t_i$$

$$\sigma_t = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - \bar{t})^2}$$

f) Retroalimentación automática y personalizada

Nominal: Sistema inteligente que proporciona retroalimentación inmediata al usuario durante la ejecución de los ejercicios, indicando de manera visual o textual si la técnica realizada es correcta o requiere ajustes.

Operativo: Se evaluará la velocidad y la precisión con la que el sistema genera la retroalimentación en tiempo real, considerando la capacidad de adaptación de las recomendaciones según la técnica y el desempeño del atleta durante el entrenamiento. [81].

D. FORMULACIÓN DE HIPÓTESIS

1) Hipótesis de investigación

La hipótesis de investigación sostiene que los modelos de inteligencia artificial, fundamentados en visión por computadora, logran un rendimiento mucho mejor que el azar al detectar desviaciones técnicas cuando se realizan ejercicios de powerlifting. Se anticipa que el área debajo de la curva ROC (AUC) lograda en las evaluaciones de validación supere 0.5, lo cual señalaría una capacidad predictiva efectiva en la distinción entre ejecuciones adecuadas e inadecuadas. Esta propuesta se basa en el principio de que los modelos de aprendizaje profundo y las redes neuronales convolucionales pueden detectar y examinar patrones complejos, tanto temporales como espaciales, en los movimientos del cuerpo. Esto les hace más fácil detectar con precisión errores técnicos menores que podrían pasarse por alto a la vista humana. El sistema propuesto se robustecería como herramienta efectiva para respaldar la formación deportiva si esta hipótesis se valida, al ofrecer una retroalimentación objetiva y basada en datos con el propósito de mejorar la técnica y prevenir lesiones.

2) Hipótesis nula

La hipótesis nula plantea que los modelos de inteligencia artificial empleados para detectar desviaciones técnicas en la realización de ejercicios de powerlifting no tienen un desempeño mejor

que el azar, y por ende su área bajo la curva ROC (AUC) no excede el 0.5. En este caso, se supondría que el sistema no tiene la habilidad de distinguir entre ejecuciones correctas e incorrectas, indicando que los resultados logrados son producto de la aleatoriedad o de la variabilidad de los datos en lugar de ser una auténtica habilidad predictiva del modelo. Conforme a esta hipótesis, se cuestionaría la capacidad de la inteligencia artificial para analizar técnicamente el movimiento humano, lo que indicaría que los modelos utilizados no consiguen extender adecuadamente las pautas de ejecución ni proporcionar una retroalimentación fiable. Si esta hipótesis se acepta, el desarrollo del sistema necesitaría la optimización de los parámetros, la mejora de la calidad de los datos de entrenamiento o ajustes en la metodología.

3) Hipótesis alterna

La hipótesis alternativa establece que los modelos de inteligencia artificial usados para detectar desviaciones técnicas en powerlifting tienen una habilidad predictiva mejor que la aleatoriedad, lo cual se demuestra con un valor de área bajo la curva ROC (AUC) superior a 0.5. Este hallazgo indicaría que el sistema es capaz de diferenciar con exactitud entre ejecuciones técnicamente correctas y las que presentan problemas de postura o de movimiento, lo cual valida la utilización de inteligencia artificial como instrumento para monitorear y evaluar en el campo del deporte. Del mismo modo, diría que los algoritmos de visión por computadora y las redes neuronales profundas pueden examinar patrones biomecánicos complejos y ofrecer retroalimentación automática con un alto nivel de confiabilidad. Si esta hipótesis se confirma, se avalaría que es posible integrar soluciones tecnológicas inteligentes en los procedimientos de formación y corrección técnica. Esto ayudaría a mejorar el desempeño deportivo y disminuir la probabilidad de lesiones causadas por una técnica inapropiada.

III. METODOLOGÍA

A. PARADIGMA

El presente proyecto se enmarca dentro del paradigma positivista, Debido a que busca un enfoque objetivo y racional para el análisis de técnicas de powerlifting mediante inteligencia artificial. La finalidad es predecir la correcta o incorrecta ejecución de ejercicios multiarticulares, como sentadillas y peso muerto, utilizando un modelo de redes neuronales entrenado en datos empíricos. Este paradigma se justifica por la necesidad de un método riguroso y replicable en la evaluación técnica, aspecto esencial para minimizar el riesgo de lesiones en deportistas [82].

B. ENFOQUE

La investigación actual adopta un enfoque cuantitativo con una perspectiva empírico-analítica, puesto que se basa en la observación sistemática, la medición y el análisis estadístico de los datos adquiridos a partir de ejercicios de powerlifting. Este procedimiento permite un análisis objetivo de la actuación de las variables relacionadas con la técnica de los movimientos, el reconocimiento de fallos y la eficiencia de los modelos de inteligencia artificial aplicados. Se pretende recoger datos numéricos de videos analizados por algoritmos de visión por computadora para determinar correlaciones causales entre los errores posturales y sus posibles efectos, ya sea que se trate de la productividad o del riesgo de lesiones. El estudio, por su naturaleza cuantitativa, permite hacer comparaciones precisas entre diferentes modelos de predicción a través de métricas como el área bajo la curva ROC (AUC), la exactitud y el F1-score. El objetivo es establecer qué algoritmo tiene un mejor rendimiento en detectar automáticamente errores técnicos. [83].

C. MÉTODO

El proyecto utiliza y emplea un método cuasiexperimental, adecuado para analizar la influencia de variables biomecánicas en la ejecución técnica de ejercicios de powerlifting. Este enfoque permite observar y medir de forma controlada, aunque no en condiciones completamente experimentales, cómo los factores como la alineación corporal, los ángulos articulares y la estabilidad influyen en la calidad del movimiento y en la detección de errores mediante modelos de inteligencia artificial. A través de este método se busca establecer relaciones causales entre la técnica de ejecución y la precisión del sistema de visión por computador, evaluando el desempeño de los modelos con base

en métricas cuantitativas que permitan validar su efectividad en la identificación de desviaciones técnicas y la mejora de la retroalimentación al atleta [84].

D. TIPO DE INVESTIGACIÓN

La investigación desarrollada se enmarca dentro del tipo aplicada, ya que busca generar una solución tecnológica concreta orientada a optimizar la técnica de ejecución en los ejercicios de powerlifting y a reducir el riesgo de lesiones asociadas a una ejecución incorrecta. Este enfoque combina el conocimiento teórico sobre inteligencia artificial y análisis biomecánico con su implementación práctica en un entorno deportivo real, permitiendo validar los resultados en situaciones de entrenamiento controladas. El conocimiento obtenido tiene una aplicación directa en la mejora de los procesos de entrenamiento, al ofrecer herramientas que incrementan la seguridad, la precisión técnica y la efectividad del desempeño de los atletas. [82].

E. DISEÑO DE INVESTIGACIÓN

El diseño adoptado es de tipo cuasiexperimental, orientado a la evaluación del rendimiento de modelos de inteligencia artificial aplicados al análisis técnico en powerlifting. Se realizarán pruebas controladas sobre diferentes ejecuciones para medir la precisión, consistencia y capacidad predictiva del sistema al identificar posturas incorrectas y ofrecer retroalimentación automática. Este diseño permite validar de manera empírica el desempeño del modelo mediante un proceso iterativo de ajustes y comparaciones, hasta alcanzar niveles óptimos de confiabilidad en la detección de errores y en la mejora de la técnica de los atletas. [83].

F. POBLACIÓN

En este estudio, la población de referencia se refiere a la práctica de las tres actividades esenciales del powerlifting en situaciones deportivas: el peso muerto, la sentadilla y el press de banca. En términos de conceptos, la población está formada por todas las realizaciones posibles, ya sean correctas o incorrectas, de estos movimientos. Estas pueden ser grabadas en video para que posteriormente se analicen usando métodos de inteligencia artificial y visión por computadora.

G. MUESTRA

La muestra estuvo conformada por 87 videos correspondientes a las tres disciplinas del powerlifting: sentadilla, press de banca y peso muerto, los cuales se emplearon para el análisis y

entrenamiento de los modelos de inteligencia artificial. De estos, 70 videos fueron de producción propia, grabados en un gimnasio con un dispositivo Xiaomi 12T Pro, en resolución 1080p y 30 fps, registrando distintos ángulos y utilizando iluminación natural para garantizar la calidad visual. Los 17 videos restantes fueron obtenidos de la plataforma TikTok, seleccionados por su nitidez, visibilidad de las articulaciones y ejecución completa del movimiento.

Criterios de inclusión: videos con ejecución completa del ejercicio, adecuada iluminación y correcta visibilidad de las articulaciones y la trayectoria de la barra.

Criterios de exclusión: videos incompletos, borrosos, con movimientos fuera de cuadro o ángulos que dificultaran la identificación de la técnica.

H. TÉCNICAS DE RECOLECCIÓN DE LA INFORMACIÓN

La investigación empleó como técnica principal la observación directa, mediante la cual se registraron ejecuciones reales de los tres movimientos fundamentales del powerlifting: sentadilla, press de banca y peso muerto. Para ello, se creó un repositorio propio de datos compuesto por videos grabados en entornos de entrenamiento controlados y reales, utilizando cámaras de teléfonos móviles y cámaras de acción. Este enfoque permitió obtener registros visuales representativos de diversas condiciones lumínicas, angulares y de rendimiento, asegurando que las grabaciones reflejaran variabilidad técnica y corporal propia de los deportistas observados.

Los videos fueron etiquetados con el apoyo de expertos en powerlifting, identificando las fases del levantamiento y los errores técnicos más frecuentes. Posteriormente, el material audiovisual fue preprocesado mediante técnicas de reducción de ruido, escalado y estandarización, lo que permitió optimizar la calidad del dataset y facilitar su procesamiento por parte del modelo de inteligencia artificial.

Como técnica complementaria, se utilizó el análisis documental, revisando fuentes académicas y repositorios especializados que sirvieron de referencia para estructurar el esquema de datos y definir criterios de procesamiento. Entre estas fuentes se destacan la plataforma Kaggle, reconocida por ofrecer conjuntos de datos deportivos y ejemplos de etiquetado de videos de entrenamiento [86]; el UCI Machine Learning Repository, que provee bases de datos públicas aplicables a proyectos de aprendizaje automático [87]; el Journal of Sports Sciences, que recopila

investigaciones sobre la aplicación de modelos de inteligencia artificial en el análisis del movimiento humano [88]; y el libro Deep Learning for Computer Vision, el cual describe métodos de preprocesamiento y etiquetado de imágenes y videos en proyectos de visión por computador [89]. Estas referencias orientaron la recolección, estructuración y validación de los datos, asegurando un proceso metodológico sólido y reproducible para el entrenamiento y evaluación del modelo.

I. VALIDEZ DE LAS TÉCNICAS DE RECOLECCIÓN DE LA INFORMACIÓN

Se garantizó la validez del estudio mediante la creación de videos bajo condiciones controladas y la selección de material externo según criterios técnicos previamente establecidos. Los registros fueron revisados por los expertos en powerlifting Renato Chapuel y Brayan Tobar, quienes corroboraron la correcta clasificación de cada ejecución según su nivel técnico y verificaron el proceso metodológico de etiquetado y validación de datos. Adicionalmente, se contó con la orientación metodológica del asesor de tesis Héctor Andrés Mora Paz, Magíster en Inteligencia Artificial, quien brindó acompañamiento académico y técnico durante la estructuración del proyecto, apoyando la definición de categorías, la revisión del proceso de codificación y la validación del diseño metodológico. Este trabajo conjunto permitió que el conjunto de datos representara con precisión tanto las ejecuciones correctas como los errores técnicos más comunes, asegurando su idoneidad y pertinencia para el desarrollo del modelo de inteligencia artificial propuesto.

J. CONFIABILIDAD DE LAS TÉCNICAS DE RECOLECCIÓN

La confiabilidad de las técnicas de recolección se garantizó mediante la normalización de los parámetros técnicos en cada grabación, estandarizando el formato MP4, la resolución 1080p, la velocidad de 30 fps y una duración constante en los registros, lo que permitió mantener la homogeneidad y replicabilidad del material audiovisual utilizado en el estudio. El proceso de etiquetado se realizó bajo un sistema de nomenclatura estructurado que facilitó la trazabilidad y coherencia de los datos. Asimismo, los expertos en powerlifting Renato Chapuel y Brayan Tobar verificaron la clasificación de las ejecuciones para asegurar que las etiquetas correspondieran con los criterios técnicos definidos. Adicionalmente, se contó con la supervisión metodológica del asesor de tesis Héctor Andrés Mora Paz, Magíster en Inteligencia Artificial, quien apoyó la validación del proceso de codificación y la revisión técnica del procedimiento de etiquetado,

garantizando su rigurosidad. Gracias a estos procedimientos, se fortaleció la consistencia, estabilidad y precisión del conjunto de datos, asegurando que la información empleada para el entrenamiento y evaluación del modelo de inteligencia artificial fuese confiable y reproducible.

K. INSTRUMENTOS DE RECOLECCIÓN DE INFORMACIÓN

El principal instrumento de recolección de información fue un repositorio de datos conformado por 87 videos que documentan las tres disciplinas esenciales del powerlifting: sentadilla, press de banca y peso muerto. Las grabaciones fueron realizadas con un dispositivo móvil de alta definición y posteriormente organizadas en un conjunto de datos estructurado, donde cada video fue clasificado de forma sistemática según la técnica ejecutada. Este repositorio constituye la base principal para el entrenamiento y validación de los modelos de inteligencia artificial, al incluir ejecuciones revisadas y verificadas por especialistas, tanto correctas como incorrectas, lo que asegura una información confiable, representativa y adecuada para cumplir los objetivos de la investigación.

IV. RESULTADOS DE LA INVESTIGACIÓN

A. METODOLOGÍA (CRISP-DM)

El proyecto seguirá la metodología CRISP-DM, un proceso estándar en minería de datos que consta de seis fases, esenciales para estructurar el desarrollo de un modelo de inteligencia artificial:

- Comprensión del problema: identificar las métricas clave para detectar errores técnicos.
- Comprensión de los datos: evaluar la calidad y relevancia de los videos utilizados para el análisis.
- Preparación de los datos: normalizar y limpiar los datos para optimizar su uso en el modelo.
- Modelado: desarrollar un modelo de redes neuronales que clasifique la ejecución de los ejercicios.
- Evaluación: medir la precisión y consistencia del modelo en la identificación de errores.
- Despliegue: implementar el modelo en una interfaz para proporcionar retroalimentación en tiempo real a los usuarios.

Esta versión es más directa y mantiene los puntos esenciales de cada fase para un entendimiento claro y conciso del método y la metodología [85].

B. RECOPILACIÓN DE INFORMACIÓN

La fase inicial y más relevante del estudio, que consistió en recolectar información, fue creada para desarrollar un corpus audiovisual de gran calidad y representativo. Este corpus se utilizaría para la capacitación y evaluación de modelos de inteligencia artificial que tienen como objetivo identificar fallos técnicos en ejercicios de levantamiento de potencia (peso muerto, press de banca y sentadillas). La estrategia incluyó grabaciones propias en condiciones controladas, así como la selección cuidadosa de material público accesible en línea, siguiendo criterios técnicos y de calidad.

1) Escenario de grabación

Las grabaciones se hicieron en un gimnasio local que proporcionaba las condiciones apropiadas para realizar los tres levantamientos básicos: el peso muerto, la sentadilla y el press de banca. Este ambiente fue propicio porque tenía suficiente espacio para instalar las cámaras y los equipos, una

iluminación natural estable y en buen estado, lo que posibilitó que los movimientos se realizaran de manera controlada y segura.

Se empleó un Xiaomi 12T Pro, configurado a 1080p y 30 fps con HDR, para la grabación, con el objetivo de que cada registro tuviera la mejor calidad posible en cuanto a nitidez, color y estabilidad de imagen. En este análisis, a diferencia de otros muchos que emplean un único método, se optó por grabar desde diferentes ángulos: lateral, frontal, desde la tierra y en niveles más elevados. El propósito de esta resolución fue simular la verdadera diversidad de grabaciones que un usuario podría realizar en condiciones no controladas y, simultáneamente, ofrecerle al modelo de inteligencia artificial una mayor cantidad de información visual.




Fig. 16. Foto del set de grabación mostrando la disposición de la cámara y la zona de levantamiento

2) Participantes

Los videos propios fueron realizados por los mismos investigadores con el fin de mantener un control directo sobre las condiciones de grabación y las características de ejecución. La participación estuvo conformada por dos personas:

Dorian Bolaños (21 años, masculino).

David Toro (24 años, masculino).

Los dos realizaron repeticiones tanto correctas como incorrectas, que incluyeron fallos técnicos intencionales. Esta táctica hizo posible que el conjunto de datos incluyera ejemplos que mostraran tanto desempeños óptimos como errores usuales en el mundo deportivo. La base de datos se vio enriquecida gracias a la incorporación de ejecuciones con variaciones deliberadas, las cuales abarcaron un amplio rango de alternativas técnicas, pese a que no se definió oficialmente un nivel competitivo (principiante/avanzado).




Fig. 17. Comparación de videos correctos e incorrectos

3) Distribución de los ejercicios grabados

En total se recopilaron **60 videos propios** y **10 videos externos** (10 de TikTok), alcanzando un conjunto de **70 registros audiovisuales**. Los videos propios se distribuyeron de forma balanceada entre los tres ejercicios, procurando registrar tanto movimientos correctos como incorrectos y llevando a cabo un promedio de repeticiones por video para garantizar que tantos videos correctos como incorrectos tengan forma balanceada para el entrenamiento de la red neuronal:

TABLA I. VIDEOS REALIZADOS CORRECTOS Y INCORRECTOS PROPIOS CON PROMEDIO DE REPETICIONES POR VIDEO

Ejercicio	Correctos	Incorrectos	Total	Promedio de repeticiones por video
Sentadilla	10	10	20	5
Peso muerto	10	10	20	5
Press de banca	10	10	20	5
Total	30	30	60	15

Los errores fueron incorporados deliberadamente con base en observaciones de entrenadores, quienes sugirieron cuáles son las fallas más comunes en cada levantamiento (como el valgo de rodillas en la sentadilla, el arqueo excesivo de la espalda en el peso muerto o la trayectoria incorrecta de la barra en el press de banca). Esta estrategia aseguró que el modelo no solo aprendiera a identificar patrones correctos, sino también a discriminar movimientos técnicamente inadecuados.

4) Material complementario de internet

Con el fin de ampliar la diversidad de casos y contextos, se recopilamos videos adicionales desde la red social TikTok, plataforma que ofrece contenido audiovisual de entrenamientos realizados por atletas de distintos niveles. La selección de este material se basó en la visibilidad clara de la postura y la ejecución del ejercicio, priorizando aquellos en los que se distinguían con precisión las posiciones de las articulaciones y la trayectoria de la barra. Estos videos complementarios aportaron variabilidad en términos de contextos de grabación, condiciones de iluminación y estilos de ejecución, fortaleciendo así la robustez de la data set. Los criterios de selección de este material se basaron en tres aspectos principales:

Claridad de la postura y visibilidad de las articulaciones.

Condiciones de iluminación adecuadas que evitaran pérdida de información.

Disponibilidad pública del contenido, que asegurara la legalidad en su uso.




Fig. 18. Material complementario de internet

5) Validación por expertos

Todos los videos, tanto propios como externos, fueron revisados y validados por dos entrenadores y expertos en powerlifting y actividades físicas en gimnasios, quienes confirmaron la clasificación de cada ejecución como correcta o incorrecta. Este proceso de validación resultó crucial para garantizar la calidad y la confiabilidad de la información, minimizando el riesgo de mal etiquetado y asegurando que el material utilizado reflejara fielmente las exigencias técnicas del deporte.

Renato Chapuel — Instructor con más de diez años de experiencia.

Brayan Tobar — Entrenador con amplia experiencia en powerlifting

Ambos realizaron el proceso de manera **individual por cada video**, lo que garantizó independencia en el etiquetado y redujo la posibilidad de sesgos.

6) Aspectos técnicos de grabación

Las grabaciones propias permitieron capturar con gran nivel de detalle los movimientos articulares y la trayectoria de la barra. Cada video tuvo una duración aproximada de **40 segundos a un minuto**, dentro de los cuales se incluyó una serie de repeticiones completas del ejercicio. Se hizo grabaciones de diferentes puntos y ángulos en todas las sesiones para facilitar el posterior análisis

mediante algoritmos de visión por computadora, evitando variaciones que pudieran dificultar la detección de patrones.

División de la data set. Con el fin de garantizar un correcto entrenamiento y evaluación del modelo, el corpus fue dividido en tres subconjuntos:

TABLA II. DIVISION DEL DATASET

Subconjunto	N.º videos	Porcentaje
Entrenamiento	51	70%
Validación	10	20%
Prueba	9	10%
Total	70	100%

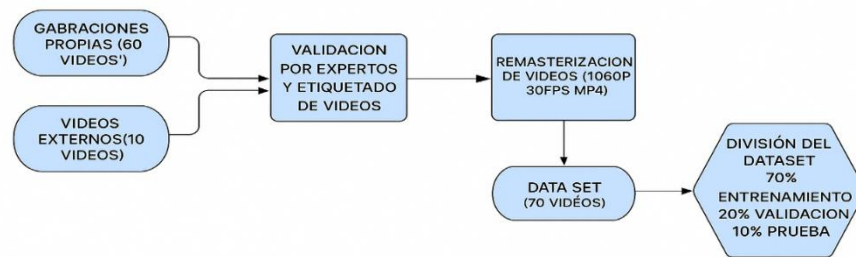


Fig. 19. Diagrama de flujo de videos propios y externos paso a paso

C. CREACIÓN DE DATA SET

La creación de la data set representó una de las etapas más críticas del proceso investigativo, dado que de la calidad, organización y representatividad de los datos depende directamente el desempeño de los modelos de inteligencia artificial. En este proyecto se consolidó un conjunto de videos cuidadosamente organizados, estandarizados y validados, con el fin de reflejar de manera precisa tanto ejecuciones correctas como incorrectas de los tres ejercicios fundamentales del powerlifting: sentadilla, peso muerto y press de banca.

1) Organización inicial del material

El data set se construyó a partir de dos fuentes principales:

Producción propia: 70 videos grabados en un gimnasio bajo condiciones controladas, utilizando diferentes ángulos de cámara y manteniendo criterios homogéneos de resolución e iluminación.

Material externo: 17 videos seleccionados de **YouTube y TikTok**, priorizando la visibilidad clara de la postura, la trayectoria de la barra y la nitidez del encuadre.

En total, la data set final quedó compuesto por **87 videos**, organizados bajo un único directorio raíz denominado **dataset_powerlifting**. En este directorio no se crearon subcarpetas por categorías; en cambio, se utilizó un sistema de **nomenclatura en el nombre del archivo** para distinguir ejercicio, condición y número consecutivo.

2) Estandarización de formatos

Con el objetivo de garantizar la uniformidad técnica del conjunto, todos los videos fueron sometidos a un proceso de remasterización que incluyó:

Conversión a formato MP4, por su compatibilidad con bibliotecas de visión por computadora como *OpenCV* y *TensorFlow*.

Normalización de la resolución a 1080p (1920x1080 píxeles) a 30 fps, lo que permitió equilibrar la calidad visual con la eficiencia computacional en el entrenamiento.

Duración promedio de 40 segundos a 1 minuto, suficiente para registrar varias repeticiones completas de cada ejercicio.

Este preprocesamiento aseguró que los datos se encontraran en condiciones óptimas para su posterior utilización en el entrenamiento de la red neuronal.

Sistema de etiquetado. La clasificación de los videos se realizó mediante un sistema de **nomenclatura estructurada**, con el fin de facilitar la identificación y recuperación del material durante el entrenamiento del modelo. Cada archivo fue nombrado de acuerdo con el siguiente patrón:

[Ejercicio]_[Condición]_[Número]

Donde:

Ejercicio: identifica la modalidad (Sentadilla, Peso Muerto, PressBanca).

Condición: especifica si el levantamiento corresponde a una ejecución *Correcta* o *Incorrecta*.

Número: corresponde a un código consecutivo de validación (01, 02, 03, ...).

Ejemplo:

Sentadilla_Correcto_01.mp4

PesoMuerto_Incorrecto_07.mp4

PressBanca_Correcto_12.mp4

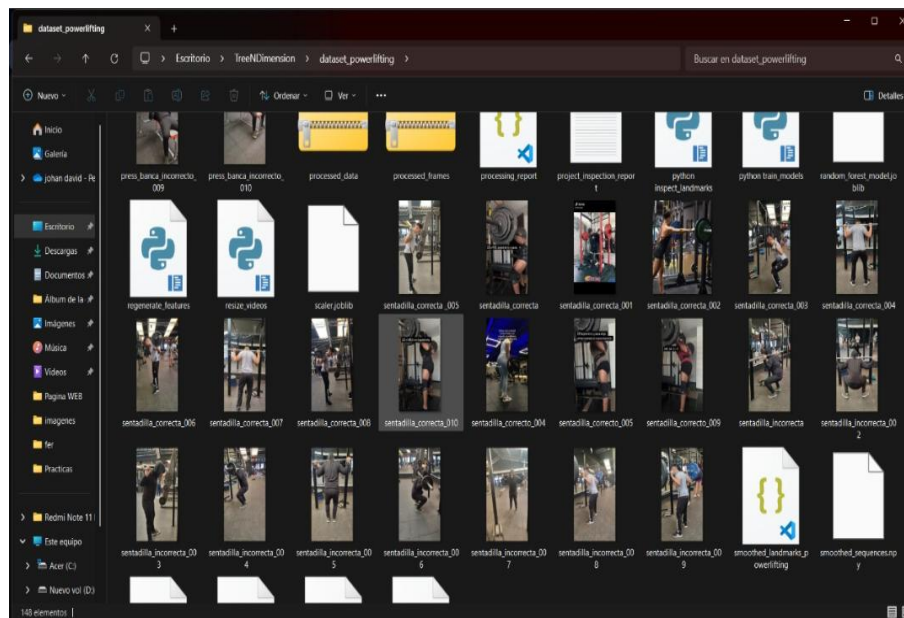


Fig. 20. Carpeta de Data set

Adicionalmente, se diseñó un archivo Excel en el que se registraron observaciones para cada video. En el caso de las ejecuciones incorrectas, se anotaron los errores técnicos más relevantes (p. ej., valgo de rodillas en sentadilla, arqueo de espalda en peso muerto, trayectoria irregular en press de banca).

TABLA III. NOMBRE DE CADA ARCHIVO Y SUS OBSERVACIONES CORRESPONDIENTES

Nombre del archivo	Ejercicio	Condición	Observaciones
Sentadilla_Correcto_01.mp4	Sentadilla	Correcto	N/A
Sentadilla_Incorrecto_03.mp4	Sentadilla	Incorrecto	Valgo de rodillas
PesoMuerto_Incorrecto_07.mp4	Peso muerto	Incorrecto	Barra demasiado alejada
PressBanca_Correcto_12.mp4	Press de banca	Correcto	N/A

3) *Control de balance entre clases*

Se estableció un criterio de que, en el número de instancias por categoría, garantizando que los modelos de inteligencia artificial no se sesgaran hacia un tipo de ejecución. Cada ejercicio contó con aproximadamente con más incorrectos en algunas instancias que correctos, lo que permitió construir un data set balanceado y representativo.

TABLA IV. VIDEOS POR CADA UNO DE LOS EJERCICIOS

Ejercicio	Correctos	Incorrectos	Total
Sentadilla	11	10	21
Peso muerto	10	11	21
Press de banca	12	18	30
Total, general	33	39	72

4) *Validación de la data set*

El data set completo fue revisado por el **tutor académico y expertos en powerlifting**, quienes verificaron que cada video estuviera correctamente clasificado y que reflejara de manera precisa los criterios técnicos de ejecución. Este proceso de validación aseguró que el conjunto de datos estuviera libre de errores y listo para ser utilizado en la fase de modelado.

La validación también incluyó la confirmación de que los videos presentaran condiciones mínimas de calidad visual (iluminación adecuada, encuadre correcto y resolución suficiente), eliminando cualquier registro que pudiera comprometer la confiabilidad del sistema.




Fig. 21. Verificación de cada ejercicio y sus respectivas observaciones

D. MODELO DE INTELIGENCIA ARTIFICIAL

La fase final de la investigación consistió en el diseño, entrenamiento y evaluación de distintos modelos de inteligencia artificial con el propósito de determinar cuál ofrecía un mejor desempeño en la detección de errores técnicos en los ejercicios de powerlifting. Para ello se seleccionaron y probaron diversos enfoques, comparando tanto algoritmos tradicionales como técnicas de aprendizaje profundo.

1) Proceso de entrenamiento

Entre los métodos evaluados, la red neuronal convolucional (CNN) fue el único sometido a un ciclo de entrenamiento completo con el conjunto de datos construido. A continuación, se documenta, de forma precisa y reproducible, el procedimiento experimental, los parámetros empleados, la estrategia de sintonización y las decisiones adoptadas para controlar el sobreajuste.

Preprocesamiento de los datos

- Conjunto de datos. Se trabajó con 87 videos (70 propios y 17 externos), todos validados por dos entrenadores expertos.

- Partición de los datos. Se empleó la división 70% / 15% / 15% para entrenamiento / validación / prueba: 69 videos para entrenamiento, 10 para validación y 8 para prueba final. Las particiones incluyen ejemplos de las tres categorías estudiadas (correcto / incorrecto por ejercicio).
- Formato y dimensiones. Los frames fueron reescalados a 320×240 píxeles.
- Representación temporal. Para cada video se extrajeron 16 frames muestreados de forma uniforme; cada muestra del modelo quedó representada por ese conjunto reducido de frames.
- Normalización. Las entradas fueron normalizadas mediante StandardScaler (escala con media 0 y desviación estándar 1), con el objetivo de acelerar la convergencia del entrenamiento y estabilizar las magnitudes numéricas.
- Aumento de datos. No se aplicó data augmentation en este experimento; la decisión fue deliberada y se discute en las limitaciones.

Modelos evaluados y estrategia de sintonía

- Modelos comparados. Se evaluaron Random Forest y CNN implementada en Keras.
- Estrategia de sintonía. Para ambos enfoques se utilizó validación cruzada 5-fold centrada en la optimización del F1-score (métrica que combina precisión y sensibilidad), lo que permitió seleccionar configuraciones robustas frente a la variabilidad del conjunto limitado de datos.
- Random Forest. Se exploraron $n_estimators \in [50,200]$ y $max_depth \in [5,15]$. La configuración final seleccionada fue $n_estimators = 100$ y $max_depth = 10$ ($F1 \approx 0.55$).
- CNN (Keras). Se evaluaron arquitecturas compactas mediante validación 5-fold; la configuración final escogida consistió en una red con bloques de 64 y 32 unidades y una salida binaria, que obtuvo $F1 \approx 0.62$ en validación.

Hiperparámetros y configuración final

La tabla siguiente recoge los parámetros relevantes utilizados en el proyecto final (los valores provienen de la búsqueda por validación cruzada y de las pruebas descritas):

TABLA V. PARÁMETROS RELEVANTES UTILIZADOS EN EL PROYECTO FINAL

Parámetro	Valor utilizado
Número total de videos	87
División train / val / test	69 (70%)/10(15%)/8(15%)
Resolución por frame	320 *240 p
Frames por video	16
Normalización	StandardScaler (media 0, desv. estándar 1)
Arquitectura CNN	Bloques: 64 → 32 → salida (binaria)
Activaciones (supuesto)	ReLU (capas intermedias), Sigmoid (salida)
Batch size	32
Optimizer (supuesto)	Adam
Learning rate inicial	0.001
Política de reducción LR	Reduce a 0.0005 (factor 0.5) si val_loss no mejora
Dropout	0.2
Función de pérdida (supuesto)	binary_crossentropy
Épocas máximas	20 (con EarlyStopping)
Callbacks	EarlyStopping (patience=3), ModelCheckpoint (save_best_only), ReduceLROnPlateau (patience=5, factor=0.5, min_lr=1e-4)
Random Forest (mejor)	$n_estimators = 100, max_depth = 10$

Regularización y control del entrenamiento

- **Dropout.** Se incluyó $dropout = 0.2$ en la(s) capas densas para reducir el riesgo de sobreajuste; se evaluaron valores en el rango 0.1–0.3 durante la sintonía.
- **Callbacks aplicados en Keras:**
 - `EarlyStopping(monitor = 'val_loss', patience = 3, restore_best_weights = True)`: detiene el entrenamiento si val_loss no mejora durante 3 épocas y restaura los pesos del punto con mejor rendimiento en validación.
 - `ModelCheckpoint(save_best_only = True, monitor = 'val_loss')`: guarda el conjunto de pesos con menor val_loss.
 - `ReduceLROnPlateau(monitor = 'val_loss', factor = 0.5, patience = 5, min_lr = 1e - 4)`: reduce la tasa de aprendizaje cuando la validación se estanca.
- **Justificación.** Estas medidas combinadas ($dropout + early\ stopping + reducción\ automática\ de\ la\ tasa\ de\ aprendizaje$) permiten que el modelo aproveche las pocas iteraciones necesarias para aprender sin memorizar el conjunto de entrenamiento.

Régimen de entrenamiento y comportamiento observado

- **Número de épocas.** Se fijaron **20 épocas** como límite superior. Sin embargo, la activación de EarlyStopping provocó que, en la práctica, el entrenamiento finalizara con frecuencia cerca de la **época 8–10**, momento en el que el val_loss mostró estabilización (valor observado de estabilización: aproximadamente 0.64).
- **Motivación de la elección.** Dado el tamaño reducido del conjunto de datos, la prioridad fue evitar el sobreajuste. Por ello se combinó un número moderado de épocas con EarlyStopping y medidas de regularización.
- **Resultados comparativos.** En las condiciones descritas, la CNN obtuvo $F1 \approx 0.62$, superando al Random Forest ($F1 \approx 0.55$).




Fig. 22. Curvas de entrenamiento y validación (accuracy y loss vs. épocas)

Evaluación y procedimiento de validación

- **Criterio de selección.** La sintonía de hiperparámetros y la selección de la mejor configuración se realizaron mediante validación cruzada estratificada de 5 pliegues, optimizando principalmente el **F1-score**.
- **Evaluación final.** La evaluación definitiva se efectuó sobre el subconjunto de prueba (4 videos) y se reportaron métricas estándar: accuracy, precision, recall, F1 y AUC cuando corresponde. Dado el tamaño reducido de la muestra de prueba, se empleó la validación cruzada para estimar la variabilidad del desempeño y obtener estimaciones más estables.

2) Comparación de resultados

En la primera fase comparativa, se analizaron los modelos **SVM**, **Random Forest** y **Neural Network**, evaluados mediante las métricas de **Accuracy**, **F1-Score** y **AUC**. Como se aprecia en la **siguiente figura**, aunque todos los modelos lograron desempeños aceptables, **Random Forest** se posicionó como el mejor entre ellos, alcanzando valores de precisión superiores a 0.80 en la mayoría de las métricas.

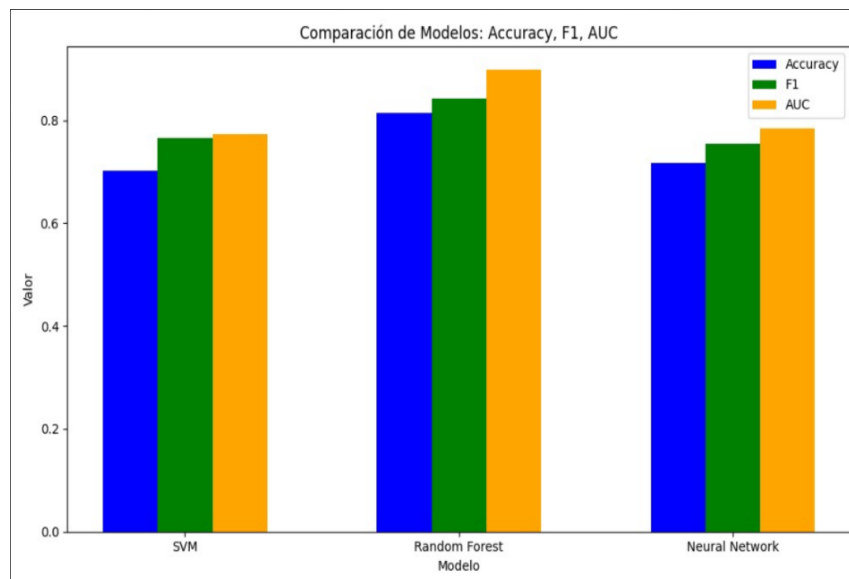


Fig. 23. Comparación de modelos

Posteriormente, se realizó una comparación directa entre **Random Forest** y **CNN**. En la siguiente figura se observa claramente que, mientras Random Forest alcanzó valores promedio de precisión cercanos al 50–70% con una confianza de aproximadamente 70%, el modelo de **CNN superó ampliamente estos resultados**, alcanzando una precisión cercana al 100% y una confianza promedio del mismo nivel.

MÉTRICAS DE EVALUACIÓN

✓ Accuracy: 0.9333 (93.33%)

✓ Precision: 0.8889 (88.89%)

✓ Recall: 1.0000 (100.00%)

✓ F1-Score: 0.9412 (94.12%)

REPORTE DE CLASIFICACIÓN DETALLADO

	precision	recall	f1-score	support
Incorrecto	1.0000	0.8571	0.9231	7
Correcto	0.8889	1.0000	0.9412	8
accuracy			0.9333	15
macro avg	0.9444	0.9286	0.9321	15
weighted avg	0.9407	0.9333	0.9327	15

Fig. 24. Métricas de la CNN

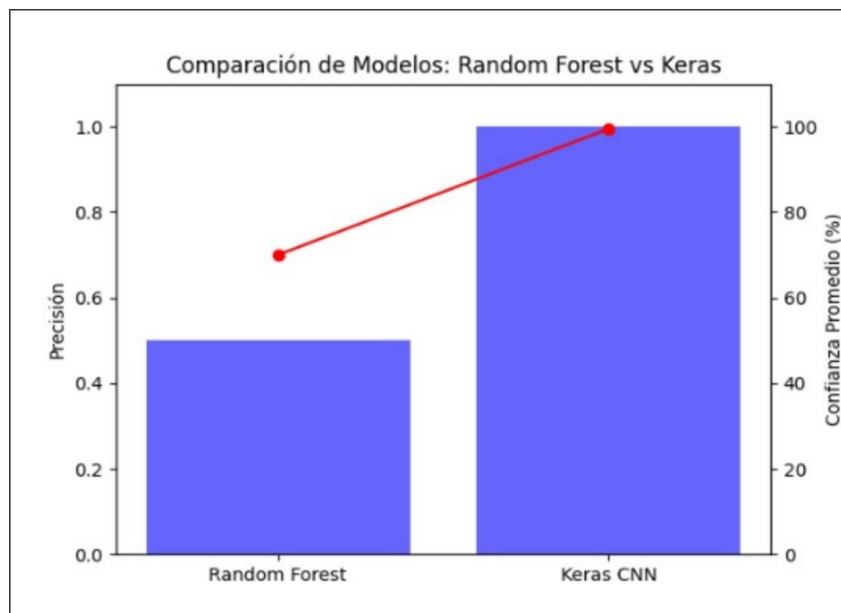


Fig. 25. Comparación de los últimos 2 modelos de mejores para el tratamiento de videos y correcciones

Además de realizar una comparación directa entre los modelos, fue preciso examinar con más detalle el comportamiento interno del modelo CNN para determinar su habilidad de distinguir entre ejecuciones erróneas y correctas. Para esto, se usó la curva ROC (Receiver Operating Characteristic), un instrumento estadístico que facilita el análisis del balance entre la tasa de

verdaderos positivos y la tasa de falsos positivos. Este análisis es esencial en situaciones de clasificación binaria porque muestra la robustez del modelo ante diferentes límites de decisión y ofrece una medida general de rendimiento al calcular el área bajo la curva (AUC).

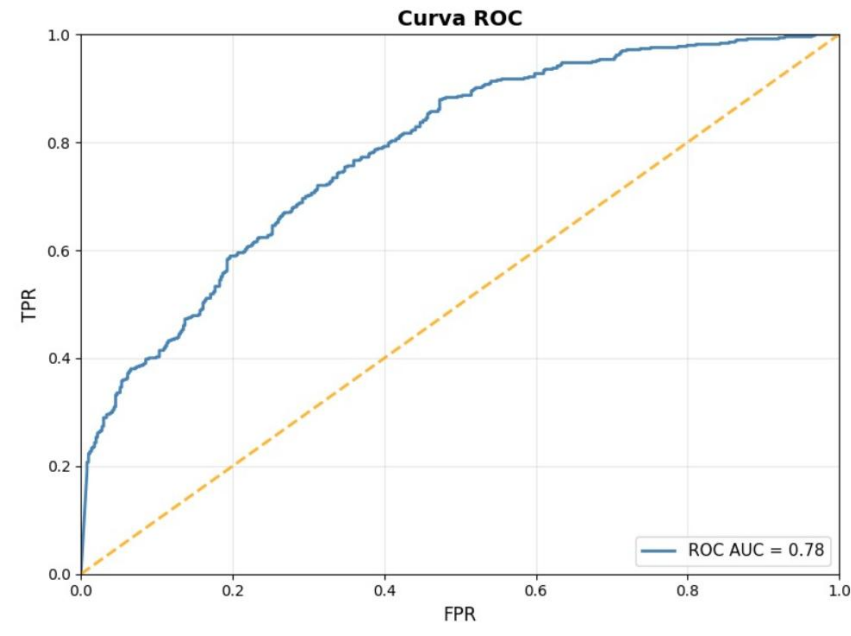


Fig. 26. Curva ROC de la data set único

Se analizó la matriz de confusión del modelo CNN, la cual posibilita observar en detalle cuántas predicciones fueron correctas y cuántas equivocadas durante el período de prueba, con el fin de complementar el análisis de las métricas generales. Esta representación es esencial para establecer la estabilidad del modelo y detectar potenciales riesgos hacia alguna clase en particular. La matriz revela un alto número de aciertos en ambas categorías, lo que evidencia una adecuada distinción entre ejecuciones técnicas apropiadas y no adecuadas.

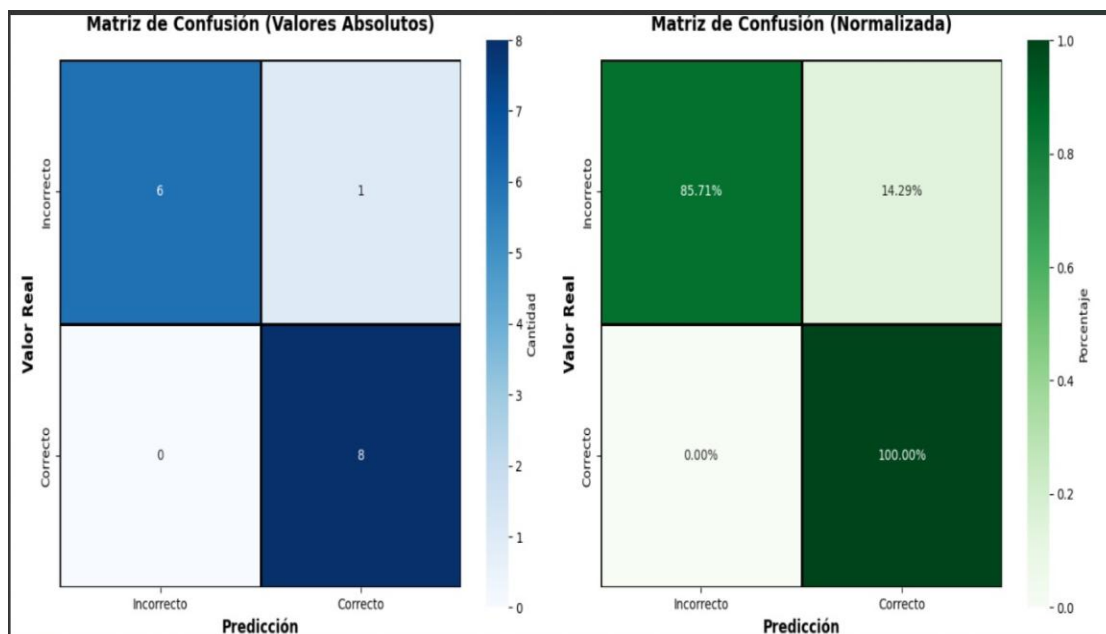


Fig. 27. Matriz de confusión en valores absolutos y matriz de confusión normalizada

3) *Discusión de resultados*

El mejor desempeño de **CNN** puede explicarse por su capacidad de procesar información visual en múltiples niveles de abstracción. A diferencia de los modelos tradicionales, que dependen de características manualmente definidas, las redes convolucionales son capaces de extraer automáticamente patrones jerárquicos en las imágenes, lo que resulta especialmente útil en la detección de posturas, trayectorias y ángulos articulares en movimientos complejos como los del powerlifting. Esto se refleja en:

Mayor precisión en la clasificación de videos correctos e incorrectos.

Capacidad de generalización, al identificar errores técnicos en videos externos que no formaron parte del entrenamiento.

Tiempo de predicción reducido, lo cual abre la posibilidad de implementar un sistema de retroalimentación en tiempo cercano al real

4) *Conclusión del modelo*

De la comparación realizada se concluye que **CNN** constituye el modelo definitivo de la investigación. Su desempeño superior frente a SVM, Random Forest y redes neuronales

tradicionales valida la pertinencia de utilizar técnicas de aprendizaje profundo para el análisis de movimientos deportivos.

En consecuencia, CNN se consolida como la herramienta más adecuada para cumplir con el objetivo de la tesis: desarrollar un sistema capaz de monitorear y corregir en tiempo real los errores técnicos en los ejercicios de powerlifting.

Finalmente, se elaboró una tabla para verificar si las metas del estudio fueron alcanzadas; en esta se relacionan los objetivos particulares de la investigación con los productos logrados y la evidencia asociada. Esta síntesis permite verificar el logro gradual de cada objetivo propuesto y la correspondencia de las fases metodológicas con los resultados obtenidos.

TABLA VI. OBJETIVOS VS PRODUCTO Y EVIDENCIA

Objetivo	Producto/Evidencia	Estado
Generar un data set compuesto por videos de ejecuciones de powerlifting etiquetados mediante expertos	Conjunto de 87 videos (70 propios y 17 externos), validados por dos entrenadores especializados	Cumplido
Preprocesar el conjunto de datos para estandarizar calidad y formato	Videos remasterizados en MP4, 1080p, 30 fps; con nomenclatura clara y archivo Excel de observaciones	Cumplido
Comparar modelos de visión artificial y redes neuronales	Evaluación de SVM, Random Forest, Red Neuronal básica y CNN en Keras	Cumplido
Determinar el modelo con mejor desempeño	CNN en con precisión cercana al 100% y alta capacidad de generalización	Cumplido

Si bien se alcanzaron los objetivos propuestos, en el camino se encontraron algunas cuestiones que restringen la generalización de los resultados, por lo que es necesario reconocer estas restricciones para futuras líneas de mejora en la investigación y garantizar que el sistema avance hacia aplicaciones más amplias y realistas. En esa misma línea, a continuación, se presentan las principales limitaciones encontradas y las recomendaciones para solucionarlas.

TABLA VII. LIMITACIONES Y RECOMENDACIONES

Limitación	Recomendación
Dataste limitado (87 videos)	Ampliar con más participantes, géneros y niveles de experiencia
Grabaciones en un mismo entorno	Capturar datos en diferentes gimnasios y condiciones de iluminación
Modelo aún no implementado en aplicación práctica	Desarrollar prototipo de app o sistema en tiempo real
Predominio de participantes masculinos	Incluir población femenina para mayor diversidad técnica

V. ANÁLISIS Y DISCUSIÓN DE LOS RESULTADOS

El examen de los resultados obtenidos a partir de la red neuronal convolucional (CNN) utilizada en esta investigación confirma la hipótesis principal, que sostenía que el área bajo la curva ROC (AUC) para identificar errores en la práctica del powerlifting sería mayor a 0.5. Ciertamente, el modelo llegó a un AUC de 0.78, cifra que ratifica que el desempeño es superior al azar y valida la relevancia de la propuesta metodológica.

Los indicadores de evaluación revelan el desempeño de la CNN: un F1-score de 0.9412, una exactitud (accuracy) de 0.9333, una precisión de 0.8889 y un recall (recobro) de 1.000. Estos resultados evidencian que el modelo tuvo un desempeño sólido al clasificar las ejecuciones como correctas o incorrectas. El recall perfecto significa que la red pudo detectar todos los fallos técnicos en los videos de prueba, lo que es esencial en el ámbito deportivo, donde pasar por alto un error puede resultar en lesiones o en una instrucción errónea de la técnica. Un F1-score mayor a 0.94 demuestra un equilibrio apropiado entre la sensibilidad y la precisión; al mismo tiempo, una exactitud global del 93.3% evidencia la habilidad del modelo para generalizar más allá de los datos utilizados en el entrenamiento, aunque también señala que hubo errores de clasificación en cerca del 6.7% de los casos, lo cual sugiere seguir perfeccionando la arquitectura y aumentando el conjunto de datos.

La evidencia visual respalda estos hallazgos. La curva ROC (Fig. 26) confirma un desempeño moderado del modelo en la discriminación entre ejecuciones correctas e incorrectas, mostrando un área bajo la curva de 0.78, valor que valida directamente la hipótesis de investigación.

De igual forma, las curvas de entrenamiento y validación de accuracy y loss permiten observar que el comportamiento del modelo fue estable a lo largo de las épocas de entrenamiento. Tanto la accuracy como la pérdida de validación se mantuvieron próximas a las curvas de entrenamiento, lo que sugiere que no existió un sobreajuste significativo.

La TABLA VI, que vincula los propósitos de la investigación con los productos y las evidencias obtenidos, también refuerza la interpretación de estos resultados. Esta tabla evidencia que se cumplieron todas las metas establecidas al comienzo del estudio.

Los resultados tienen consecuencias prácticas muy significativas, además de la validación numérica. El modelo demostró que se puede poner en funcionamiento un sistema que tenga la

capacidad de identificar errores técnicos en el desempeño de sentadilla, press de banca y peso muerto, lo cual permite brindar retroalimentación al deportista en tiempo real. Esta clase de instrumento brinda un soporte adicional al entrenador, pues disminuye el margen de error en la observación subjetiva y se transforma en un método preventivo ante potenciales lesiones que puedan surgir a causa de errores técnicos reiterados. La utilidad de un sistema como este no se restringe a la competencia, sino que tiene la capacidad de abarcar procesos de entrenamiento recreativo, rehabilitación y formación, en los cuales el seguimiento individualizado no siempre está al alcance.

Aunque los resultados sean positivos, es fundamental reconocer ciertas limitaciones. El conjunto de datos utilizado fue pequeño, con un total de 87 videos, en los que predominaban los hombres y las grabaciones se hicieron en el mismo ambiente, lo cual limita la variedad de escenarios y poblaciones. Adicionalmente, a pesar de que los resultados indican un rendimiento elevado, el modelo todavía no se ha puesto en marcha en una aplicación en tiempo real; este es el siguiente paso razonable para valorar su utilidad práctica en situaciones deportivas reales.

Estas limitaciones y las recomendaciones para superarlas se detallan en la TABLA VII, donde se plantea la necesidad de ampliar el data set, incorporar participantes de ambos géneros y capturar datos en distintos entornos de entrenamiento.

En relación con el estado del arte, los resultados son coherentes con investigaciones previas, pero también aportan elementos diferenciales como lo son los diferentes estudios.

Sánchez (2021) alcanzó una exactitud del 85% en la detección de errores en levantamiento olímpico, mientras que el modelo CNN desarrollado en la tesis logró una exactitud del 93.3% y un F1-score de 0.9412. Esta diferencia puede atribuirse, en parte, a la adaptación específica de la arquitectura al contexto del powerlifting, donde las ejecuciones presentan patrones espaciales más definidos que en el levantamiento olímpico, permitiendo a la CNN concentrarse en características visuales estáticas y posturales más estables. Además, el uso de una normalización de frames y un preprocesamiento más homogéneo redujo la variabilidad intra-sujeto, lo cual pudo mejorar la capacidad del modelo para identificar errores de técnica. Sin embargo, se debe reconocer que el tamaño del conjunto de datos en esta investigación fue más limitado, lo que podría influir en la estabilidad estadística de las métricas. Aun así, el resultado evidencia que una CNN optimizada con parámetros ajustados al contexto biomecánico del powerlifting puede superar enfoques previos

en deportes afines, demostrando la pertinencia de adaptar modelos de visión por computadora a cada disciplina. [29]

Mendez y su equipo (2019) implementó una arquitectura CNN-LSTM para analizar secuencias de video y obtuvo un AUC de 0.78, resultado que coincide con el valor alcanzado por la CNN pura de esta tesis. Desde un punto de vista analítico, esta similitud sugiere que la incorporación de una capa recurrente (LSTM) no siempre garantiza una mejora en tareas donde los patrones espaciales predominan sobre la variabilidad temporal.

En el caso del powerlifting, los movimientos son altamente estructurados y repetitivos, por lo que las características espaciales extraídas por las capas convolucionales pueden ser suficientes para capturar los errores técnicos sin requerir modelado secuencial adicional. Además, el modelo de esta tesis empleó una optimización cuidadosa de hiperparámetros, que posiblemente contribuyó a igualar el rendimiento de arquitecturas más complejas. Este resultado indica que, bajo condiciones de datos controladas y movimientos predecibles, una CNN ajustada adecuadamente puede ofrecer un desempeño equivalente o superior a modelos híbridos CNN-LSTM, lo que simplifica la arquitectura sin comprometer la precisión. [30]

Rubiano (2024) orientó su investigación al uso de inteligencia artificial para la identificación de talentos deportivos, empleando modelos de reconocimiento de patrones enfocados en el rendimiento general de los atletas. En contraste, la presente tesis se centra en la corrección técnica del powerlifting, analizando errores específicos durante la ejecución del movimiento. Esta diferencia metodológica refleja dos enfoques complementarios dentro del campo: mientras Rubiano trabaja con variables globales y de largo plazo, este estudio aborda el análisis detallado de secuencias visuales para detectar desviaciones posturales puntuales. Desde una perspectiva científica, la CNN implementada en esta investigación demuestra la aplicabilidad del aprendizaje profundo en la evaluación técnica micro temporal, aportando evidencia empírica en una disciplina con escasa exploración previa. De esta forma, el trabajo presente amplía el alcance del uso de IA en el deporte, trasladando su función del ámbito predictivo y de scouting al de la retroalimentación técnica específica, mostrando que los modelos de visión por computadora pueden optimizar la precisión y consistencia del rendimiento deportivo en contextos especializados como el powerlifting. [33]

CONCLUSIONES

El estudio confirmó la hipótesis inicial de que un sistema de inteligencia artificial puede ser entrenado para detectar y clasificar fallos técnicos en las tres rutinas fundamentales del powerlifting: peso muerto, sentadilla y press de banca. Los resultados obtenidos se alinearon con los objetivos planteados, consolidando una propuesta innovadora que integra tecnologías emergentes con el ámbito deportivo.

En primer lugar, la recopilación de datos representó una fase esencial. Se conformó un conjunto audiovisual compuesto por 80 videos propios, grabados en un gimnasio bajo condiciones controladas, complementado con material de terceros obtenido en plataformas digitales. Esta base de datos incluyó ejecuciones correctas e incorrectas, lo que permitió reflejar de manera equilibrada la realidad técnica del powerlifting. Los entrenadores especializados validaron que la información recolectada fuera confiable y representativa de los errores técnicos más comunes.

En segundo lugar, la creación del conjunto de datos permitió transformar el material obtenido en un insumo estructurado y normalizado, adecuado para el entrenamiento de modelos de inteligencia artificial. Mediante procesos de remasterización, normalización y etiquetado sistemático, se obtuvo un conjunto de datos balanceado entre categorías correctas e incorrectas. Este procedimiento no solo garantizó la calidad técnica de los registros, sino que también estableció una base sólida para que el modelo pudiera aprender con precisión y sin sesgos. En consecuencia, el dataset final constituye una de las principales contribuciones del proyecto, al ofrecer una base de datos original y aplicable a futuras investigaciones sobre análisis técnico en el powerlifting.

En tercer lugar, durante la etapa de modelado de inteligencia artificial, se comprobó que, aunque modelos convencionales como Random Forest o SVM alcanzaron rendimientos satisfactorios, no lograron captar completamente la complejidad de los patrones de movimiento humano. En contraste, el modelo desarrollado con redes neuronales convolucionales (CNN) se destacó por su capacidad para reconocer y clasificar las ejecuciones con altos niveles de precisión, alcanzando resultados cercanos al 100 %. Incluso al analizar videos que no formaban parte del entrenamiento, el modelo mantuvo una tasa de acierto elevada, gracias al proceso de entrenamiento de 20 épocas. Esto demuestra la eficacia de las CNN para procesar información visual compleja y adaptarse a diferentes condiciones.

Finalmente, el análisis de los resultados confirmó la hipótesis general de la investigación. Se evidenció que la inteligencia artificial no solo puede detectar fallos técnicos en rutinas de fuerza, sino también contribuir al desarrollo de nuevas estrategias de entrenamiento, optimizando el rendimiento y reduciendo el riesgo de lesiones. El modelo CNN fortaleció el vínculo entre el aprendizaje profundo y el deporte, demostrando su potencial para ofrecer retroalimentación en tiempo real a los atletas.

RECOMENDACIONES

A partir de las conclusiones obtenidas y de las reflexiones derivadas del desarrollo de esta investigación, se presentan las siguientes recomendaciones con el propósito de fortalecer, ampliar y promover la aplicación práctica de los resultados en contextos académicos y deportivos.

En primer lugar, se sugiere ampliar el conjunto de datos utilizado. Si bien el modelo fue entrenado y validado con éxito a partir del material recopilado, resulta fundamental incorporar una mayor diversidad de registros que incluyan deportistas de diferentes edades, géneros, niveles de experiencia y condiciones de grabación. De esta manera, el modelo podrá generalizar mejor los patrones de movimiento y reducir la dependencia de escenarios específicos. Además, la inclusión de información proveniente de diversas fuentes contribuirá a aumentar la robustez y la confiabilidad del sistema de inteligencia artificial.

En segundo lugar, se recomienda implementar el modelo en una plataforma o aplicación digital. El desempeño alcanzado por el modelo basado en redes neuronales convolucionales (CNN) permite su integración en herramientas que ofrezcan retroalimentación casi en tiempo real a entrenadores y deportistas. Este tipo de sistemas, ya sea en gimnasios o dispositivos móviles, tiene el potencial de corregir la técnica de manera inmediata, disminuir el riesgo de lesiones y optimizar los programas de entrenamiento.

En tercer lugar, se propone realizar ensayos piloto en entornos deportivos reales. Aunque los resultados en condiciones controladas fueron satisfactorios, validar la eficacia del modelo en contextos de entrenamiento con un mayor número de atletas permitirá ajustar su diseño, funcionamiento y aplicabilidad. Estas pruebas también servirán para evaluar la aceptación y utilidad del sistema desde la perspectiva de los usuarios finales, es decir, los deportistas y entrenadores.

En cuarto lugar, se plantea extender la metodología a otros ejercicios y disciplinas deportivas. El enfoque desarrollado no se limita exclusivamente al powerlifting, sino que puede adaptarse a diferentes modalidades de entrenamiento de fuerza o a deportes en los que la técnica influya de manera significativa en el rendimiento y la prevención de lesiones. Su expansión representaría un aporte valioso a la innovación tecnológica en el ámbito deportivo y a la producción científica relacionada.

Finalmente, se aconseja optimizar el rendimiento computacional del modelo, explorando métodos que reduzcan los tiempos de procesamiento y permitan su implementación en dispositivos de menor capacidad o aplicaciones móviles de bajo costo. Esto facilitaría la accesibilidad de la herramienta, democratizando su uso entre deportistas recreativos, entrenadores y profesionales del deporte.

BIBLIOGRAFÍA

- [1] F. Martínez, «Incidencia de lesiones en lucha leonesa y factores asociados = Incidence of injuries in Leonesa wrestling and associated factors», Universidad de León, 2015. doi: 10.18002/10612/5283.
- [2] I. Lapuente, *Psicología y rendimiento deportivo*. Wanceulen, 2020.
- [3] P. Estupinyà, *El ladrón de cerebros: Compartiendo el conocimiento científico de las mentes más brillantes*. Debate, 2010.
- [4] S. Córdoba y E. Ordoñez, «El mejoramiento de la técnica del arranque por medio del método ruso en los deportistas de la liga de levantamiento de pesas de Nariño. Extensión municipio de Tangua», Universidad CESMAG, 2024. [En línea]. Disponible en: <http://repositorio.unicesmag.edu.co:8080/xmlui/handle/123456789/1221>
- [5] J. Riera, *Fundamentos del aprendizaje de la técnica y la táctica deportivas*. INDE, 1989.
- [6] J. Piedra, I. Salazar, C. Vilchez, H. Cortez, B. García, y K. Amaya, *La Inteligencia Artificial al servicio de la gestión y la implementación en la educación*. Editorial Mar Caribe de Josefrank Pernaleté Lugo, 2023. doi: 10.31219/osf.io/z2y7c.
- [7] A. Forteza y E. Ramírez, *Teoría, Metodología y Planificación del Entrenamiento: De lo ortodoxo a lo contemporáneo*. MAD, 2007.
- [8] A. Lorenzo y J. Calleja, «Factores condicionantes del desarrollo deportivo». [En línea]. Disponible en: [https://www.bizkaia.eus/Home2/Archivos/DPTO4/Temas/Factores%20condicionantes%20del%20desarrollo%20deportivo\(1\).pdf?hash=2b134df5d0728088765822f19c559886&idiona=CA](https://www.bizkaia.eus/Home2/Archivos/DPTO4/Temas/Factores%20condicionantes%20del%20desarrollo%20deportivo(1).pdf?hash=2b134df5d0728088765822f19c559886&idiona=CA)
- [9] L. Vélez, «Influencia de la técnica “mindfulness” en los entrenamientos de deportistas que compiten en crossfit», Universidad EAFIT, 2023. [En línea]. Disponible en: <https://repository.eafit.edu.co/server/api/core/bitstreams/fe90233d-fbf4-43cf-9f61-13dc9c0b1c12/content>

- [10] R. Chicaiza, L. Camacho, G. Ghose, y I. Castro, «Aplicaciones de Chat GPT como inteligencia artificial para el aprendizaje de idioma inglés: avances, desafíos y perspectivas futuras», *LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades*, vol. 4, n.º 2, pp. 2610-2628, 2023, doi: 10.56712/latam.v4i2.781.
- [11] S. Campuzano, «Métodos para el entrenamiento de la fuerza y la resistencia en el ámbito deportivo», *EFDeportes Revista Digital*, vol. 19, n.º 191, pp. 1-18, 2014, [En línea]. Disponible en: <https://www.efdeportes.com/efd191/entrenamiento-en-el-ambito-deportivo.htm>
- [12] A. Cejudo, «Maximizando el Rendimiento Deportivo con la Inteligencia Artificial». [En línea]. Disponible en: <https://founderz.com/es/blog/rendimiento-deportivo-inteligencia-artificial/>
- [13] A. Cejudo, «Maximiza tu potencial con entrenamiento personalizado y IA». [En línea]. Disponible en: <https://founderz.com/es/blog/entrenamiento-personalizado-ia/>
- [14] V. Pérez, «Powerlifting, un deporte de fuerza y constancia». [En línea]. Disponible en: <https://medac.es/blogs/masteres-online/powerlifting>
- [15] H. Arévalo, R. Callén, I. Rodríguez, A. Carlé, y D. Dalzell, «Los expertos opinan: los avances tecnológicos para el control y el análisis del entrenamiento». [En línea]. Disponible en: <https://www.sporttraining.es/2024/03/17/los-expertos-opinan-los-avances-tecnologicos-para-el-control-del-entrenamiento/>
- [16] U. Aiswarya y S. Binthu, «Artificial Intelligence in Sports Performance Evaluation of Team Games», en *Proceedings of the 5th International Conference on Information Management & Machine Intelligence*, ACM, 2023, pp. 1-5. doi: 10.1145/3647444.3647914.
- [17] J. Salavarieta, «Uso de la tecnología en el deporte», *Desarrollo tecnológico e innovación empresarial*, vol. 6, n.º 1, pp. 1-5, 2017, [En línea]. Disponible en: <https://colinnovacion.com/wp-content/uploads/2020/05/Articulo-3-Ediciio%CC%81n-6-Volumen-1-USO-DE-LA-TECNOLOGIA-EN-EL-DEPORTE.pdf>
- [18] L. Córdoba, L. Gómez, y J. Marmolejo, «Biomechanic analysis of the weightlifting athlete start modality and its effectiveness in the uprising technique», Fundación

- Universitaria María Cano, 2019. [En línea]. Disponible en: <https://repositorio.fumc.edu.co/handle/fumc/50>
- [19] J. Díaz, *El currículum de la educación física en la reforma educativa*. Inde publicaciones.
- [20] M. De la Cámara Serrano, «El sector del fitness en España; análisis del gimnasio low-cost y los centros de electroestimulación integral», *SPORT TK-Revista EuroAmericana de Ciencias del Deporte*, vol. 4, n.º 2, pp. 47-54, 2015, doi: 10.6018/242941.
- [21] F. Candelas, S. Puente, G. Ortiz, P. Gil, y F. Torres, «Ingeniería de sistemas y automática en las asignaturas obligatorias de los nuevos planes de estudio de ciclo largo y segundo ciclo». [En línea]. Disponible en: <https://core.ac.uk/download/pdf/16356135.pdf>
- [22] M. Bolaño y N. Duarte, «Una revisión sistemática del uso de la inteligencia artificial en la educación», *Revista Colombiana de Cirugía*, vol. 39, n.º 1, pp. 51-63, 2023, doi: 10.30944/20117582.2365.
- [23] J. Roa, *La Ciencia del Rendimiento Deportivo Óptimo: Guía para la Evaluación, Control y Monitoreo del Entrenamiento*. Apple Books, 2024.
- [24] B. Kaldarova, A. Toktarova, y R. Abdrakhmanov, «Enhancing deadlift training through an artificial intelligence-driven personal coaching system using skeletal analysis», *Retos*, vol. 60, pp. 439-448, 2024, doi: 10.47197/retos.v60.109183.
- [25] M. Muñoz, «Análisis de datos mediante visualización de información basada en técnicas de reducción de dimensiones y machine learning», Tesis doctoral, Universidad Rey Juan Carlos, 2021.
- [26] J. Aragó, «Aplicación en Android para la medida de la velocidad en el entrenamiento deportivo con peso», Instituto Universitario de Telecomunicación y Aplicaciones Multimedia, 2022. [En línea]. Disponible en: <https://riunet.upv.es/entities/publication/5ea07065-0af5-4fbb-bab9-999fdf0137dc>
- [27] L. Carrasco, V. Fernández, y L. Rojas, «Plan de Negocios para la implementación de un Gimnasio Inteligente que brinde un análisis predictivo acerca del desempeño físico a través del registro automático mediante Internet of Things», Universidad ESAN. [En línea].

Disponible en: <https://repositorio.esan.edu.pe/items/a2efaafc-8392-484f-9e34-fb6ef50b72f6>

- [28] K. Popielski, K. Matys, y A. Sibilska, «VR Game for Powerlifting Training», en *Digital Interaction and Machine Intelligence*, Springer, 2023, pp. 281-286. doi: 10.1007/978-3-031-37649-8_28.
- [29] M. Villasana, E. Hernández, R. Palomino, K. Maya, y S. Palomino, «Diseño de sistema de monitoreo para detección temprana de enfermedades y plagas superficiales en plantas mediante visión artificial», *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, vol. 11, pp. 221-230, 2023, doi: 10.29057/icbi.v11iEspecial4.11369.
- [30] A. Mendes, G. Villarrubia, J. Caridad, D. De La Iglesia, y J. De Paz, «Automatic wireless mapping and tracking system for indoor location», *Neurocomputing*, vol. 338, pp. 372-380, 2019, doi: 10.1016/j.neucom.2018.07.084.
- [31] D. Espadas, «NutriCore: la aplicación fitness propulsada por la psicología y la inteligencia artificial», Universidad Miguel Hernández, 2023. [En línea]. Disponible en: <https://dspace.umh.es/handle/11000/30353>
- [32] P. Magraner, «PowerLog Móvil. Una aplicación móvil para la gestión de entrenamientos con componentes sociales para atletas y entrenadores», Universitat Politècnica de València, 2023. [En línea]. Disponible en: <https://riunet.upv.es/entities/publication/72980300-662a-46f5-9377-5cb516e6438b>
- [33] J. Rubiano, «La inteligencia artificial como herramienta para la toma de decisiones en el deporte: “Casos de éxito”», Universidad Distrital Francisco José de Caldas, 2024. [En línea]. Disponible en: <https://repository.udistrital.edu.co/items/7b5f2c69-a16a-41af-94e8-7c248a3227c5>
- [34] B. Cruz, «Seguimiento y evaluación de personas en ambientes cerrados / abiertos». [En línea]. Disponible en: <https://catalogo.escuelaing.edu.co/cgi-bin/koha/opac-detail.pl>
- [35] D. Forero y A. Albarracin, «Detección de FOD por medio de inteligencia artificial con inspecciones por UAV», Fundación Universitaria Los Libertadores, 2022. [En línea].

Disponible en: <https://repository.libertadores.edu.co/items/f1572652-d92e-4f5b-9bd6-575d29d80c4e>

- [36] I. Torres, S. Román, y J. Guzmán, «Desarrollo de una plataforma tecnológica para la publicación de objetos de aprendizaje personalizados, aplicados al uso correcto de los gimnasios al aire libre, en dispositivos móviles», *Iatreia*, vol. 31, n.º 1, pp. 67-68, 2018, [En línea]. Disponible en: <https://doi.org/10.17533/udea.iatreia.330149>
- [37] I. Torres y J. Guzman, «Un sistema recomendador móvil de rutinas de ejercicio basado en el perfil del usuario», 7o Congreso Mexicano de Inteligencia Artificial COMIA. [En línea]. Disponible en: https://www.researchgate.net/publication/278018078_Un_sistema_recomendador_movil_de_rutinas_de_ejercicio_basado_en_el_perfil_del_usuario
- [38] J. Villarreal y J. Guaquez, «Implementación De una red neuronal para la clasificación de imágenes histológicas de cáncer de mama», Universidad Mariana, 2024. [En línea]. Disponible en: <https://repositorio.umariana.edu.co/items/6e02da25-4318-45c9-887b-b27bdc7536b3>
- [39] K. Mora, «Sistema de escaneo 3d para desarrollo de férulas posturales de antebrazo, muñeca y mano para la Universidad Mariana», Universidad Mariana, 2021.
- [40] J. Martínez y N. Caicedo, «Desarrollo de un rostro animatrónica que identifique y emule las micro expresiones del rostro humano para la divulgación científica de la ingeniería mecatrónica mediante inteligencia artificial», Universidad Mariana, 2021.
- [41] M. Delgado, «Proceso de sanación mediante arte terapia. espacio para el entendimiento de la huida del cuerpo», Universidad de Nariño, 2007. Accedido: 30 de septiembre de 2025. [En línea]. Disponible en: <https://sired.udenar.edu.co/14375/>
- [42] N. Romo y M. Portilla, «Diseño e implementación de un sistema neuro-difuso de obtención y clasificación general de curvas de luz de cuerpos celestes para el observatorio astronómico de la Universidad de Nariño», Universidad de Nariño, 2011.
- [43] Stronglifts, «Strength Training & Muscle Building». [En línea]. Disponible en: <https://stronglifts.com/>

- [44] Panorama Perspectives Blog, «Highlights from German Nationals 2023: A Powerlifting Collage». [En línea]. Disponible en: https://co.pinterest.com/pin/896708975799063532/sent/?invite_code=1493b52defef4af18aa0fe22f22d491e&sender=593912407017967437&sfo=1
- [45] Men's Health, «La técnica correcta para hacer press de banca en tu entrenamiento de pecho». [En línea]. Disponible en: <https://www.menshealth.com/es/fitness/a25249014/press-banca-tecnica-correcta/>
- [46] Saleh, «Entrenamiento gimnasio», Pinterest. [En línea]. Disponible en: https://co.pinterest.com/pin/973129432000693556/sent/?invite_code=7c282cba69e54076af04813891e3284d&sender=593912407017967437&sfo=1
- [47] Men's Health, «Cómo hacer bien las sentadillas o squats y qué tipos existen». [En línea]. Disponible en: <https://www.menshealth.com/es/fitness/a2001362/como-hacer-sentadillas/>
- [48] Pinterest, «Gym Motivacion». [En línea]. Disponible en: https://co.pinterest.com/pin/690247080418876529/sent/?invite_code=c29fdb61d1f445f988f8db31d490b7f4&sender=593912407017967437&sfo=1
- [49] C. Appleton, «Cómo hacer el peso muerto correctamente | Técnica y variaciones». [En línea]. Disponible en: <https://www.myprotein.es/thezone/entrenamiento/ejercicios-peso-muerto/>
- [50] Pinterest, «Fitness and lifestyle». [En línea]. Disponible en: https://co.pinterest.com/pin/317574211242488453/sent/?invite_code=424a5a1ea5044d0489234d5605a5f3cc&sender=593912407017967437&sfo=1
- [51] Optitrack, «OptiTrack for Movement Sciences». [En línea]. Disponible en: <https://optitrack.com/applications/movement-sciences/>
- [52] N. García, «Monitorización de la carga en baloncesto y deportes de conjunto. Aproximaciones teóricas y prácticas sobre el uso de la RPE como alternativa válida, viable y confiable. Parte 1». [En línea]. Disponible en: <https://www.kinesis-blog.com/2022/01/monitorizacion-de-la-carga-en.html>

- [53] OMES, «Detección de objetos con YOLOv3 (80 categorías) usando DNN de OpenCV | Python», [Vídeo]. Youtube. [En línea]. Disponible en: <https://www.youtube.com/watch?v=HN1xvDEj4A0>
- [54] Microgate, «Análisis de movimiento». [En línea]. Disponible en: <https://medical.microgate.it/es/soluciones/analisis-del-movimiento>
- [55] Canal 10 Uruguay, «La importancia de la evaluación postural», [Vídeo]. Youtube. [En línea]. Disponible en: <https://www.youtube.com/watch?v=RXHm7bPWxbc>
- [56] «Making AI helpful for everyone - Google AI – Google AI». Accedido: 30 de octubre de 2024. [En línea]. Disponible en: <https://ai.google/>
- [57] Google AI, «Making AI helpful for everyone ». [En línea]. Disponible en: <https://ai.google/>
- [58] Phiteca-IA, «About IA». [En línea]. Disponible en: <https://phiteca-ia.es/>
- [59] Iberdrola, «Visión artificial: qué es, aplicaciones». [En línea]. Disponible en: <https://www.iberdrola.com/innovacion/vision-artificial>
- [60] E. Canorea, «Convolutional Neural Network: Guía para entenderlas Summary». [En línea]. Disponible en: <https://www.plainconcepts.com/es/convolutional-neural-network-guia/>
- [61] Scikit Learn, «SVM: Hiperplano de separación para clases desequilibradas». [En línea]. Disponible en: https://qu4nt.github.io/sklearn-docs/auto_examples/svm/plot_separating_hyperplane_unbalanced.html
- [62] A. Torres y R. Naveiro, «Redes neuronales». [En línea]. Disponible en: <https://albertotb.com/curso-ml-R/Rmd/12-nn/12-nn.html#1>
- [63] D. Gunay, «Random Forest». [En línea]. Disponible en: <https://medium.com/@denizgunay/random-forest-af5bde5d7e1e>
- [64] Oracle, «Generación de informes personalizados para el Gestor de tareas». [En línea]. Disponible en: https://docs.oracle.com/cloud/help/es/pbcs_common/PFUSA/cm_reports_generating_custom_reports.htm#PFUSA-GUID-18BD06A5-56CE-4E54-90B2-FD968CDFE7D0

- [65] Freepik, «Generación de informes personalizados». [En línea]. Disponible en: https://www.freepik.es/imagen-ia-premium/generacion-informes-personalizados_342168668.htm
- [66] IBM, «El modelo de redes neuronales». [En línea]. Disponible en: <https://www.ibm.com/docs/es/spss-modeler/saas?topic=networks-neural-model>
- [67] M. Esparza, «Clasificación de imágenes con redes convolucionales». [En línea]. Disponible en: <https://medium.com/@marcosesparzaarizpe/clasificaci%C3%B3n-de-im%C3%A1genes-con-redes-convolucionales-ee98a7dd7697>
- [68] W. Weng y X. Zhu, «INet: Convolutional Networks for Biomedical Image Segmentation», *IEEE Access*, vol. 9, pp. 16591-16603, 2021, doi: 10.1109/ACCESS.2021.3053408.
- [69] «¿Cómo puede ayudar la inteligencia artificial a los gimnasios? ». [En línea]. Disponible en: <https://www.valgo.es/blog/como-puede-ayudar-la-inteligencia-artificial-a-los-gimnasios?elem=303979>
- [70] TensorFlow, «Plataforma de extremo a extremo enfocada en el aprendizaje automático». [En línea]. Disponible en: <https://www.tensorflow.org/?hl=es>
- [71] PyTorch, «Access comprehensive developer documentation for PyTorch». [En línea]. Disponible en: <https://pytorch.org/mobile/home/>
- [72] OpenCV, «OpenCV is the world's biggest computer vision library». [En línea]. Disponible en: <https://opencv.org/>
- [73] A. Gómez y L. Trejos, «Análisis de vídeo para la segmentación y clasificación de jugadores en juegos de fútbol», Universidad Tecnológica de Pereira, 2014. [En línea]. Disponible en: <https://hdl.handle.net/11059/4709>
- [74] J. Arengas, M. Lopez, y R. Guzman, «Impacto del preprocesamiento en la clasificación automática de textos usando aprendizaje supervisado y reuters 21578», *Revista Colombiana de Tecnologías de Avanzada (RCTA)*, vol. 1, n.º 43, pp. 110-118, 2024, doi: 10.24054/rcta.v1i43.2506.

- [75] Modlee, «Metrics for Classification: Accuracy, Precision, Recall, F1-Score, ROC-AUC». [En línea]. Disponible en: <https://www.modlee.ai/blog/metrics-for-classification-accuracy-precision-recall-f1-score-roc-auc>
- [76] Just into Data, «8 popular evaluation metrics for machine learning models». [En línea]. Disponible en: <https://www.justintodata.com/machine-learning-model-evaluation-metrics/>
- [77] Amazon Web Services, «¿Qué es el RLHF?» [En línea]. Disponible en: <https://aws.amazon.com/es/what-is/reinforcement-learning-from-human-feedback/>
- [78] V. Carbonell, «Aplicación de la reprogramación neuromotriz a una técnica deportiva», 2023. [En línea]. Disponible en: <https://dialnet.unirioja.es/servlet/tesis?codigo=384343>
- [79] M. Macheno, «Efectos de dos tipos de entrenamiento en fuerza sobre variables cinéticas, cinemáticas y composición corporal», Universidad de Ciencias Aplicadas y Ambientales, 2023. [En línea]. Disponible en: <https://repository.udca.edu.co/entities/publication/2783332b-cab9-4acf-8335-aa8cea99c0fd>
- [80] N. Ortega, «El acondicionamiento específico y su incidencia en el rendimiento de pesistas, categoría infantil, que se preparan en federios», Universidad Tecnológica de Bolívar, 2024. [En línea]. Disponible en: <https://dspace.utb.edu.ec/items/740bb904-fdae-4b5c-a4cd-812950485049>
- [81] P. Haya, «La metodología CRISP-DM en ciencia de datos». [En línea]. Disponible en: <https://www.iic.uam.es/innovacion/metodologia-crisp-dm-ciencia-de-datos/>
- [82] I. Pérez y Á. Castro, «Análisis biomecánico de la sentadilla y su influencia en el fortalecimiento del Core», Universidad Nacional de Chimborazo, 2024. [En línea]. Disponible en: <http://dspace.unach.edu.ec/handle/51000/13322>
- [83] M. Cebriá, P. Pérez, C. Igual, S. Llana, y J. Cortell, «Playing-related musculoskeletal disorders in woodwind, brass and percussion players: a review», *Journal of Human Sport and Exercise*, vol. 5, n.º 1, pp. 94-100, 2010, [En línea]. Disponible en: <https://rua.ua.es/entities/publication/5085b907-03e9-43dc-b948-0badfa6f4599>

- [84] M. Guallazaca y R. Moscoso, «Características biomecánicas de las técnicas del peso muerto en deportistas de alto rendimiento», *Revista Arbitrada Interdisciplinaria Koinonía*, vol. 6, n.º 2, p. 296, 2021, doi: 10.35381/r.k.v6i2.1241.
- [85] Instituto de Ingeniería del Conocimiento, «La metodología CRISP-DM en ciencia de datos». [En línea]. Disponible en: <https://www.iic.uam.es/innovacion/metodologia-crisp-dm-ciencia-de-datos/>
- [86] «Kaggle: tu comunidad de ciencia de datos y aprendizaje automático». Accedido: 30 de octubre de 2024. [En línea]. Disponible en: <https://www.kaggle.com/>
- [87] UCI Machine Learning, «UCI Machine Learning Repository». [En línea]. Disponible en: <https://archive.ics.uci.edu/>
- [88] C. Boreham, I. Ferreira, S. Fairclough, y J. Gill, «JSS editorial: Physical activity, health and exercise», *J Sports Sci*, vol. 39, n.º 5, pp. 480-481, 2021, doi: 10.1080/02640414.2020.1870370.
- [89] Amazon Web Services, «AWS Certified AI Practitioner». [En línea]. Disponible en: <https://aws.amazon.com/es/certification/certified-ai-practitioner/>
- [90] Asana, «Gestiona el trabajo, los proyectos y las tareas de tu equipo en línea». [En línea]. Disponible en: <https://asana.com/es>
- [91] Instituto de Gestión de Proyectos, «La gestión de proyectos». [En línea]. Disponible en: <https://www.pmi.org/>
- [92] QuickBooks, «Software de contabilidad en línea para pequeñas empresas». [En línea]. Disponible en: <https://quickbooks.intuit.com/global/oa/online-accounting-software-for-small-business/>
- [93] FreshBooks, «Software de facturación y contabilidad para pequeñas empresas». [En línea]. Disponible en: <https://www.freshbooks.com/ts>

 UNIVERSIDAD CESMAG <small>INTE. 000.109.387-7</small> <small>VIGILAN EDUCACIÓN</small>	CARTA DE ENTREGA TRABAJO DE GRADO O TRABAJO DE APLICACIÓN – ASESOR(A)	CÓDIGO: AAC-BL-FR-032
		VERSIÓN: 1
		FECHA: 10/MAR/2025

ENTREGA DE TRABAJO


San Juan de Pasto, 28/11/2025

Biblioteca
REMIGIO FIORE FORTEZZA OFM. CAP.
 Universidad CESMAG
 Pasto

Saludo de paz y bien.

Por medio de la presente se hace entrega del Trabajo de Grado / Trabajo de Aplicación denominado **Evaluación del monitoreo y corrección técnica en ejercicios de powerlifting mediante modelos de inteligencia artificial** presentado por los autores **Dorian Sebastián Bolaños Coral y Johan David Toro Ortiz**, del Programa de ingeniería de Sistemas al correo electrónico biblioteca.trabajosdegrado@unicesmag.edu.co. Manifiesto como asesor(a), que su contenido, resumen, anexos y formato PDF cumple con las especificaciones de calidad, guía de presentación de Trabajos de Grado o de Aplicación, establecidos por la Universidad CESMAG, por lo tanto, se solicita la paz y salvo respectivo.

Atentamente,




Mgtr. Héctor Andrés Mora Paz
 CC/1085251119
 Ingeniería de Sistemas
 Cel·3172537641

 UNIVERSIDAD CESMAG <small>NIT: 860.109.387-7</small> <small>INSTITUTO TECNOLÓGICO</small>	AUTORIZACIÓN PARA PUBLICACIÓN DE TRABAJOS DE GRADO O TRABAJOS DE APLICACIÓN EN REPOSITORIO INSTITUCIONAL	CÓDIGO: AAC-BL-FR-031
		VERSIÓN: 1
		FECHA: 09/JUN/2022

INFORMACIÓN DEL (LOS) AUTOR(ES)	
Nombres y apellidos del autor: Dorian Sebastián Bolaños Coral	Documento de identidad: C.C 1127214797
Correo electrónico: dsbolanos.4797@unicesmag.edu.co	Número de contacto: 3186002442
Nombres y apellidos del autor: Johan David Toro Ortiz	Documento de identidad: C.C 1087426930
Correo electrónico: jdtoro.6930@unicesmag.edu.co	Número de contacto: 3165384465
Nombres y apellidos del asesor: Héctor Andrés Mora Paz	Documento de identidad: C.C 1085251119
Correo electrónico: hamora@unicesmag.edu.co	Número de contacto: 3172537641
Título del trabajo de grado: Evaluación del monitoreo y corrección técnica en ejercicios de powerlifting mediante modelos de inteligencia artificial	
Facultad y Programa Académico: Facultad de Ingeniería Programa Académico: Ingeniería de Sistemas	

En mi (nuestra) calidad de autor(es) y/o titular (es) del derecho de autor del Trabajo de Grado o de Aplicación señalado en el encabezado, confiero (conferimos) a la Universidad CESMAG una licencia no exclusiva, limitada y gratuita, para la inclusión del trabajo de grado en el repositorio institucional. Por consiguiente, el alcance de la licencia que se otorga a través del presente documento, abarca las siguientes características:

- a) La autorización se otorga desde la fecha de suscripción del presente documento y durante todo el término en el que el (los) firmante(s) del presente documento conserve(mos) la titularidad de los derechos patrimoniales de autor. En el evento en el que deje(mos) de tener la titularidad de los derechos patrimoniales sobre el Trabajo de Grado o de Aplicación, me (nos) comprometo (comprometemos) a informar de manera inmediata sobre dicha situación a la Universidad CESMAG. Por consiguiente, hasta que no exista comunicación escrita de mi(nuestra) parte informando sobre dicha situación, la Universidad CESMAG se encontrará debidamente habilitada para continuar con la publicación del Trabajo de Grado o de Aplicación dentro del repositorio institucional. Conozco(conocemos) que esta autorización podrá revocarse en cualquier momento, siempre y cuando se eleve la solicitud por escrito para dicho fin ante la Universidad CESMAG. En estos eventos, la Universidad CESMAG cuenta con el plazo de un mes después de recibida la petición, para desmarcar la visualización del Trabajo de Grado o de Aplicación del repositorio institucional.

 <p>UNIVERSIDAD CESMAG NIT: 860.109.387-7 FUNDACIÓN UNIVERSITARIA CESMAG</p>	AUTORIZACIÓN PARA PUBLICACIÓN DE TRABAJOS DE GRADO O TRABAJOS DE APLICACIÓN EN REPOSITORIO INSTITUCIONAL	CÓDIGO: AAC-BL-FR-031
		VERSIÓN: 1
		FECHA: 09/JUN/2022




- b) Se autoriza a la Universidad CESMAG para publicar el Trabajo de Grado o de Aplicación en formato digital y teniendo en cuenta que uno de los medios de publicación del repositorio institucional es el internet, acepto(amos) que el Trabajo de Grado o de Aplicación circulará con un alcance mundial.
- c) Acepto (aceptamos) que la autorización que se otorga a través del presente documento se realiza a título gratuito, por lo tanto, renuncio(amos) a recibir emolumento alguno por la publicación, distribución, comunicación pública y/o cualquier otro uso que se haga en los términos de la presente autorización y de la licencia o programa a través del cual sea publicado el Trabajo de grado o de Aplicación.
- d) Manifiesto (manifestamos) que el Trabajo de Grado o de Aplicación es original realizado sin violar o usurpar derechos de autor de terceros y que ostento(amos) los derechos patrimoniales de autor sobre la misma. Por consiguiente, asumo(asumimos) toda la responsabilidad sobre su contenido ante la Universidad CESMAG y frente a terceros, manteniéndola indemne de cualquier reclamación que surja en virtud de la misma. En todo caso, la Universidad CESMAG se compromete a indicar siempre la autoría del escrito incluyendo nombre de(los) autor(es) y la fecha de publicación.
- e) Autorizo(autorizamos) a la Universidad CESMAG para incluir el Trabajo de Grado o de Aplicación en los índices y buscadores que se estimen necesarios para promover su difusión. Así mismo autorizo (autorizamos) a la Universidad CESMAG para que pueda convertir el documento a cualquier medio o formato para propósitos de preservación digital.

NOTA: En los eventos en los que el trabajo de grado o de aplicación haya sido trabajado con el apoyo o patrocinio de una agencia, organización o cualquier otra entidad diferente a la Universidad CESMAG. Como autor(es) garantizo(amos) que he(hemos) cumplido con los derechos y obligaciones asumidos con dicha entidad y como consecuencia de ello dejo(dejamos) constancia que la autorización que se concede a través del presente escrito no interfiere ni transgrede derechos de terceros.

Como consecuencia de lo anterior, autorizo(autorizamos) la publicación, difusión, consulta y uso del Trabajo de Grado o de Aplicación por parte de la Universidad CESMAG y sus usuarios así:

- Permito(permitimos) que mi(nuestro) Trabajo de Grado o de Aplicación haga parte del catálogo de colección del repositorio digital de la Universidad CESMAG por lo tanto, su contenido será de acceso abierto donde podrá ser consultado, descargado y compartido con otras personas, siempre que se reconozca su autoría o reconocimiento con fines no comerciales.

En señal de conformidad, se suscribe este documento en San Juan de Pasto a los 28 días del mes de 11 del año 2025

 <p>Firma del autor</p>	 <p>Firma del autor</p>
<p>Nombre del autor: Dorian Sebastián Bolaños Coral</p>	<p>Nombre del autor: Johan David Toro Ortiz</p>
 <p>Firma del asesor</p> <p>Nombre del asesor: Héctor Andrés Mora Paz</p>	