

**Identificación de Factores Clave en el Proceso de Hipertrofia Muscular: Un Enfoque
Basado en Ciencia de Datos para Futuras Investigaciones**

Albert Danilo Blanco Castellanos

Asesor:

Luis Angel Anillo Arrieta

Universidad Nacional Abierta y a Distancia – UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería – ECBTI

Especialización en Ciencia de Datos y Analítica

2024

Dedicatoria

Dedico este trabajo a todas las personas que han sido parte de mi camino académico y personal. A mi familia, cuyo amor incondicional y constante apoyo han sido mi mayor fortaleza. A mis profesores, por su dedicación, paciencia y sabiduría, que me han guiado en este proceso de aprendizaje. A mis amigos, por su compañía, ánimo y risas que han aliviado los momentos difíciles. A todos los que creyeron en mí, me brindaron palabras de aliento y me inspiraron a seguir adelante. Este logro es también de ustedes.

Agradecimientos

Expreso mi más profundo agradecimiento a todas las personas que colaboraron en la realización de este trabajo, proporcionando su asistencia técnica y recursos materiales, así como su valiosa contribución en la preparación del manuscrito:

A mis asesores académicos, por su guía, consejos y apoyo durante todo el proceso de investigación y redacción.

A la UNAD por ofrecer el entorno adecuado y las facilidades necesarias para llevar a cabo esta investigación.

A todas las personas que, de alguna manera, aportaron su apoyo, ánimo y comprensión a lo largo de todo el proceso. Su ayuda fue crucial para alcanzar este logro.

Resumen

Esta monografía se adentra en el mundo del crecimiento muscular, explorando cómo la biología de nuestros músculos responde a la alimentación y al ejercicio. Se enfoca en descifrar los secretos esenciales que guían el desarrollo muscular y cómo estos conocimientos pueden ser aplicados para mejorar el rendimiento deportivo y la salud.

El objetivo principal es identificar los factores cruciales que impactan en el crecimiento muscular. Esta búsqueda detallada busca proporcionar una comprensión más profunda para personalizar programas de entrenamiento y nutrición, optimizando así el desarrollo muscular y promoviendo una mejor salud en general.

Esta investigación no solo aborda los aspectos biológicos, sino que también explora cómo estos hallazgos pueden ser implementados en la práctica. Se consideran herramientas innovadoras, como el aprendizaje automático, para analizar datos complejos y ofrecer estrategias personalizadas en el ejercicio y la alimentación.

El trabajo establece las bases para futuras investigaciones, ofreciendo la posibilidad de transformar nuestra comprensión y enfoque hacia el crecimiento muscular, lo que potencialmente mejorará el rendimiento deportivo y la salud muscular para todos.

Palabras clave: Hipertrofia muscular. Modelos predictivos. Entrenamiento

Abstract

This monograph delves into the world of muscle growth, exploring how the biology of our muscles responds to diet and exercise. It focuses on uncovering the essential secrets that guide muscle development and how this knowledge can be applied to improve athletic performance and health.

The main objective is to identify the crucial factors that impact muscle growth. This detailed investigation aims to provide a deeper understanding to personalize training and nutrition programs, thereby optimizing muscle development and promoting better overall health.

This research not only addresses biological aspects but also explores how these findings can be implemented in practice. Innovative tools, such as machine learning, are considered to analyze complex data and offer personalized strategies in exercise and nutrition.

The work lays the foundation for future research, offering the possibility to transform our understanding and approach to muscle growth, which could potentially enhance athletic performance and muscle health for everyone.

Keywords: Muscle hypertrophy. Predictive models. Training

Tabla de Contenido

Introducción...	10
Planteamiento del Problema...	12
Justificación...	14
Objetivos...	15
Objetivo General...	15
Objetivos Específicos...	15
Marco Conceptual...	16
Marco Teórico...	18
Metodología...	22
Datos Relevantes para el Crecimiento Muscular: ...	25
Postura de los Autores y Análisis Crítico: Una evaluación Detallada...	28
Análisis Cuantitativo de Factores en el Crecimiento Muscular...	58
Ciencia de Datos y Modelos Predictivos en el Crecimiento Muscular...	75
Perspectivas Futuros Desarrollos...	82
Conclusiones...	85
Referencias...	87
Apéndices	93

Lista de Tablas

Tabla 1 <i>Estudio bibliométrico</i>	25
Tabla 2 <i>Artículos y autores</i>	26
Tabla 3 <i>Estudio 1</i>	32
Tabla 4 <i>Estudio 2</i>	37
Tabla 5 <i>Estudio 3</i>	41
Tabla 6 <i>Estudio 4</i>	46
Tabla 7 <i>Estudio 5</i>	57
Tabla 8 <i>Métricas de evaluación del modelo</i>	80

Lista de Figuras

Figura 1 <i>Metodología</i>	22
Figura 2 <i>Correlación volumen de Carga</i>	34
Figura 3 <i>Parámetros rutinas entrenamiento</i>	48
Figura 4 <i>Submodelo de red neuronal</i>	49
Figura 5 <i>Rutina ejercicios diarios</i>	49
Figura 6 <i>Creación de la red neuronal, Python</i>	49
Figura 7 <i>Series optimas de ejercicios de carga para la hipertrofia muscular</i>	59
Figura 8 <i>Multiseries de ejercicio para hipertrofia muscular</i>	60
Figura 9 <i>Respuesta hipertrofia volumen dependiente</i>	61
Figura 10 <i>Volumen Landmark</i>	62
Figura 11 <i>Análisis de datos</i>	76
Figura 12 <i>Curva Roc</i>	77
Figura 13 <i>Matriz de confusión</i>	78
Figura 14 <i>Curva de aprendizaje</i>	81

Lista de Apéndices

Apéndice A <i>Algoritmo de regresión logística-parte a</i>	93
Apéndice B <i>Algoritmo de regresión logística-parte b</i>	94
Apéndice C <i>Algoritmo de regresión logística-parte b</i>	94

Introducción

En esta monografía, la hipertrofia muscular se erige como el centro de atención, desencadenando una variedad de enfoques y perspectivas en la literatura especializada. Este estudio se propone abordar este tema a través de una discusión crítica entre distintos estudios de hipertrofia, evaluando sus métodos, enfoques y conclusiones.

Cada objetivo específico delineado se traducirá en un capítulo individual, donde se analizarán aspectos del proceso de hipertrofia muscular y se evaluarán las variables más influyentes. Se avanzará desde la recopilación de datos relevantes hasta un análisis bibliométrico detallado, una evaluación cuantitativa de la importancia de los factores identificados y la aplicación de técnicas de ciencia de datos para identificar patrones y relaciones complejas entre los diferentes factores relacionados con el crecimiento muscular.

La integración de la ciencia de datos en esta investigación no solo permitirá una comprensión más profunda del fenómeno de la hipertrofia muscular, sino que también abrirá nuevas perspectivas y posibilidades para la optimización del rendimiento deportivo y la promoción de la salud muscular.

En este contexto, el modelo predictivo desempeña un papel fundamental al proporcionar una herramienta cuantitativa para anticipar y comprender mejor el crecimiento muscular en atletas de élite. El empleo de métodos de análisis de datos, como la regresión logística, permite analizar la relación entre diversas variables predictoras y la probabilidad de hipertrofia muscular. Al incorporar datos específicos de entrenamiento, nutrición y características individuales de los atletas, el modelo predictivo puede identificar patrones y tendencias que ayudan a predecir el éxito de un programa de entrenamiento en términos de crecimiento muscular.

Esta capacidad predictiva es invaluable para optimizar la planificación del entrenamiento y adaptar las estrategias según las necesidades individuales de cada persona. Esto, a su vez, puede mejorar significativamente el rendimiento deportivo y la efectividad de los programas de acondicionamiento físico. El modelo predictivo no solo complementa la comprensión de los factores que influyen en la hipertrofia muscular, sino que también ofrece una guía práctica para el diseño de programas de entrenamiento más efectivos y personalizados.

Este estudio pretende ofrecer una visión integral y aplicada de la hipertrofia muscular, proporcionando herramientas y conocimientos valiosos para la mejora del rendimiento deportivo y la salud muscular.

Planteamiento del problema

La investigación contemporánea sobre el rendimiento deportivo y la salud muscular se enfrenta al reto de identificar los factores que afectan la hipertrofia muscular. A pesar de los avances en las áreas de ejercicio y nutrición, todavía es necesario entender cómo se relacionan la genética, el entrenamiento y la alimentación para fomentar o limitar el crecimiento muscular. Esta falta de conocimiento complica la personalización de los programas de ejercicio y dieta, lo cual es esencial para optimizar el desarrollo muscular y la salud general.

El planteamiento del problema se centra en la necesidad de comprender a fondo los mecanismos de la hipertrofia muscular y cómo se pueden aprovechar los avances en inteligencia artificial y análisis de datos para personalizar los programas de entrenamiento y nutrición. Esta tarea implica un enfoque multidisciplinario y riguroso, donde es crucial considerar una variedad de modelos de machine learning propuestos por diferentes autores y estudios. Entre los modelos de machine learning que se considerarán, se incluye la segmentación de imágenes musculares mediante redes neuronales convolucionales (CNN) para la cuantificación automatizada de la infiltración de grasa muscular, como lo demuestra el estudio de Kenneth A. Weber y su equipo. Este enfoque no solo mejora la eficiencia en la medición de propiedades musculares, sino que también proporciona una objetividad crucial en la práctica clínica. Otro modelo para considerar es la regresión logística, que permitirá analizar la relación entre diversas variables predictoras y la probabilidad de hipertrofia muscular. Sin embargo, existen limitaciones actuales en la investigación sobre hipertrofia muscular. Por ejemplo, aunque el metaanálisis de Refalo y

colaboradores (2021) proporciona información importante sobre los efectos de la carga del entrenamiento de fuerza en la hipertrofia muscular y la fuerza máxima, presenta algunas limitaciones. Estas incluyen diferencias en la especificidad del entrenamiento, la consideración de la fatiga y el volumen de entrenamiento, y las adaptaciones neuromusculares. La efectividad del entrenamiento puede depender de la especificidad del programa en relación con los objetivos individuales, y factores como la distribución del volumen de entrenamiento y la capacidad de recuperación individual pueden influir en los resultados.

Este planteamiento del problema busca establecer las bases para investigaciones que puedan mejorar la eficacia de los programas de entrenamiento y nutrición, con el objetivo último de optimizar el rendimiento deportivo y promover la salud muscular de manera efectiva. La monografía adoptará un enfoque crítico y analítico, utilizando la ciencia de datos para explorar y evaluar diversas perspectivas de expertos en hipertrofia muscular. Se llevará a cabo un debate entre autores con diferentes enfoques sobre genética, entrenamiento y nutrición, utilizando métodos avanzados de análisis de datos. Cada autor respaldará sus argumentos con evidencia científica y casos relevantes, centrándose en la aplicación de técnicas de ciencia de datos para interpretar los datos en este contexto. Se buscarán áreas de consenso y divergencia para identificar posibles áreas de investigación futuras.

Justificación

En esta monografía, se busca mejorar el rendimiento deportivo y la salud muscular. La meta primordial es comprender los factores que inciden en la hipertrofia muscular. A pesar de los avances en el ámbito del ejercicio y la alimentación, aún hay una brecha importante en la comprensión de cómo la genética, el entrenamiento y la nutrición interactúan para estimular o detener el crecimiento muscular.

Esta falta de investigación dificulta la personalización de los programas de entrenamiento y nutrición, lo cual es determinante para maximizar el potencial de desarrollo muscular y la salud de los músculos. Por ello, esta monografía se enfoca en la necesidad primordial de profundizar en las distintas variables que intervienen en la hipertrofia muscular y en cómo llevar este conocimiento y aplicarlo de manera práctica.

En este contexto, los modelos de aprendizaje automático juegan un papel fundamental. Se explora cómo la inteligencia artificial y el análisis de datos pueden ayudar a desentrañar los secretos del crecimiento muscular. Se aspira a establecer una base sólida que permita personalizar los programas de entrenamiento y nutrición de manera más efectiva. Abordar este desafío requiere un enfoque multidisciplinario y una atención meticulosa.

Objetivos

Objetivo general

Identificar los Factores Clave en el Proceso de Hipertrofia Muscular: Un Enfoque Basado en Ciencia de Datos para Futuras Investigaciones.

Objetivos específicos

-Recopilar datos relevantes relacionados con el crecimiento muscular, incluyendo información sobre entrenamiento, nutrición y otros factores influyentes, obtenidos de fuentes como Scopus, Web of Science, Nature Research, Google Académico y otros recursos académicos pertinentes.

- Analizar factores relevantes para el crecimiento muscular a través de un estudio bibliométrico detallado utilizando herramientas especializadas como Scopus, Web of Science y otras plataformas académicas. Además, se examinará la postura de los autores respecto a estos factores para comprender su percepción y su influencia en el campo de la hipertrofia muscular.

-Evaluar la importancia de cada uno de los elementos identificados en el crecimiento muscular mediante un análisis cuantitativo y estadístico, con el fin de comprender mejor su contribución y relación específica con la hipertrofia muscular.

-Aplicar técnicas de ciencia de datos y modelos predictivos para identificar patrones y relaciones complejas entre los factores que influyen en el crecimiento muscular.

Marco Conceptual

En el marco conceptual de esta monografía, se aborda la optimización del rendimiento deportivo y la hipertrofia muscular a través de un enfoque interdisciplinario respaldado por técnicas de inteligencia artificial, específicamente el Aprendizaje Automático (Machine Learning). El objetivo principal es identificar variables críticas relacionadas con el crecimiento muscular, estableciendo una base sólida para desarrollos futuros en este campo.

Utilizando estas técnicas, se explora en profundidad cómo diversos factores, incluidos la genética, el entrenamiento y la nutrición, influyen en el proceso de hipertrofia muscular. La misión es personalizar y adaptar programas de entrenamiento y alimentación para que cada individuo pueda alcanzar su máximo potencial en términos de desarrollo muscular y bienestar general.

Analizar factores relevantes para el crecimiento muscular a través de un estudio bibliométrico detallado utilizando herramientas especializadas como Scopus, Web of Science y otras plataformas académicas. Además, se examinará la postura de los autores respecto a estos factores para comprender su percepción y su influencia en el campo de la hipertrofia muscular

El crecimiento muscular constituye el núcleo de la investigación (Díaz-Curiel, M., Rodríguez-Romo, F. J., y Martínez-Amat, A., 2020). Se busca comprender a fondo el proceso de aumento en el tamaño y la fuerza de los músculos, vinculado estrechamente al entrenamiento de fuerza y una alimentación adecuada. La clave radica en descubrir los mecanismos subyacentes que impulsan el crecimiento muscular y cómo optimizarlos.

La genética también juega un papel fundamental en esta investigación, analizando cómo los factores genéticos influyen en la respuesta individual al entrenamiento y la nutrición (Díaz- Curiel, M., Rodríguez-Romo, F. J., y Martínez-Amat, A., 2020). Esta información puede permitir la identificación de marcadores genéticos que faciliten la personalización de los programas de entrenamiento y alimentación.

La suplementación y las dietas nutricionales son elementos cruciales en este enfoque, como señalaron David Flores Zafra e Ingrid Mendivel Landeo (2019). Se explora cómo la suplementación y diferentes estilos de alimentación afectan el crecimiento muscular, considerando aspectos como la cantidad de proteínas consumidas y el uso de suplementos como la creatina, parte esencial de la estrategia para optimizar la ganancia de masa muscular.

El entrenamiento de fuerza, en conjunto con la periodización del entrenamiento, es un componente esencial de este enfoque, tal como lo destacaron Díaz-Curiel, M., Rodríguez- Romo, F. J., y Martínez-Amat (2020). Se analiza cómo la modulación de la intensidad y el volumen del entrenamiento, combinada con una planificación cuidadosa a lo largo del tiempo, puede influir significativamente en el desarrollo de la hipertrofia muscular, facilitando un progreso constante y evitando estancamientos. Además, se consideran los factores ambientales, como la altitud, la temperatura y la humedad, que pueden influir en el rendimiento deportivo y el desarrollo muscular, según Saunders (2017). Adaptar los planes de entrenamiento y la dieta a diferentes condiciones ambientales es crucial para obtener los mejores resultados.

La inteligencia deportiva es fundamental para tomar decisiones estratégicas basadas en datos y conocimientos precisos (Albarrán Jardón, Edwin Román, 2020), lo que

contribuye significativamente a identificar variables clave para el crecimiento muscular y proporciona una base sólida para futuros desarrollos en este campo. Finalmente, el enfoque en el deporte de alto rendimiento busca estrategias efectivas para que los atletas alcancen su máximo potencial en términos de desarrollo muscular y rendimiento deportivo (Albarrán Jardón, Edwin Román, 2020). Este enfoque es esencial para identificar variables que influyen en el crecimiento muscular y establecer pautas sólidas para investigaciones futuras.

Marco Teórico

El Marco teórico se sustenta en una serie de investigaciones multidisciplinarias y aplicaciones de Machine Learning en diferentes campos de la salud y el rendimiento físico. Estos estudios proporcionan una base sólida para comprender los mecanismos clave relacionados con la hipertrofia muscular. La hipertrofia muscular es un fenómeno de gran interés en el ámbito de la salud y el rendimiento físico, y su comprensión ha avanzado significativamente en las últimas décadas. En este contexto, la presente monografía tiene como objetivo identificar variables clave para el crecimiento muscular utilizando técnicas de Machine Learning. Mi investigación previa ha explorado diversos factores que influyen en la hipertrofia muscular, incluyendo genética, entrenamiento y nutrición (Schoenfeld, 2021).

Genética y Cardiovascular

Algunas investigaciones multidisciplinarias han aplicado Machine Learning a la genética y la salud cardiovascular. Moon, Posada-Quintero y Chon (2023) utilizaron redes neuronales basadas en texto para visualizar datos genéticos relacionados con el infarto de

miocardio. Su objetivo es identificar patrones genéticos significativos y conexiones genéticas subyacentes a esta enfermedad cardiovascular. Estos avances demuestran la capacidad de Machine Learning para comprender las bases genéticas de condiciones médicas complejas.

Imágenes Médicas

Además, McElliott y sus colaboradores (2023) se centraron en el uso de técnicas de aprendizaje profundo para analizar imágenes médicas de lesiones renales. Su investigación busca mejorar la comprensión de las lesiones renales y su impacto en la estructura y función del riñón. Esto subraya la utilidad de las técnicas de Machine Learning en el análisis de imágenes médicas.

Interconexión Músculos-Huesos

Por otro lado, Ono, Denda, Tsukahara, Nakamura y Okamoto (2022) se enfocaron en el desarrollo de un enfoque terapéutico que fortalece simultáneamente músculos y huesos. Esto podría ser beneficioso para mejorar la función locomotora y tratar enfermedades relacionadas con la fragilidad ósea y la debilidad muscular, destacando la interconexión entre músculos y huesos en la salud y el rendimiento físico.

Envejecimiento y Salud

Yang y su equipo (2021) investigan el proceso de envejecimiento y las enfermedades relacionadas con la edad, analizando los mecanismos moleculares

subyacentes y proponiendo intervenciones y tratamientos para promover un envejecimiento saludable. Esta investigación resalta la importancia de la salud y la biología en la búsqueda de soluciones a problemas complejos.

Aplicaciones en Hipertrofia Muscular

La aplicación de Machine Learning y aprendizaje profundo para identificar variables clave en la hipertrofia muscular se alinea con estos enfoques multidisciplinarios, representando una evolución natural en la investigación científica.

Cargas de Entrenamiento

Carlson y sus colegas (2022) examinaron estudios que comparan diferentes cargas de entrenamiento en relación con la hipertrofia muscular y la fuerza. Sus resultados indican que las cargas más altas favorecen las ganancias de fuerza en comparación con las cargas bajas y moderadas cuando el volumen de trabajo es igual.

Colaboración Interdisciplinaria

Rivera Bedoya y Sánchez Zapata (2020) destacan la colaboración interdisciplinaria entre ingenieros industriales y expertos en ciencias de la salud, diseñando un algoritmo de redes neuronales para generar planes de acondicionamiento físico personalizados.

Subrayan la importancia de seleccionar variables adecuadas y diseñar mecanismos de aprendizaje efectivos para el éxito de esta aproximación.

Inteligencia Artificial Explicable

López García (2021) en su trabajo aplicó la Inteligencia Artificial Explicable para identificar y analizar variaciones genómicas en el contexto de las distrofias musculares de Duchenne y Becker, proporcionando una comprensión más clara de estas enfermedades.

Medios Digitales y Enseñanza

Zhang (2022) propuso un modelo de red neuronal RBF para evaluar la eficacia de los medios digitales en la enseñanza, destacando su capacidad de generalización y extensión.

Nutrición Personalizada

Karla Cecilia Rivera Valdivia (2022) exploró las aplicaciones de la inteligencia artificial en la nutrición personalizada, analizando su impacto y riesgos potenciales.

Rehabilitación y Terapia Física

Quispe Laura y Sánchez Zapata (2017) desarrollaron un sistema inteligente que utiliza algoritmos de Machine Learning para evaluar la evolución de pacientes con lesiones en la rodilla durante la terapia física, mejorando así los resultados de la rehabilitación.

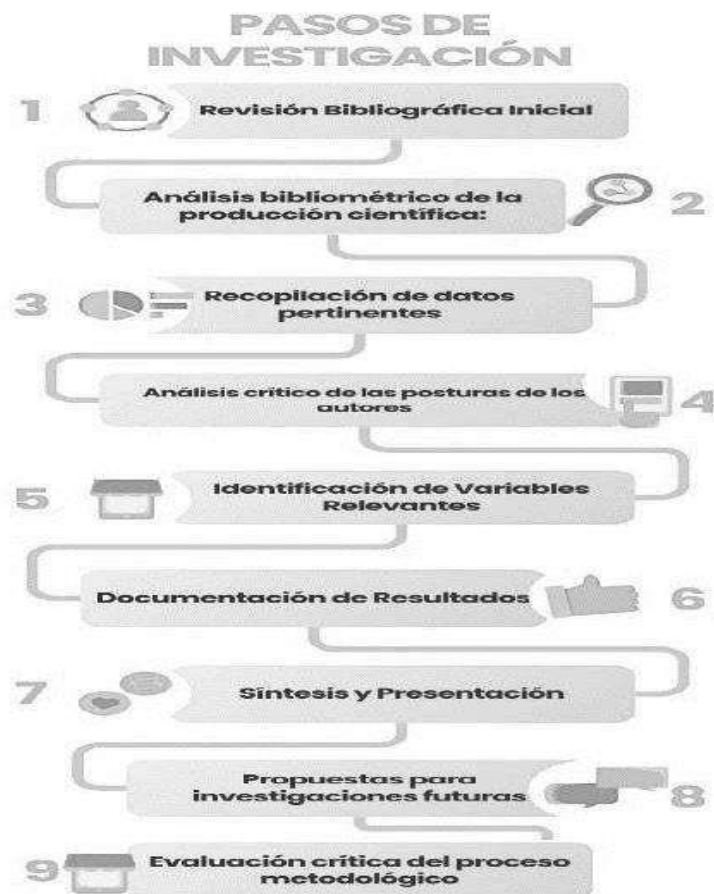
Predicción de Riesgo en Urgencias

Refalo et al. (2021) se enfocaron en la estratificación de riesgo en pacientes con dolor torácico en urgencias, creando modelos de predicción de riesgo utilizando aprendizaje automático, lo que mejora la toma de decisiones clínicas.

Metodología

Figura 1

Metodología



Fuente. Elaboración propia, 2023

Abordaje Metodológico para Investigar la Intersección entre Hipertrofia Muscular, Entrenamiento de Fuerza con la Ciencia de Datos

Revisión exhaustiva de la literatura: Se llevará a cabo una revisión inicial detallada de la bibliografía existente sobre hipertrofia muscular, con el objetivo de identificar teorías, metodologías y resultados relevantes para la investigación.

Análisis bibliométrico de la producción científica: Se realizará un análisis de la bibliometría por medio de Scopus y herramientas de análisis de datos como Excel y Python, para evaluar la producción científica relacionada con la hipertrofia muscular, identificando tendencias de investigación, autores destacados, revistas relevantes y áreas temáticas emergentes.

Recopilación de datos pertinentes: Se recopilarán datos relevantes para el estudio, incluyendo resultados de investigaciones previas, mediciones experimentales, variables fisiológicas y cualquier otra información relevante para comprender los factores que influyen en la hipertrofia muscular.

Análisis crítico de las posturas de los autores: Se llevará a cabo un análisis crítico de las posturas y enfoques de diferentes autores respecto a los factores clave en el proceso de hipertrofia muscular, comparando perspectivas teóricas, metodológicas y hallazgos de estudios relevantes.

Identificación de variables determinantes: Se identificarán y analizarán las variables clave que influyen en el proceso de hipertrofia muscular, utilizando enfoques de ciencia de datos para identificar patrones y relaciones entre las variables estudiadas.

Documentación y presentación de resultados: Se documentarán los hallazgos

obtenidos de la revisión de la literatura, el análisis bibliométrico y la recopilación de datos, presentándolos de manera clara y concisa mediante tablas, gráficos y otros recursos visuales.

Síntesis y exposición de los resultados: Se realizará una síntesis de la información recopilada y se presentarán los hallazgos de manera organizada y visualmente atractiva, resaltando tendencias identificadas y conclusiones derivadas del análisis.

Propuestas para investigaciones futuras: Se ofrecerán recomendaciones y directrices para **futuras** investigaciones en el campo de la hipertrofia muscular, basadas en los hallazgos y conclusiones del estudio, identificando áreas de investigación adicionales y posibles aplicaciones prácticas de los resultados obtenidos.

Evaluación crítica del proceso metodológico: Se realizará una evaluación crítica del proceso metodológico utilizado en la investigación, identificando posibles limitaciones y áreas de mejora para estudios futuros.

Datos Relevantes para el Crecimiento Muscular: Entrenamiento

Tabla 1

Estudio Bibliométrico

# Total de Publicaciones	Publicaciones por año	Tipo de Documentos	Países de Afiliación	Palabras Clave	Bases de Datos Utilizadas	Revista / Sitio Web	Citas Recibidas
30	2004 = 1	Artículos = 24	USA = 10	Genética	Scopus		2
	2006 = 1	Revistas = 4	China = 5	Crecimiento Muscular	Web of Science		6
	2007 = 1	Tesis = 2	Japón = 2	Leucina	Nature Research		2
	2015 = 2		Rusia = 2	Proteínas	Biblioteca digital Universidad del Valle		1
	2016 = 2		Australia = 2	Nutrición deportiva	Repositorio institucional RI		4
	2018 = 2		México = 3	Entrenamiento de fuerza	Google Académico		5
	2019 = 2		España = 3	Lesiones renales	Journal of Applied Physiology		3
	2020 = 2		Argentina = 1	Inteligencia artificial	Journal of Sports Sciences		1
	2021 = 1		Canadá = 2	Rendimiento deportivo	Scielo		0
	2022 = 3			Toma de decisiones	Kaggle		5
	2023 = 4			Machine Learning		<u>Revista Nature Medicine</u>	2

Nota. Análisis de referencias bibliográficas por país

Tabla 2
Artículos y Autores

Artículo	Autor(es)
Genetic data visualization using literature text-based neural networks	Moon, J., Posada-Quintero, H. F., & Chon, K. H.
Crecimiento muscular, estableciendo una base sólida para futuros desarrollos en el campo	Díaz-Curiel, M., Rodríguez-Romo, F. J., & Martínez-Amat, A.
Leucine regulates translation initiation of protein synthesis in skeletal muscle after exercise	Norton, L. E., & Layman, D. K.
Protein and amino acids for athletes	Tipton, K. D., & Wolfe, R. R.
Dietary protein for athletes: From requirements to optimum adaptation	Phillips, S. M., & Van Loon, L. J.
Nutrition and Athletic Performance	Thomas, D. T., Erdman, K. A., & Burke, L. M.
The Muscle & Strength Pyramid: Entrenamiento	Helms, E., Morgan, A., & Valdez, A.
Time course of recovery following resistance training leading or not to failure	Morán-Navarro R, Pérez CE, Mora-Rodríguez R, de la Cruz-Sánchez E, González-Badillo JJ, Sánchez-Medina L, Pallarés JG
The relationship between the number of repetitions performed at given intensities is different in endurance and strength trained athletes	Richens, B. & Cleather, D.J.
Strength and Hypertrophy Adaptations Between Low- vs. High-Load Resistance Training: A Systematic Review and Meta-analysis	Schoenfeld, BJ, Grgic J, Ogborn D, Krieger JW.
Effects of Low- vs. High-Load Resistance Training on Muscle Strength and Hypertrophy in Well-Trained Men	Schoenfeld BJ, Peterson MD, Ogborn D, Contreras B, Sonmez GT.
Redes neuronales para análisis de datos genéticos	Kennet, R.
Influencia de la carga de entrenamiento de fuerza en la hipertrofia y fuerza máxima	Fisiología del Ejercicio
Sistema de Visión Artificial para la Detección y Corrección de Posturas en Ejercicios realizados por Fisicoculturistas	Martínez José, J. M.
Diseño de un algoritmo de redes neuronales artificiales para la elaboración de planes de acondicionamiento físico personalizados	Rivera Bedoya, L. A., & Sanchez Zapata, C. A.
Mostraron que 3x por semana produjo mayores ganancias en bíceps que 1x en hombres entrenados	Schoenfeld, B. J., Peterson, M. D., Ogborn, D., Contreras, B., & Sonmez, G. T.
Essentials of Strength Training and Conditioning	Haff, G. G., & Triplett, N. T.
Fundamentals of Resistance Training: Progression and Exercise Prescription	Kraemer, W. J., & Ratamess, N. A.
Deep learning convolutional neural networks for the automatic quantification of muscle fat infiltration following whiplash injury	Weber, K. A., Smith, A. C., Wasielewski, M., Eghtesad, K., Upadhyayula, P. A., Wintermark, M., Hastie, T. J., Parrish, T. B., Mackey, S., & Elliott, J. M.
Digital Media Teaching and Effectiveness Evaluation Integrating Big Data and Artificial Intelligence	Zhang, R. Y.
Mejora de la salud y el rendimiento de deportistas a través de la aplicación de avances en técnicas de Inteligencia Artificial	Sánchez Palop, L. I., Magraner Llavador, L., Alcántara Alcover, E., & Laparra Hernández, J.
MicroRNA-1 and microRNA-133a expression are decreased during skeletal muscle hypertrophy	McCarthy, J. J., & Esser, K. A.
Influence of resistance training load on measures of skeletal muscle hypertrophy and improvements in maximal strength and neuromuscular task performance: A systematic review	Refalo, M. C., Hamilton, D. L., Paval, D. R., Gallagher, I. J., Feros, S. A., & Fyfe, J. J.
Simultaneous augmentation of muscle and bone by locomimeticism through calcium-PGC-1 α signaling	Ono, T., Denda, R., Tsukahara, Y., Nakamura, T., Okamoto, K., Takayanagi, H., & Nakashima, T.
High-throughput image analysis with deep learning captures heterogeneity and spatial relationships after kidney injury	McElliott, M. C., Al-Suraimi, A., Telang, A. C., Ference-Salo, J. T., Chowdhury, M., Soofi, A., Dressler, G. R., & Beamish, J. A.
¿Cómo mejorar la recuperación después del deporte con comida?	Rezola, I.
BIG DATA E INTELIGENCIA ARTIFICIAL APLICADO AL RUBRO DEPORTIVO	Brunengo, A.
Inteligencia Deportiva: Tecnología Aplicada al Deporte	Albarrán Jardón, E. R.
Predicción de la Hipertrofia Muscular en la Distrofia Muscular de Duchenne Utilizando Aprendizaje Automático y Resonancia Magnética	Barber, D. C., & Phillips, S. M

Nota. Análisis por autores y artículos

Las tablas anteriores revelan una amplia gama de investigaciones y recursos relevantes que abordan varios aspectos relacionados con el ejercicio, la nutrición deportiva y la aplicación de tecnología en el ámbito deportivo. En concreto, se destacan los hallazgos presentados en **dos tablas**, las cuales ofrecen una síntesis detallada de la literatura revisada y los datos recopilados.

En el ámbito de la visualización de datos genéticos, el trabajo de Moon, Posada-Quintero y Chon (2023) utiliza redes neuronales basadas en texto para analizar la literatura científica.

El estudio de Díaz-Curiel, Rodríguez-Romo y Martínez-Amat (2020) profundiza en el crecimiento muscular y sienta bases importantes para investigaciones futuras.

Respecto a la nutrición deportiva, Norton y Layman (2006) investigan el papel de la leucina en la síntesis de proteínas musculares post-ejercicio, mientras que Tipton y Wolfe (2004) resaltan la importancia de las proteínas y aminoácidos para atletas.

Phillips y Van Loon (2011) proporcionan información valiosa sobre la dieta de proteínas respaldada por instituciones como la Academia de Nutrición y Dietética.

En el ámbito del entrenamiento de fuerza, la investigación de Schoenfeld et al. (2015) compara diferentes frecuencias de entrenamiento, mientras que libros como "Essentials of Strength Training and Conditioning" (Haff & Triplett, 2016) y "Fundamentals of Resistance Training" (Kraemer & Ratamess, 2004) ofrecen bases teóricas sólidas.

La aplicación de tecnología en el deporte se ve reflejada en estudios como el de Weber et al. (2019), que emplea redes neuronales para analizar la infiltración de grasa muscular post-lesión.

Además, hay investigaciones sobre la integración de big data y inteligencia artificial en la enseñanza de medios digitales (Zhang, 2022) y en la mejora del rendimiento deportivo mediante técnicas de inteligencia artificial (Sánchez Palop et al., 2020).

Esta variedad de recursos ofrece una visión profunda y completa de los temas relacionados con el ejercicio, la nutrición deportiva y la tecnología aplicada al deporte, enriqueciendo la comprensión y la práctica en estos campos.

Postura de los Autores y Análisis Crítico: Una Evaluación Detallada

Se examinará la postura de los autores respecto a estos factores para comprender su percepción y su influencia en el campo de la hipertrofia muscular.

Análisis Comparativo de Autores y Perspectiva Personal

Estudio 1: visualización de datos genéticos utilizando redes neuronales basadas en texto de literatura.

En nuestra investigación sobre la hipertrofia muscular, he explorado críticamente las opiniones y hallazgos de diversos autores en el campo de la salud y el rendimiento físico, especialmente aquellos que han aplicado técnicas de Machine Learning en sus estudios. Un aspecto clave que destaco es la diversidad de enfoques y perspectivas que estos autores han aportado al tema. Comenzando con Moon, Posada-Quintero y Chon (2023), se utilizó una red neuronal para visualizar datos genéticos relacionados con la salud cardiovascular. Sus hallazgos sugieren la presencia de patrones genéticos significativos que podrían estar relacionados con el riesgo de enfermedades cardiovasculares e igualmente se destacan algunos puntos: se centra en la necesidad de identificar y comprender los factores de riesgo asociados con las enfermedades cardiovasculares (CVD) utilizando un enfoque basado en la literatura. Destacan la importancia de utilizar modelos

de incrustación de palabras para extraer información relevante de grandes conjuntos de datos de texto biomédico, como PubMed y Google Scholar.

Su investigación sugiere que este enfoque podría ayudar a identificar factores de riesgo nuevos y significativos, así como a comprender mejor los mecanismos subyacentes de las enfermedades cardiovasculares.

La Integración de datos de la literatura biomédica y datos clínicos: Moon y Chon reconocen la importancia de combinar la información textual de la literatura biomédica con datos clínicos y epidemiológicos para obtener una comprensión más completa de los factores de riesgo asociados con las enfermedades cardiovasculares (CVD). Su enfoque se basa en la premisa de que la información contenida en la literatura médica puede complementar y enriquecer los datos clínicos tradicionales, lo que puede conducir a una identificación más precisa de los factores de riesgo y síntomas asociados con las enfermedades cardiovasculares.

Uso de modelos de incrustación de literatura: Moon y Chon proponen utilizar modelos de incrustación de literatura, específicamente una extensión de la estructura Skip-gram de Word2Vec, para representar de manera semántica los términos y conceptos presentes en la literatura biomédica. Estos modelos permiten asignar vectores numéricos a términos médicos y genéticos, lo que facilita la comparación y el análisis de la similitud semántica entre los términos relacionados con las enfermedades cardiovasculares.

Validación del modelo: Para evaluar la calidad y eficacia de su enfoque, Moon y Chon proponen realizar evaluaciones intrínsecas y extrínsecas. Las evaluaciones intrínsecas se centran en medir la similitud semántica entre los vectores de incrustación de literatura, mientras que las evaluaciones extrínsecas implican utilizar datos de cohortes y

métricas de predicción de enfermedades cardiovasculares para determinar si el modelo de incrustación de literatura puede mejorar la precisión de la predicción de enfermedades cardiovasculares.

La **postura** de Moon y Chon implica un enfoque interdisciplinario que integra el análisis de la literatura biomédica con técnicas de aprendizaje automático para mejorar la comprensión y la predicción de enfermedades cardiovasculares. Su trabajo destaca la importancia de utilizar enfoques innovadores para abordar desafíos complejos en el campo de la salud cardiovascular. También toda la evidencia presentada por Moon y sus colegas sugiere la existencia de patrones genéticos que podrían estar asociados con la respuesta al entrenamiento y, por ende, con el potencial de crecimiento muscular. Esta perspectiva refuerza mi postura en favor de considerar la variabilidad genética como un factor crucial al diseñar estrategias para la hipertrofia muscular.

Análisis crítico de los estudios: Reflexiones personales y perspectiva académica

A pesar de los avances significativos en la integración de datos de la literatura biomédica en modelos de predicción de enfermedades cardiovasculares (CVD), considero que existen ciertas limitaciones y preocupaciones que deben abordarse antes de adoptar ampliamente esta técnica en la práctica clínica. A continuación, presento algunos aspectos que considero críticos:

Complejidad y generalización del modelo: Los modelos de incrustación de literatura pueden capturar relaciones complejas entre términos médicos y genéticos, pero la generalización de estos modelos a diferentes contextos clínicos puede ser problemática. La variabilidad en la calidad y el volumen de la literatura biomédica puede afectar la capacidad

del modelo para identificar y predecir factores de riesgo específicos en diferentes poblaciones y entornos clínicos.

Interpretación y transparencia: A medida que los modelos de incrustación de literatura se vuelven más complejos, la interpretación de los resultados y la transparencia del proceso de modelado pueden verse comprometidas. Los médicos y los investigadores pueden enfrentar dificultades para comprender cómo se generan las predicciones del modelo y cómo se utilizan en la práctica clínica, lo que plantea preocupaciones éticas y de responsabilidad.

Sesgos y errores: Existe el riesgo de sesgos y errores inherentes en los datos de la literatura biomédica utilizados para entrenar los modelos de incrustación. La inclusión de información incorrecta o sesgada en el modelo puede conducir a predicciones inexactas y decisiones clínicas erróneas. Además, la presencia de sesgos sociales y culturales en la literatura biomédica puede afectar la equidad y la justicia en el tratamiento de las enfermedades cardiovasculares.

Privacidad y seguridad de los datos: La integración de datos clínicos sensibles con datos de la literatura biomédica plantea preocupaciones significativas sobre la privacidad y la seguridad de los datos. Es fundamental garantizar que los datos de los pacientes estén protegidos contra el acceso no autorizado y el mal uso, especialmente en el contexto de la creciente preocupación por la protección de la privacidad de la información médica.

Aunque los modelos de incrustación de literatura ofrecen oportunidades interesantes para mejorar la comprensión y la gestión de las enfermedades cardiovasculares, e indirectamente pueden tener implicaciones en condiciones como la hipertrofia muscular, es esencial abordar críticamente las limitaciones y preocupaciones asociadas con su

implementación en la práctica clínica. Se requiere una evaluación cuidadosa de los riesgos y beneficios potenciales, así como un enfoque colaborativo entre médicos, investigadores y expertos en ética para garantizar que estos modelos se utilicen de manera ética y efectiva en el cuidado de los pacientes. La inclusión de variables relacionadas con la hipertrofia muscular podría añadir una capa adicional de complejidad y consideración a la implementación de estos modelos en la práctica clínica, lo que destaca aún más la importancia de abordar críticamente todas las implicaciones éticas y prácticas. A continuación, se presenta la tabla 3 con los aspectos destacados de la investigación mencionada:

Tabla 3:

Estudio 1

Aspectos Destacados	Variables Destacadas	Impacto Potencial	Relevancia para la Hipertrofia Muscular
Utilización de redes neuronales para visualizar datos genéticos relacionados con la salud cardiovascular.	Genética	- Identificación de factores de riesgo cardiovascular y su relación con la hipertrofia muscular	- Potencial para descubrir variantes genéticas asociadas con la respuesta al entrenamiento y la hipertrofia muscular.
Enfoque en identificar y comprender factores de riesgo de enfermedades cardiovasculares (CVD).	Redes Neuronales	- Integración de la genética en la comprensión de la respuesta al entrenamiento	- Posible influencia de factores de riesgo cardiovascular en la capacidad de hipertrofia muscular y adaptaciones al ejercicio.
Integración de datos de literatura biomédica y clínica para una comprensión más completa de los factores de riesgo de CVD.	Factor Cardiovascular	- Mejora en la predicción de riesgo cardiovascular y rendimiento deportivo	- Entender cómo la salud cardiovascular puede afectar la respuesta al entrenamiento y la capacidad de hipertrofia muscular.
Propuesta de modelos de incrustación de literatura para representar términos y conceptos biomédicos de manera semántica.	Representación Semántica de Términos Biomédicos	- Evaluación intrínseca y extrínseca del modelo para validar su calidad y eficacia	- Potencial para identificar biomarcadores relacionados con la hipertrofia muscular y su respuesta al ejercicio.

Nota. Aspectos destacados de las redes neuronales

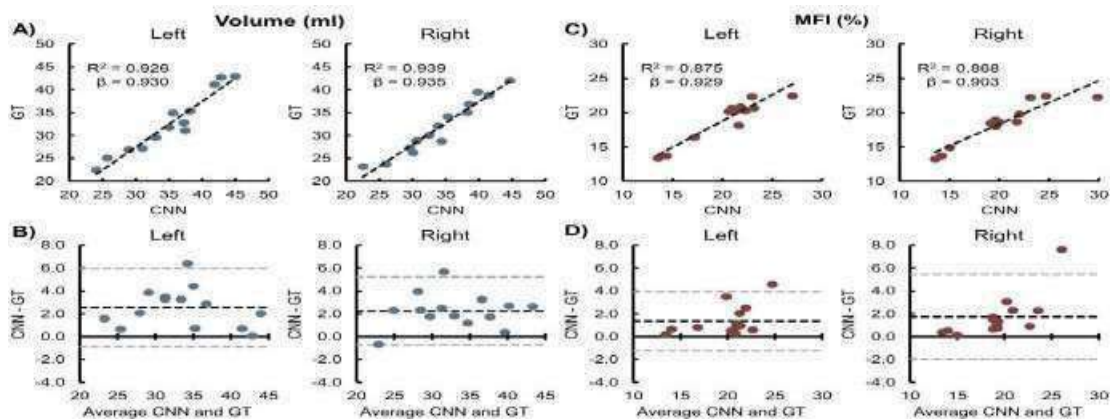
Estudio 2: Segmentación muscular en afecciones cervicales: Utilización de redes neuronales convolucionales para la cuantificación automática de la infiltración de grasa

Kenneth A. Weber y su equipo llevan una investigación de redes neuronales convolucionales de aprendizaje profundo para la cuantificación automática de la infiltración de grasa muscular.

La segmentación de imágenes musculares mediante el uso de redes neuronales convolucionales (CNN) ofrece una valiosa herramienta para la cuantificación automatizada de la infiltración de grasa muscular (MFI) en afecciones de la columna cervical, como el latigazo cervical. Este enfoque, como se demostró en el estudio, no solo mejora la eficiencia en la medición de propiedades musculares, sino que también proporciona una objetividad que puede ser fundamental en la práctica clínica. (Weber et al., 2019).

Uno de los aspectos destacados del estudio es la alta precisión y confiabilidad de las pruebas de CNN en comparación con la segmentación manual. Esta precisión es importante para garantizar resultados confiables y reproducibles, lo que a su vez respalda la utilidad clínica de esta técnica. La capacidad de la CNN para segmentar cada corte axial de las imágenes en un tiempo relativamente corto subraya su potencial para facilitar el seguimiento cuantitativo de las propiedades musculares en entornos clínicos. (Weber et al., 2019).

Figura 2

Correlación Volumen de Carga

Fuente. Adaptado de Deep Learning Convolutional Neural, por Pub Med, 2019, KennethA Weber

Además, el estudio exploró las relaciones entre el volumen muscular y la MFI obtenidos mediante CNN y medidas clínicas de dolor y discapacidad relacionada con el cuello. Los resultados revelaron correlaciones significativas entre el volumen muscular y el dolor, así como entre el volumen muscular y la discapacidad, lo que sugiere un posible papel de la musculatura cervical en la experiencia de estos síntomas. Por otro lado, la MFI tendió a correlacionarse positivamente con la discapacidad, lo que podría indicar una asociación entre la infiltración de grasa muscular y la gravedad de la discapacidad relacionada con el cuello. (Weber et al., 2019).

Sin embargo, es importante reconocer que este estudio tiene limitaciones y áreas que requieren una mayor investigación. Por ejemplo, aunque se encontraron correlaciones entre las medidas musculares y las medidas clínicas, no se establece una relación causal definitiva. Además, el tamaño de la muestra podría limitar la generalización de los resultados, y se necesitan estudios longitudinales con cohortes más grandes para confirmar

y ampliar estos hallazgos.

La aplicación de CNN para la segmentación muscular en afecciones de la columna cervical representa un avance significativo en la cuantificación objetiva de las propiedades musculares. El entrenamiento del modelo V-Net se completó en 25,000 iteraciones, logrando segmentar cada corte axial desde las vértebras C3 a C7 en menos de 60 s por imagen. La CNN entrenada demostró una alta precisión y confiabilidad en el conjunto de datos de prueba, con un volumen muscular promedio de $34,9 \pm 6,2$ ml y $34,1 \pm 6,1$ ml para los músculos izquierdo y derecho, respectivamente, y un MFI promedio de $20,7 \pm 3,5$ % y $20,2 \pm 4,3$ %, respectivamente (Weber et al., 2019).

Estos resultados subrayan el potencial de las técnicas de aprendizaje profundo para mejorar la práctica clínica al ofrecer una herramienta precisa y eficiente para la cuantificación automatizada de la infiltración de grasa muscular en condiciones como el latigazo cervical. Sin embargo, para su implementación generalizada en entornos clínicos, se requieren más investigaciones que validen y amplíen estos hallazgos (Weber et al., 2019).

La postura definitiva de Kenneth A y su equipo de acuerdo a su investigación es que respaldan firmemente el uso de redes neuronales convolucionales (CNN) para la segmentación muscular en afecciones de la columna cervical. Consideran que esta técnica ofrece una herramienta valiosa para la cuantificación automatizada de la infiltración de grasa muscular (MFI), mejorando la eficiencia y objetividad en la medición de propiedades musculares. (Weber et al., 2019).

Además, los autores respaldan los resultados obtenidos en su estudio, que revelaron correlaciones significativas entre el volumen muscular y el dolor, así como entre el

volumen muscular y la discapacidad relacionada con el cuello. Consideran que estos hallazgos subrayan la importancia de la musculatura cervical en la experiencia de estos síntomas y respaldan la utilidad clínica de las medidas musculares obtenidas mediante CNN. (Weber et al., 2019).

Sin embargo, los autores reconocen la necesidad de investigaciones adicionales para validar y ampliar estos hallazgos. Destacan la importancia de estudios longitudinales con cohortes más grandes para establecer relaciones causales y generalizar los resultados antes de considerar la implementación generalizada de estas técnicas en la práctica clínica.

Análisis crítico de los estudios: Reflexiones personales y perspectiva académica

A pesar de los avances tecnológicos en el campo de la segmentación muscular utilizando redes neuronales convolucionales (CNN), mi postura es un poco escéptica sobre la fiabilidad y generalización de estos modelos en la práctica clínica.

Limitaciones de la generalización: Existe preocupación sobre la capacidad de los modelos de machine learning, como las CNN, para generalizar los resultados a diferentes poblaciones y contextos clínicos. Los datos utilizados para entrenar estos modelos pueden no representar adecuadamente la diversidad genética y demográfica de los pacientes, lo que podría limitar su aplicabilidad en entornos clínicos diversos.

Interpretación de resultados: A medida que los modelos de machine learning se vuelven más complejos, la interpretación de los resultados puede volverse más difícil. Los médicos y los investigadores podrían enfrentar desafíos para comprender cómo se generan las predicciones del modelo y cómo aplicarlas de manera efectiva en la práctica clínica. Esto podría generar desconfianza en la precisión y utilidad de los resultados obtenidos

mediante modelos de machine learning.

Necesidad de validación clínica: Aunque los modelos de machine learning pueden ofrecer resultados prometedores en entornos de investigación, se requiere una validación clínica rigurosa antes de su implementación generalizada en la práctica clínica. Esto incluye estudios longitudinales con cohortes grandes y diversificadas para evaluar la precisión y la utilidad clínica de las medidas musculares obtenidas mediante modelos de machine learning.

Pienso que los modelos de machine learning, como las CNN, ofrecen nuevas oportunidades para la identificación de factores clave de la hipertrofia muscular, es importante abordar críticamente sus limitaciones y desafíos. Se necesita más investigación y validación clínica antes de que estos modelos puedan considerarse como herramientas confiables y efectivas en la práctica clínica para la identificación de factores clave de la hipertrofia muscular.

Tabla 4

Estudio 2

Aspectos Destacados	VARIABLES Destacadas	Impacto Potencial	Relevancia para la Hipertrofia Muscular
Utilización de redes neuronales convolucionales para la cuantificación automática de la infiltración de grasa muscular.	Segmentación Muscular	- Mejora en la eficiencia y objetividad en la medición de propiedades musculares	- Posible relación entre la infiltración de grasa muscular y la hipertrofia en la columna cervical.
Alta precisión y confiabilidad de las pruebas de CNN en comparación con la segmentación manual.	Precisión de las Pruebas CNN	- Garantía de resultados confiables y reproducibles	- Facilitación del seguimiento cuantitativo de las propiedades musculares para evaluar la hipertrofia.
Correlaciones entre volumen muscular y medidas clínicas de dolor y discapacidad relacionada con el cuello.	Volumen Muscular	- Identificación de posibles asociaciones entre el dolor cervical y la hipertrofia muscular	- Exploración de cómo la hipertrofia cervical puede influir en la experiencia del dolor y la discapacidad.

Nota. Aspectos destacados redes neuronales convolucionales

Estudio 3: El metaanálisis sobre la influencia de la carga de entrenamiento de fuerza en la hipertrofia y la fuerza máxima

En el artículo de Refalo y Hamilton en 2021 “*El metaanálisis sobre la influencia de la carga de entrenamiento de fuerza en la hipertrofia y la fuerza máxima*” tuvo como objetivo investigar los efectos de la carga del entrenamiento de fuerza en el desarrollo de la hipertrofia muscular, la fuerza máxima y el rendimiento neuromuscular. Para ello, se llevó a cabo un metaanálisis que incluyó 45 estudios con un total de 4713 participantes.

Los estudios seleccionados compararon el entrenamiento de fuerza con carga más alta ($> 60\%$ 1RM o <15 -RM) con entrenamiento de fuerza con carga más baja ($\leq 60\%$ 1RM o ≥ 15 - RM). Se evaluaron medidas de hipertrofia muscular, fuerza máxima (1RM) y fuerza isométrica, así como rendimiento neuromuscular mediante pruebas como el salto con contra movimiento (CMJ). (Refalo et al. 2021)

Los principales hallazgos del metaanálisis fueron los siguientes:

Hipertrofia muscular: Se encontró que tanto el entrenamiento de fuerza con cargas más altas como con cargas más bajas indujeron una hipertrofia muscular similar a nivel global (en todo el cuerpo), así como en la masa muscular en su conjunto y en la fibra muscular.

Fuerza máxima: El entrenamiento de fuerza con carga superior resultó en una mayor mejora del 1RM en comparación con el entrenamiento con cargas más bajas. Esta diferencia fue significativa y se observó tanto en participantes más jóvenes como en mayores.

Fuerza isométrica: Similar al 1RM, el entrenamiento de fuerza con carga superior también condujo a una mayor ganancia en la fuerza isométrica en comparación con el entrenamiento con cargas más bajas.

Rendimiento neuromuscular: No se encontraron diferencias claras en el rendimiento neuromuscular entre el entrenamiento con cargas más altas y más bajas. La influencia de la carga de entrenamiento en el rendimiento neuromuscular, como el CMJ, no fue concluyente según los resultados del metaanálisis.

Los resultados de este metaanálisis sugieren que tanto el entrenamiento de fuerza con cargas más altas como con cargas más bajas pueden inducir una hipertrofia muscular similar, pero el entrenamiento con cargas más altas conduce a una mayor mejora en la fuerza máxima y la fuerza isométrica. Sin embargo, la influencia de la carga de entrenamiento en el rendimiento neuromuscular no está clara según los resultados presentados. (Refalo et al. 2021)

Análisis crítico de los estudios: Reflexiones personales y perspectiva académica

Aunque el metaanálisis de Refalo y colaboradores (2021) proporciona información importante sobre los efectos de la carga del entrenamiento de fuerza en la hipertrofia muscular y la fuerza máxima, considero que pueden existir algunas limitaciones y posibles interpretaciones alternativas de los resultados.

Diferencias en la especificidad del entrenamiento: Aunque el estudio comparó el efecto de cargas más altas y bajas en la hipertrofia muscular y la fuerza máxima, es importante recordar que la efectividad del entrenamiento puede depender de la especificidad del programa de entrenamiento en relación con los objetivos individuales.

Es posible que ciertos individuos se beneficien más de un enfoque de entrenamiento con cargas más altas, mientras que otros puedan experimentar mejores resultados con cargas más bajas, dependiendo de factores como la genética, el nivel de condición física inicial y los objetivos personales.

Consideración de la fatiga y el volumen de entrenamiento: El metaanálisis no profundiza en la relación entre la carga del entrenamiento y la fatiga acumulada o el volumen total de entrenamiento. Es posible que el efecto de la carga del entrenamiento en la hipertrofia y la fuerza esté influenciado por otros factores, como la distribución del volumen de entrenamiento y la capacidad de recuperación individual. Una carga de entrenamiento más alta puede resultar en una mayor fatiga y requerir una mayor recuperación, lo que podría afectar la capacidad de mantenimiento del volumen de entrenamiento a lo largo del tiempo.

Adaptaciones neuromusculares: El metaanálisis no aborda exhaustivamente las adaptaciones neuromusculares que pueden influir en la fuerza máxima y el rendimiento neuromuscular. Además de la hipertrofia muscular, la fuerza máxima también puede estar influenciada por factores como la coordinación neuromuscular, la activación de unidades motoras y la eficiencia del sistema nervioso central. Estos aspectos podrían no reflejarse completamente en la medida del 1RM o en pruebas de fuerza isométrica.

El **metaanálisis** proporciona una visión útil sobre los efectos de la carga del entrenamiento de fuerza, es importante considerar estas limitaciones y explorar más a fondo las respuestas individuales al entrenamiento, así como los factores adicionales que pueden influir en los resultados observados. Una perspectiva más holística podría ayudar a diseñar programas de entrenamiento más efectivos y personalizados para alcanzar los objetivos de

cada individuo.

Tabla 5

Estudio 3

Aspectos Destacados	VARIABLES Destacadas	Impacto Potencial	Relevancia para la Hipertrofia Muscular
Comparación entre entrenamiento de fuerza con carga alta y baja en la hipertrofia y la fuerza máxima.	Carga del Entrenamiento de Fuerza	- Efectos en la hipertrofia muscular y la fuerza máxima	- Identificación de la relación entre la carga del entrenamiento y la hipertrofia muscular.
Hallazgos sobre la mejora del 1RM y la fuerza isométrica con carga de entrenamiento superior.	Mejora del 1RM y Fuerza Isométrica	- Impacto positivo de la carga superior en la fuerza máxima y isométrica	- Importancia de la carga del entrenamiento para la mejora de la fuerza y la hipertrofia.
Falta de diferencias claras en el rendimiento neuromuscular entre cargas altas y bajas.	Rendimiento Neuromuscular	- Incertidumbre sobre la influencia de la carga del entrenamiento	- Necesidad de más investigación para comprender su impacto en la hipertrofia muscular.

Nota. Aspectos destacados entrenamiento de fuerza

Estudio 4: Efectos de diferentes duraciones concéntricas y excéntricas durante el entrenamiento de resistencia en la hipertrofia muscular

En el estudio Carlson (2018), "*Efectos de diferentes duraciones concéntricas y excéntricas durante el entrenamiento de resistencia en la hipertrofia muscular*" y el estudio de Chaves et al. (2020) se titula: "Efectos del ejercicio de control excéntrico de diferente duración en el press de banca sobre la hipertrofia muscular y la fuerza".

El trabajo de Chaves et al. (2020) reveló diferencias notables entre el grupo que realizaba repeticiones en 4 segundos y aquellos que controlaban el tempo. Estas diferencias fueron más prominentes dado que los participantes eran desentrenados, lo que facilitó adaptaciones ante varios estímulos de entrenamiento. Sin embargo, al considerar los tres estudios restantes, en los cuales todos los sujetos estaban entrenados, se observó una mejora similar y sin diferencias significativas entre los diferentes tempos.

El estudio de Carlson et al. (2018) merece una mención especial debido a su enfoque en repeticiones extremadamente lentas (20 y 90 segundos), lo cual produjo resultados inesperados. Es posible que esta novedad en el estímulo haya desencadenado una respuesta positiva del cuerpo, incluso en el grupo de 6 segundos, que mejoró significativamente, pero de manera más relativa. Esto sugiere que la ejecución de repeticiones a un ritmo poco habitual puede generar adaptaciones notables, especialmente cuando los participantes no están acostumbrados a ese tempo.

De manera general, los estudios sugieren que el tempo óptimo para la ganancia de masa muscular oscila entre 2 y 6 segundos por repetición. Sin embargo, exceder este rango, como se observó en las repeticiones extremadamente lentas, puede no ser beneficioso y podría resultar en fatiga excesiva sin inducir una mayor hipertrofia en comparación con

tempos más cortos.

El estudio abordó la influencia del tempo de levantamiento en la hipertrofia muscular mediante la revisión de varios programas de entrenamiento. Se seleccionaron estudios que comparaban diferentes tempos de levantamiento y evaluaban su efecto en la ganancia de masa muscular. Los participantes incluidos en los estudios fueron tanto desentrenados como entrenados, lo que permitió examinar cómo estas poblaciones responden a diferentes estímulos de entrenamiento.

Los resultados mostraron que, mientras que los sujetos desentrenados parecían beneficiarse de una variedad de tempos de levantamiento, los sujetos entrenados exhibían mejoras similares independientemente del tempo utilizado. Sin embargo, las repeticiones extremadamente lentas, como las realizadas en el estudio de Carlson et al. (2018), destacaron como un estímulo novedoso que generó adaptaciones notables incluso en sujetos entrenados.

En conclusión, el estudio sugiere que un tempo óptimo para la hipertrofia muscular se sitúa entre 2 y 6 segundos por repetición, con tempos extremadamente lentos mostrando resultados prometedores pero inusuales. Sin embargo, se necesitan más investigaciones para validar estas conclusiones y comprender mejor cómo el tempo de levantamiento puede influir en las adaptaciones musculares.

Análisis crítico de los estudios: Reflexiones personales y perspectiva académica

Los estudios revisados sugieren que un rango de tempo de 2 a 6 segundos por repetición puede ser óptimo para la hipertrofia muscular, Considero que existen argumentos que sugieren una posición contraria.

Primero, es importante tener presente que la adaptación muscular puede variar significativamente entre individuos debido a factores genéticos, nivel de entrenamiento previo, edad y otras variables. Por lo tanto, establecer un rango de tiempo como óptimo para todos los sujetos puede ser demasiado simplista y no tener en cuenta estas diferencias individuales.

Además, el enfoque en el tiempo de levantamiento puede desviar la atención de otras variables igualmente importantes en el entrenamiento de fuerza, como el volumen total, la intensidad, la frecuencia y la progresión adecuada. Centrarse demasiado en el tiempo puede llevar a descuidar estos aspectos cruciales del diseño del programa de entrenamiento.

Otro punto por considerar es que la respuesta hipertrófica puede ser influenciada por la variabilidad en la ejecución del ejercicio, más allá del tiempo de levantamiento.

Factores

como la técnica de ejecución, la amplitud del movimiento, la velocidad de ejecución y el tiempo bajo tensión total pueden variar entre individuos y afectar la respuesta muscular.

Además, los estudios de Carlson y Chaves pueden tener limitaciones en cuanto al tamaño de la muestra y la duración del seguimiento. Un tamaño de muestra pequeño puede limitar la generalización de los resultados, mientras que un seguimiento a corto plazo puede no capturar completamente las adaptaciones a largo plazo

Los autores reconocen que los estudios incluidos en la revisión presentan ciertas limitaciones que deben ser consideradas al interpretar los hallazgos. Por ejemplo, algunos de los participantes eran desentrenados, lo que podría haber influido en las adaptaciones observadas frente a diferentes estímulos de entrenamiento. Esta distinción es crucial, ya que

la respuesta al entrenamiento puede variar significativamente entre individuos desentrenados y entrenados.

Además, se destaca la importancia de analizar el contexto específico de cada estudio, incluyendo el tipo de ejercicio, el nivel de intensidad y el volumen de entrenamiento utilizado. Estos factores pueden influir en la respuesta al tiempo de levantamiento y en las adaptaciones musculares resultantes. Por lo tanto, es fundamental considerar múltiples variables al diseñar programas de entrenamiento de fuerza.

Carlson y Chaves también discuten la relación entre el tiempo de levantamiento y la fatiga muscular, tanto periférica como central. Se plantea que entrenar con tempos muy lentos puede provocar una fatiga excesiva, lo que podría afectar negativamente el rendimiento y las adaptaciones musculares. En contraste, mantener un tempo constante y controlado podría permitir una adecuada activación de las unidades motoras y una mejor calidad de ejecución del ejercicio.

En cuanto a las conclusiones, los autores sugieren que un tempo óptimo para la hipertrofia muscular podría estar en el rango de 2 a 6 segundos por repetición. Sin embargo, reconocen que esta conclusión se basa en la evidencia disponible hasta el momento y que se necesita más investigación para validarla. Además, enfatizan la importancia de considerar otras variables del entrenamiento, como la intensidad y el volumen, para maximizar las adaptaciones musculares.

La postura de los autores es proporcionar una visión crítica y equilibrada sobre el papel del tiempo de levantamiento en la hipertrofia muscular, reconociendo tanto sus posibles beneficios como sus limitaciones. Se destaca la necesidad de considerar múltiples factores al diseñar programas de entrenamiento de fuerza y se sugiere continuar

investigando para mejorar nuestra comprensión de esta variable.

Tabla 6

Estudio 4

Aspectos Destacados	Variables Destacadas	Impacto Potencial	Relevancia para la Hipertrofia Muscular
Comparación de diferentes duraciones concéntricas y excéntricas durante el entrenamiento de resistencia en la hipertrofia muscular	Duraciones Concéntricas y Excéntricas	- Efectos en la hipertrofia muscular	- Identificación de la relación entre la duración de las repeticiones y la hipertrofia muscular
Resultados de estudios sobre el efecto del tempo de levantamiento en la ganancia muscular	Tempo de Levantamiento	- Impacto en la ganancia de masa muscular	- Evaluación de la influencia del tempo en la respuesta hipertrófica y la fatiga muscular
Consideraciones sobre el rango óptimo de tempo para la hipertrofia muscular	Rango de Tempo	- Identificación del rango óptimo para la hipertrofia	- Importancia de establecer un tempo adecuado para maximizar los resultados en la hipertrofia muscular

Nota. Vol. Cargas

Estudio 5: Diseño de un algoritmo de redes neuronales artificiales para la elaboración de planes de acondicionamiento físico personalizados.

El estudio sobre la prescripción de ejercicios físicos personalizados utilizando algoritmos de redes neuronales fue llevado a cabo por un equipo de investigadores liderado por *Rivera Bedoya, L. A., & Sanchez Zapata, C. A. (2020)*. Diseño de un algoritmo de Redes neuronales artificiales para la elaboración de planes de acondicionamiento físico *personalizados*. La investigación fue motivada por la necesidad de diseñar rutinas de ejercicio adaptadas a las necesidades individuales de cada persona, con el objetivo de promover la salud y el bienestar.

La metodología del estudio de Bedoya, L. A., y Sanchez Zapata, C. A. (2020) se dividió en varias etapas:

Recopilación de datos:

Se recopilaron datos de una población objetivo utilizando un formato de inscripción estructurado diseñado específicamente para este estudio. Este formato incluyó campos detallados para características individuales como edad, género, altura, peso, nivel de actividad física previa, objetivos de entrenamiento y posibles limitaciones físicas o médicas. También se recabó información exhaustiva sobre el historial médico, incluyendo condiciones de salud preexistentes, lesiones previas y medicamentos actuales. Además, se exploraron las preferencias de ejercicio de los participantes, como los tipos de actividades físicas preferidas, la intensidad deseada del entrenamiento y metas específicas de acondicionamiento físico.

Antes de participar, se obtuvo el consentimiento informado de los participantes, explicándoles claramente los objetivos del estudio, los procedimientos involucrados, así

como los posibles riesgos y beneficios. Se implementaron estrictos protocolos de privacidad y confidencialidad para proteger la información personal, asegurando que los datos fueran utilizados únicamente para fines de investigación y almacenados de manera confidencial en una base de datos digitalizada. A continuación, se detallan los parámetros utilizados en la investigación Bedoya, L. A., y Sanchez Zapata, C. A. (2020).

Figura 3

Parámetros Rutinas Entrenamiento

PARÁMETRO	DESCRIPCIÓN	VALORES Y UNIDADES
EJERCICIO	Los ejercicios por lo general son acciones físicas y movimientos repetitivos. Es la base del plan de acondicionamiento físico pues este está compuesto por un conjunto de ejercicios. El ejercicio tiene un nombre específico y según sea el caso, se puede ejecutar solo con el movimiento del cuerpo o una parte de este, con diferentes elementos como mancuernas o bandas elásticas; o alguna máquina de ejercicios particular. Igualmente se debe especificar la combinación de series y repeticiones, según la metodología de entrenamiento. Algunos están dados en término de tiempo o distancia según la naturaleza del ejercicio y la acción que deba ejecutarse.	Este parámetro está dado con nombres de ejercicios específicos que determinan la acción a ejecutar.
REPETICIONES	Corresponde a la cantidad de veces que se debe ejecutar un ejercicio específico.	Este parámetro está dado en valores numéricos enteros sin unidades. Por lo general, toma valores entre 10 y 100.
TIEMPO	Algunos ejercicios están dados en unidades de tiempo, así como algunas metodologías de entrenamiento para conjuntos de ejercicios determinados por el instructor.	Este parámetro está dado en segundos con valores numéricos enteros. Por lo general, toma valores entre 10 y 1200 segundos.
DISTANCIA	Otros ejercicios y metodologías de entrenamiento se realizan de acuerdo con una distancia que debe recorrer el individuo al momento de ejecutar un determinado ejercicio.	Este parámetro está dado en metros con valores numéricos enteros. Por lo general, toma valores entre 1000 y 5000 metros.
SERIES	Corresponde a la cantidad de circuitos que debe realizar el individuo, bien sea de un solo ejercicio o de un conjunto de ejercicios. Por ejemplo, si el instructor dispone que el ejercicio tenga 10 repeticiones con 5 series, esto quiere decir que se debe ejecutar el ejercicio 10 veces y con ello completará una serie, debe descansar un periodo de tiempo corto y hacer nuevamente 10 repeticiones, así completará una segunda serie. Debe seguir este procedimiento hasta completar las 5 series.	Este parámetro está dado en valores numéricos enteros sin unidades. Por lo general, toma valores entre 3 y 10.

Fuente. Adaptado de Rutinas de Entrenamiento, por Biblioteca digital Universidad del Valle 2020, Rivera Bedoya, Luis Alejandro Sanchez Zapata, Carlos Alberto

Figura 4 submodelo de red Neuronal

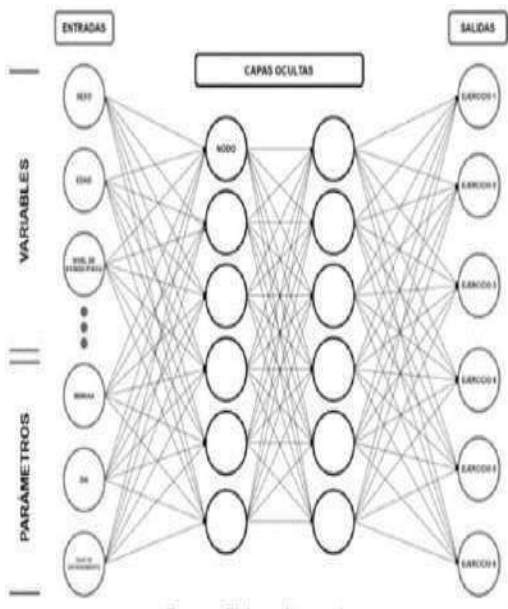


Figura 5 Rutina ejercicios diarios

FASE DE LA RUTINA	EJERCICIO	SERIES	REP.	TIEMPO	DISTANCIA
CALENTAMIENTO GENERAL	TITIRERES	5	20		
	PLANCHA	5		60	
	ESCALADORES POR PIERNA	5	50		
ENTRENAMIENTO CENTRAL	SENTADILLA LIBRE	10	10		
	SENTADILLA LIBRE CON SALTO	10	10		
	FLEXIONES DE BRAZO	10	10		
	ESCALADORES POR PIERNA	5	20		
	SKIPPING	5	20		
VUELTA A LA CALMA	ESTOCADA LATERAL POR LADO	3	20		
	INCLINADO HACIA UN LADO	3		60	
	ISQUIOTIBIALES SENTADO	3		30	
	EXTENSION DE ESPALDA	3		30	

Fuente. Adaptado de Población Objetivo, Universidad del Valle 2020, Bedoya, Luis *Fuente. Adaptado de Ejercicios de un día, Universidad del Valle 2020, Bedoya, Luis*

Figura 6

Creación de la red neuronal, Python

```
#Creación de la red neuronal
import keras
import tensorflow as tf
from keras.models import Sequential
from keras.layers import Dense

clasificador = Sequential()

clasificador.add(Dense(units=48, kernel_initializer='uniform', activation='relu', input_dim=48))
clasificador.add(Dense(units=40, kernel_initializer='uniform', activation='relu', ))
clasificador.add(Dense(units=30, kernel_initializer='uniform', activation='relu', ))
clasificador.add(Dense(units=1, kernel_initializer='uniform', activation='sigmoid',))
```

Fuente. Adaptado de Población Objetivo, Universidad del Valle,2020, Bedoya Luis

Preprocesamiento de datos:

Antes de utilizar los datos en el algoritmo de redes neuronales, se llevó a cabo un proceso de limpieza y preparación para garantizar su calidad y coherencia. Esto implicó eliminar datos faltantes, estandarizar formatos y seleccionar las variables más relevantes para el análisis.

Antes de comenzar cualquier análisis, se realizó una fase de limpieza de datos para identificar y corregir posibles errores, valores atípicos o datos faltantes. Esto implicó la revisión exhaustiva de la base de datos para eliminar cualquier inconsistencia o inexactitud que pudiera afectar la validez de los resultados. Durante esta etapa, se llevaron a cabo diversas transformaciones en los datos para prepararlos adecuadamente para su análisis. Esto incluyó la estandarización de unidades de medida, la codificación de variables categóricas y la normalización de datos numéricos para garantizar que estuvieran en un rango uniforme y comparable.

Se identificaron las características más relevantes y significativas de los datos que serían utilizadas como entradas para el algoritmo de redes neuronales. Esto implicó un análisis detallado de las variables disponibles y su relación con los resultados deseados, con el objetivo de seleccionar aquellas que tuvieran el mayor impacto en la predicción de las calificaciones de las rutinas de ejercicios. Los datos se dividieron en dos conjuntos principales: un conjunto de datos de entrenamiento y un conjunto de datos de prueba. El conjunto de entrenamiento se utilizó para ajustar los parámetros del modelo de redes neuronales, mientras que el conjunto de prueba se reservó para evaluar la capacidad de generalización del modelo sobre datos no vistos previamente.

Se aplicó el método de validación cruzada para evaluar la robustez y la generalización del modelo de redes neuronales. Esto implicó dividir repetidamente los datos en subconjuntos de entrenamiento y prueba, entrenar el modelo en cada subconjunto de entrenamiento y evaluar su rendimiento en el subconjunto de prueba correspondiente.

Programación del algoritmo:

Para programar el algoritmo de redes neuronales, se empleó Python junto con la distribución Anaconda y el entorno de desarrollo Spyder. Se importaron librerías como NumPy, Matplotlib y Pandas para facilitar el proceso. El diseño del algoritmo se realizó utilizando la biblioteca Keras, una herramienta de Python minimalista para Deep Learning.

Se dividió el conjunto de datos en datos de entrenamiento y prueba mediante la librería Scikit-learn (SKLearn), asignando el 80% de los datos al entrenamiento y el 20% restante a la prueba. Además, se normalizaron los datos para asegurar un procesamiento adecuado por parte del modelo de redes neuronales.

La construcción de la red neuronal artificial se llevó a cabo utilizando Keras. Se configuró un modelo secuencial agregando capas de neuronas de manera ordenada. Para cada capa, se definieron varios parámetros, como el número de nodos, la distribución de valores, la función de activación y el número de datos de entrada.

Para el aprendizaje del modelo, se utilizó el algoritmo Adam con el fin de minimizar el error durante el entrenamiento. Se empleó el error cuadrático medio (MSE) como métrica para evaluar el rendimiento del modelo tanto en el entrenamiento como en la prueba.

Se establecieron el tamaño de lote y el número de épocas para controlar el proceso de entrenamiento, utilizando un tamaño de lote de 30 y ejecutando 200 ciclos para asegurar un procesamiento adecuado de los datos. Se creó una matriz para almacenar los resultados del modelo durante el aprendizaje, lo que permitió realizar comparaciones entre los datos reales y las predicciones del modelo para evaluar su precisión y eficacia.

División de datos:

En el estudio, se llevó a cabo una división de los datos en dos conjuntos: entrenamiento y prueba. Para esto, se utilizó la función `train_test_split` de la librería Scikit-learn, asignando el 80% de los datos para entrenamiento y el 20% restante para evaluación. Previamente a la división, los datos fueron normalizados para asegurar una mejor convergencia del modelo durante el entrenamiento. Se estableció el parámetro `random_state` para garantizar la reproducibilidad de los resultados. Esta estrategia de división de datos permitió entrenar el modelo con una porción de los datos y luego evaluar su desempeño en datos independientes, validando así su capacidad de generalización a nuevos ejemplos.

Medición del desempeño de la red neuronal:

Se utilizó el algoritmo Adam para el proceso de aprendizaje, junto con la métrica del error cuadrático medio (MSE) para medir el desempeño del modelo. En la fase de creación de la red neuronal artificial, se empleó un modelo secuencial para construir la red neuronal, donde se agregaron capas de neuronas de manera ordenada. Se establecieron

varios parámetros clave, como el número de nodos en cada capa, la distribución de los valores de las capas y las funciones de activación de los nodos, utilizando ReLU y Sigmoid. Estos parámetros fueron determinados con base en diferentes referencias bibliográficas y experimentación. Para evaluar el desempeño del modelo, se utilizó el algoritmo de optimización Adam durante el proceso de aprendizaje. Además, se empleó la métrica del error cuadrático medio (MSE) para medir la discrepancia entre los valores reales y las predicciones del modelo. Esta métrica proporciona una medida cuantitativa del rendimiento del modelo durante el entrenamiento.

Definición de tamaños de lote y ciclos del modelo:

En cuanto a la definición de tamaños de lote y ciclos del modelo, se determinó el tamaño de lote, que indica la cantidad de muestras que se procesan antes de actualizar los parámetros del modelo, así como el número de ciclos o épocas de entrenamiento. Estos parámetros se seleccionaron con el fin de garantizar un procesamiento eficiente y completo de los datos de entrenamiento.

Almacenamiento de resultados del modelo:

Para el almacenamiento de los resultados del modelo, se creó una matriz específica que permitió registrar los datos obtenidos durante el proceso de aprendizaje. Esta matriz se utilizó para almacenar los resultados intermedios y finales del modelo, lo que facilitó el análisis y la evaluación del rendimiento del algoritmo.

Predicción de nuevas rutinas:

En la etapa de generación de nuevas rutinas, se recopilaron datos detallados de un nuevo grupo de individuos, utilizando un formato de inscripción diseñado previamente. Estos datos incluían información relevante sobre variables específicas relacionadas con el ejercicio y la condición física de los individuos. Luego, estos datos se introdujeron en el algoritmo de redes neuronales para generar planes de acondicionamiento físico personalizados para cada individuo. Las rutinas de ejercicios resultantes fueron diseñadas para ser ejecutadas semanalmente y se adaptaron a las necesidades y características de cada individuo, utilizando los parámetros establecidos durante la fase de creación de la red neuronal. Posteriormente, se entregaron estas rutinas a los individuos para su ejecución y se recopilaron sus calificaciones y observaciones sobre la efectividad y adecuación de las rutinas. Esta información se utilizó para evaluar el desempeño del algoritmo y ajustar los parámetros si fuera necesario, con el objetivo de mejorar la precisión y eficacia de las futuras generaciones de rutinas.

Las conclusiones del estudio reflejan la efectividad y el éxito del enfoque adoptado. La selección de las variables de entrada se realizó de manera satisfactoria con la asesoría de un grupo de expertos multidisciplinario, que proporcionó una base teórica sólida y relevante. El diseño y programación del algoritmo de redes neuronales recurrentes se basó en parámetros identificados específicamente para el estudio, así como en una recolección de datos adecuada y heterogénea que permitió un entrenamiento efectivo del algoritmo. A pesar de los desafíos impuestos por la pandemia del COVID-19, la fase de prueba piloto se llevó a cabo con éxito, obteniendo resultados positivos tanto en la percepción de los

individuos como en la evaluación de expertos. Se destaca la importancia de trabajar con un grupo de expertos para obtener soluciones innovadoras y satisfactorias en campos interdisciplinarios. El estudio concluye con la propuesta de seguir desarrollando la herramienta, incorporando más datos y diseñando una aplicación con una interfaz amigable para su distribución y venta. Además, se señala la relevancia de incluir variables que permitan seleccionar diferentes tipos de planes de acondicionamiento físico personalizado, considerando la posibilidad de ejecutar las rutinas en casa, una necesidad que se hizo evidente durante la pandemia. En resumen, el estudio resalta el potencial de la inteligencia artificial y la tecnología para abordar problemas complejos y adaptarse a las necesidades cambiantes de la sociedad. Los autores del estudio muestran confianza en los resultados obtenidos, resaltando la efectividad del enfoque multidisciplinario y la solidez del algoritmo desarrollado. Consideran crucial la selección precisa de variables y la recolección de datos heterogéneos para el entrenamiento del algoritmo. Valoraron positivamente la fase de prueba piloto y proponen seguir desarrollando la herramienta, incluyendo más datos y diseñando una interfaz amigable para su distribución y venta. Además, sugieren mejoras futuras, como la inclusión de variables para seleccionar diferentes tipos de planes de acondicionamiento físico, especialmente relevantes durante la pandemia del COVID-19.

En resumen, los autores muestran optimismo en el potencial de la inteligencia artificial para abordar problemas de salud y bienestar de manera innovadora.

Análisis crítico de los estudios: Reflexiones personales y perspectiva académica

Se ve algunas limitaciones y consideraciones que podrían influir en la interpretación y aplicación de los resultados obtenidos en este estudio. Si bien se destaca la importancia de la selección cuidadosa de variables y la recolección de datos heterogéneos, es fundamental garantizar que estas variables sean verdaderamente representativas y relevantes para el problema en cuestión. La validez de las calificaciones otorgadas por los individuos durante la fase de prueba piloto podría estar sujeta a sesgos de percepción o subjetividad, lo que podría impactar la interpretación de los resultados. Sería prudente realizar un análisis más exhaustivo de la precisión y robustez del algoritmo desarrollado, así como compararlo con otros métodos existentes en la literatura científica para evaluar su desempeño relativo en términos de predicción y prescripción de rutinas de ejercicios. Además, la propuesta de incluir variables para seleccionar diferentes tipos de planes de acondicionamiento físico es interesante, pero también plantea desafíos adicionales en términos de diseño y validación del algoritmo, especialmente en lo que respecta a la generalización y adaptabilidad a diversas situaciones y perfiles de usuarios. Aunque el estudio representa un avance significativo en la aplicación de inteligencia artificial al diseño de rutinas de ejercicios personalizadas, es importante abordar estas consideraciones para fortalecer la validez y la aplicabilidad de los resultados en entornos reales.

Tabla 7*Estudio 5*

Aspectos Destacados	Variables Destacadas	Impacto Potencial	Relevancia para la Hipertrofia Muscular
Recopilación de datos	Características individuales, historial médico, preferencias de ejercicio	Mejora en la personalización de planes de entrenamiento	La recopilación detallada de datos permite adaptar los planes de ejercicios a las necesidades específicas de cada individuo, lo que podría influir en la hipertrofia muscular.
Preprocesamiento de datos	Limpieza y preparación de datos	Mejora en la calidad de los datos	El preprocesamiento garantiza que los datos utilizados para entrenar el algoritmo sean precisos y coherentes, lo que puede afectar la precisión de la predicción del crecimiento muscular.
Programación del algoritmo	Uso de Python, Keras, Scikit-learn	Automatización y eficiencia	El uso de algoritmos de inteligencia artificial permite desarrollar planes de entrenamiento personalizados de manera eficiente, lo que puede optimizar el crecimiento muscular.
División de datos	Train_test_split	Validación del modelo	La división de datos permite evaluar la capacidad del modelo para generalizar sobre nuevos ejemplos, lo que es crucial para su aplicación en la hipertrofia muscular.
Medición del desempeño	Algoritmo Adam, Error Cuadrático Medio	Evaluación de la precisión del modelo	La precisión del modelo en predecir el rendimiento de los planes de entrenamiento puede influir en la efectividad de la hipertrofia muscular.
Definición de tamaños de lote y ciclos del modelo	Tamaño de lote, número de ciclos	Control del proceso de entrenamiento	Los parámetros del modelo afectan directamente la eficiencia y la precisión del proceso de entrenamiento, lo que influye en el resultado de la hipertrofia muscular.
Almacenamiento de resultados del modelo	Creación de una matriz específica	Facilita el análisis del rendimiento del modelo	El almacenamiento adecuado de los resultados del modelo permite evaluar su precisión y eficacia, lo que puede influir en el diseño de planes de entrenamiento más efectivos para la hipertrofia muscular.
Predicción de nuevas rutinas	Generación de planes de entrenamiento personalizados	Aplicación práctica del modelo	La capacidad del modelo para generar planes de entrenamiento adaptados a las necesidades individuales puede influir en la efectividad del crecimiento muscular en un contexto práctico.

Nota. Modelo de entrenamiento personalizado

Análisis Cuantitativo de Factores en el Crecimiento Muscular

Se valorizan las conclusiones de la literatura científica que indican que, al aproximarse al fallo muscular, el número total de repeticiones y la carga utilizada no son los únicos factores determinantes para generar adaptaciones musculares. Esto lleva a la reflexión sobre la necesidad de considerar un enfoque más completo al medir el volumen de entrenamiento.

Según el estudio bibliométrico realizado, se ha sintetizado que el volumen de trabajo, definido por el número total de series realizadas por grupo muscular, es un factor crucial en el desarrollo de la hipertrofia muscular. Este análisis ha permitido comprender que el método tradicional de calcular el volumen, basado únicamente en series, repeticiones y peso, puede subestimar el verdadero impacto del entrenamiento en ciertos ejercicios.

Se reconoce la importancia de considerar la diversidad de repeticiones a lo largo del rango de cargas, desde las más pesadas que generan alta tensión mecánica hasta las más ligeras que enfatizan el estrés metabólico, para obtener resultados óptimos en el crecimiento muscular.

Por lo tanto, se sostiene que una forma más efectiva de medir el volumen es considerar el número total de series de trabajo por grupo muscular, siempre y cuando estas se realicen cerca del fallo muscular y dentro de un rango de repeticiones de 6 a 25 (Schoenfeld, Ogborn, & Krieger, 2017).

Dentro del contexto del volumen de entrenamiento, se destaca el principio de la "U" invertida, que sugiere que un cierto número de series semanales produce adaptaciones óptimas para la hipertrofia muscular. A continuación, en la figura 7 se describe las series óptimas de carga de entrenamiento

Figura 7

Series Óptimas de ejercicios de carga para la hipertrofia muscular



Fuente. Adaptado de Series óptimas de Hipertrofia, por TrainoloGym, 2019, (Radaelli et al., 2013., 2014)

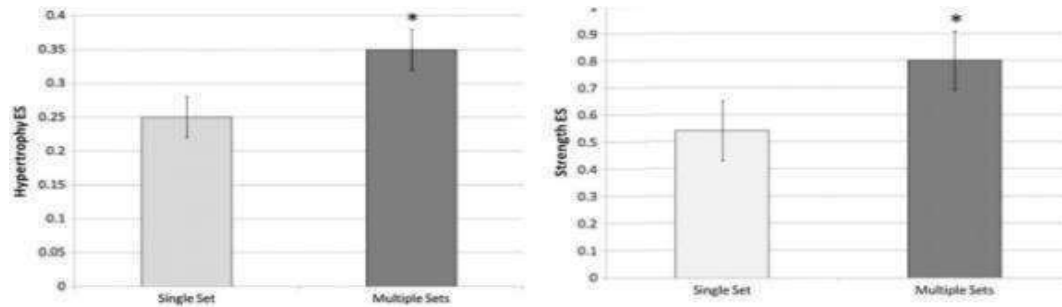
Según este principio y respaldado por varios estudios, se observa que las rutinas de series múltiples tienden a ser más efectivas que las de series únicas en términos de ganancias de masa muscular. Sin embargo, es importante destacar que algunos estudios no encuentran diferencias significativas entre protocolos de series únicas y multiseries, especialmente en sujetos no entrenados o en estudios de corta duración.

Un estudio a largo plazo con sujetos entrenados demostró que un protocolo de 5 series produjo mejores resultados que los de 3 y 1 serie, mostrando una respuesta hipertrófica dependiente del volumen. Además, análisis meta analíticos respaldan la idea de que los protocolos de multiseries están asociados con mayores ganancias de hipertrofia y

fuerza en comparación con los de series únicas. (Radaelli et al., 2015).

Figura 8

Multiseries de ejercicios para hipertrofia muscular

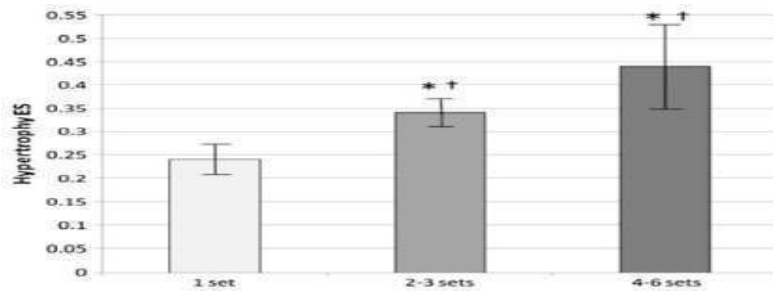


Fuente. Adaptado por Mejoras significativas en los protocolos multiseries, TrainoloGym, Krieger, 2010.

La relación dosis-respuesta del volumen también ha sido observada en varias revisiones, lo que sugiere que, a mayor volumen de entrenamiento, mayores ganancias, hasta cierto punto. Sin embargo, existe un límite fisiológico en el volumen a partir del cual las adaptaciones pueden disminuir y la fatiga acumulada puede conducir al sobreentrenamiento. Determinar el volumen óptimo de entrenamiento es crucial y depende de diversos factores individuales como la genética, el nivel de entrenamiento, la nutrición y el descanso. La guía propuesta por el Dr. Mike Israetel, utilizando los Volume Landmarks, ofrece una referencia útil para establecer el volumen óptimo de entrenamiento.

Figura 9

Respuesta hipertrófica volumen dependiente



Fuente. Adaptado a Respuesta hipertrófica volumen dependiente, TrainoloGym, (Krieger, 2010).

El rango de repeticiones recomendado suele estar entre 8 y 20, con un promedio establecido. Es importante que las cargas utilizadas estén dentro del rango del 60 al 80 % de la Repetición Máxima (1RM) en promedio y que se llegue cerca del fallo muscular, con no más de 3 o 4 repeticiones en reserva. Una vez cumplidas estas premisas, es crucial determinar el Volumen Efectivo Mínimo Semanal (MEV) para iniciar un mesociclo de entrenamiento. Progresivamente, se debe buscar aumentar el volumen de entrenamiento, moviéndose principalmente dentro del Volumen Adaptativo Máximo (MAV) y aproximándose o superando puntualmente el Volumen Recuperable Máximo (MRV). Este principio de sobrecarga progresiva es esencial para generar adaptaciones musculares efectivas a lo largo del tiempo. Israel, M. (2017). *Scientific Principles of Strength Training*. RP Strength.

Figura 10

Volumen Landmarks

VOLUME LANDMARKS	DESCRIPCIÓN
MV = Volumen de Mantenimiento	Mínimo volumen que necesitas para mantener tus ganancias
MEV = Volumen mínimo efectivo	Volumen mínimo a partir del cual se generan adaptaciones
MAV = Volumen máximo adaptativo	Volumen donde se generan las mejores adaptaciones
MRV = Volumen máximo recuperable	Máximo volumen del que te puedes recuperar. Sobrepasarlo

Fuente. Adaptado a Volúmenes de entrenamiento, TrainoloGym, (Israetel, M., 2017).

Se ha observado que la mayoría de los estudios sugieren un volumen de entre 10 y 20 series semanales como óptimo para inducir hipertrofia muscular. Por lo tanto, un punto de partida recomendado podría ser iniciar con alrededor de 10 series semanales por grupo muscular.

Luego, se puede experimentar incrementando gradualmente este volumen, agregando aproximadamente 2 series por semana hasta acercarse o superar las 20 series, evaluando los resultados de manera constante. Estas recomendaciones son particularmente relevantes para personas principiantes, ya que un incremento progresivo del volumen de entrenamiento puede facilitar la mejora y la adherencia inicial al programa. Es importante tener en cuenta que la capacidad de tolerar el volumen de entrenamiento varía entre grupos musculares y personas, por lo que es necesario adaptar las recomendaciones según las características individuales.

Carga de Entrenamiento:

La carga de entrenamiento es un concepto fundamental en el ámbito del entrenamiento deportivo. Se refiere al conjunto de exigencias biológicas y psicológicas que

resultan de las actividades de entrenamiento, las cuales provocan desgaste, alteraciones fisiológicas y psicológicas, así como cambios en el equilibrio homeostático del organismo (Matveev, 1981).

Tipos de Carga de Entrenamiento

Carga Real: Se refiere al desgaste y las alteraciones fisiológicas y psicológicas que resultan directamente de las actividades de entrenamiento. Es la respuesta del organismo a la estimulación externa proporcionada por el ejercicio físico.

Carga Propuesta: Consiste en los estímulos planificados que se utilizan para expresar la carga real a través del entrenamiento sistemático. Estos estímulos constituyen el entrenamiento al que se enfrenta el deportista de manera planificada y controlada.

Medición de la Carga de Entrenamiento

Porcentaje de 1RM: Esta medida se basa en el peso relativo al máximo que una persona puede levantar en un ejercicio específico, conocido como una repetición máxima (1RM). Por ejemplo, trabajar al 75% de mi 1RM significa usar una carga equivalente al 75% del máximo (Haff & Triplett, 2016).

Número Máximo de Repeticiones (RM): Se cuantifica la intensidad según la cantidad de repeticiones realizadas con una carga máxima. Por ejemplo, si puedo hacer un máximo de 6 repeticiones (6RM) con un peso determinado, estoy entrenando a esa intensidad (Kraemer & Ratamess, 2004).

Esfuerzo Percibido (RPE): Se evalúa subjetivamente la intensidad durante el ejercicio en una escala del 1 al 10. Un RPE de 9 indica que se podría hacer una repetición

más antes de llegar al fallo muscular (Foster et al., 2001).

Relación entre la Carga de Entrenamiento y la Hipertrofia Muscular

La relación entre la carga de entrenamiento y la hipertrofia muscular es crucial para entender cómo el estímulo del entrenamiento afecta al crecimiento del músculo. Aquí se detallan los principales enfoques:

Entrenamiento para Fuerza: Se enfoca en trabajar entre el 2/3 y 3/4 del volumen total entre 1 y 6 repeticiones, con un RPE de 5-10. Esto permite acumular un volumen significativo de trabajo con cargas pesadas para estimular la ganancia de fuerza y hipertrofia (Schoenfeld et al., 2015).

Entrenamiento para Hipertrofia Muscular: Aquí se realizan entre 6 y 12 repeticiones, con un RPE de 5-10, y hasta el 3/4 del volumen total. Mantener un esfuerzo elevado durante estas repeticiones es crucial para maximizar el estímulo para el crecimiento muscular (The Muscle & Strength Pyramid, 2019).

Importancia de la Carga de Entrenamiento en la Hipertrofia Muscular

La correcta aplicación y comprensión de la carga de entrenamiento es esencial para maximizar la hipertrofia muscular. Ajustar la intensidad, el volumen y el esfuerzo percibido según los objetivos específicos de entrenamiento puede ayudar a optimizar los resultados en términos de crecimiento muscular y fuerza (González-Badillo & Sánchez-Medina, 2010).

Sin embargo, es crucial recordar que la carga de entrenamiento debe ser individualizada y adaptada según las capacidades y necesidades de cada persona. La relación entre la carga de entrenamiento y la hipertrofia muscular es un área de investigación en constante

evolución que requiere más estudios para comprender mejor su contribución al desarrollo muscular.

Duración del tiempo de levantamiento:

El Tiempo Bajo Tensión Muscular y el Tempo del Levantamiento: Factores Clave en el Entrenamiento de Fuerza y Hipertrofia

El tiempo bajo tensión muscular (TUT) y el tempo del levantamiento son elementos esenciales, pero a menudo pasados por alto en el entrenamiento de fuerza y la hipertrofia muscular. Aquí analizamos en detalle su importancia, así como su impacto en los resultados del entrenamiento.

Definición y Significado del Tiempo Bajo Tensión (TUT)

El tiempo bajo tensión se refiere al período durante el cual las fibras musculares están bajo carga durante un ejercicio. Este factor es crítico para el desarrollo muscular, ya que la tensión sostenida en las fibras musculares provoca micro lesiones que, con la adecuada recuperación, conducen al crecimiento muscular (Schoenfeld et al., 2017).

El TUT es influenciado por la velocidad de ejecución del ejercicio: a mayor velocidad, menor tiempo bajo tensión, y viceversa. Por ejemplo, al realizar repeticiones más lentas, el tiempo bajo tensión se incrementa, lo que favorece la hipertrofia muscular.

Entendiendo el Tempo del Levantamiento

El tempo del levantamiento se refiere a la duración de cada fase del movimiento durante un ejercicio. Por lo general, se divide en tres fases:

Fase Concéntrica: Es la fase en la que los músculos se contraen para levantar la carga.

Fase Isométrica o de Pausa: Es el breve período entre las fases concéntrica y excéntrica.

Fase Excéntrica: Es la fase en la que los músculos se alargan mientras controlan el descenso de la carga.

El tempo se expresa como una serie de números que indican la duración en segundos de cada fase del movimiento. Por ejemplo, un tempo de 3/1/3 significa que la fase concéntrica dura 3 segundos, seguida de una pausa de 1 segundo, y luego la fase excéntrica dura 3 segundos.

Impacto del Tiempo Bajo Tensión y el Tempo del Levantamiento

Hipertrofia Muscular: El tiempo bajo tensión es esencial para provocar el crecimiento muscular. Se recomienda un TUT de entre 30 y 60 segundos para estimular la hipertrofia, con un énfasis en la fase excéntrica controlada (Schoenfeld et al., 2015).

Fuerza Máxima: En el entrenamiento de fuerza, el énfasis está en mover cargas pesadas. Aunque el tiempo bajo tensión es menos relevante, una fase excéntrica controlada es importante para iniciar el movimiento en una posición óptima y una fase concéntrica rápida para maximizar la aceleración (Kraemer & Ratamess, 2004).

Efectos del Tempo del Levantamiento

Fase Excéntrica Lenta: Al alargar la fase excéntrica, se incrementa el tiempo bajo tensión. Sin embargo, al exceder los 10 segundos totales de cada repetición, puede comprometerse el volumen y la intensidad del entrenamiento (Schoenfeld et al., 2015).

Fase Concéntrica Potente: Una fase concéntrica rápida y potente ayuda a generar fuerza y potencia, beneficiosos para el rendimiento deportivo y el desarrollo muscular (Schoenfeld et al., 2017).

Frecuencia de Entrenamiento:

La frecuencia de entrenamiento para el crecimiento muscular ha sido objeto de un intenso debate en el mundo del fitness y el culturismo

Puntos Clave

Para la hipertrofia, la evidencia sugiere que entrenar un músculo 2x o 3x por semana es más efectivo que hacerlo solo 1x. No obstante, no existen estudios claros que establezcan si 3x es preferible a 2x.

La periodización es fundamental para determinar las frecuencias de entrenamiento. Aunque un bloque de alta frecuencia puede parecer beneficioso, puede conducir al agotamiento y aumentar el riesgo de lesiones si se mantiene constantemente.

Cómo la Frecuencia de Entrenamiento Impacta el Crecimiento Muscular

En la investigación sobre frecuencias, los participantes suelen dividirse en grupos que entrenan 1x, 2x o 3x por semana (por grupo muscular). Esto se refiere a cuántas veces entrenan un grupo muscular específico semanalmente.

Es importante igualar el volumen de entrenamiento entre los grupos para determinar si una frecuencia es más efectiva que otra. Por ejemplo, dos programas pueden tener el

mismo volumen semanal, aunque varíe la frecuencia de entrenamiento por grupo muscular.

Estudios con Volumen Igualado: Impacto en las Ganancias Musculares

Aquí hay una visión general de estudios que equiparan el volumen de entrenamiento para analizar la hipertrofia:

McLester et al. (2000): Compararon 1x vs 3x por semana en sujetos recreativos. La frecuencia 3x mostró mayores ganancias, pero el volumen fue bajo y los resultados no fueron significativos estadísticamente.

Candow & Burke (2007): Contrastaron 2x vs 3x en sujetos desentrenados, sin diferencias significativas.

Benton et al. (2011): No encontraron diferencias significativas entre 2x vs 3x en mujeres con sobrepeso sin experiencia en entrenamiento.

Gentil et al. (2015): Compararon 1x vs 2x en hombres no entrenados, sin diferencias significativas pero una tendencia hacia 2x.

Schoenfeld et al. (2015): Mostraron que 3x por semana produjo mayores ganancias en bíceps que 1x en hombres entrenados.

Thomas & Burn (2016): No encontraron diferencias entre (1x y 3x por semana) en hombres y mujeres con experiencia en entrenamiento.

Crewther et al. (2016): Tendencia hacia mayores ganancias con 3x, pero no significativo en hombres entrenados

Gentil et al. (2018): Encontraron que 1x aumentó significativamente el grosor del bíceps en comparación con 2x en individuos entrenados

Colquhoun et al. (2018): No hubo diferencias entre 3x y 6x en masa magra y fuerza en individuos entrenados.

Los resultados tienden a favorecer frecuencias más altas, pero las diferencias no son significativas en muchos casos.

Meta-Análisis

Schoenfeld et al. (2015) analizaron múltiples estudios y encontraron que, en general, las frecuencias más altas se asocian con mayores ganancias musculares, pero el impacto es pequeño. Las frecuencias de (2x por semana) parecen ser más efectivas que 1x.

Aplicación Práctica.

En general, los datos probablemente favorezcan una frecuencia de (2x a 3x por semana) una vez que esté acostumbrado a un protocolo de entrenamiento. Sin embargo, al observar los datos meta-analíticos, la frecuencia juega un papel muy menor en la hipertrofia, y probablemente sea mejor elegir una frecuencia que funcione mejor para usted y sus habilidades de recuperación, y que le permita entrenar con un volumen de calidad suficiente.

Evite entrenamientos de (1x por semana) con volúmenes muy altos, ya que pueden no ser ideales para el crecimiento muscular.

La recuperación individual y la capacidad de manejar el volumen de entrenamiento son factores importantes.

La frecuencia óptima puede variar según la edad, la experiencia en entrenamiento y otros factores individuales.

La periodización es clave para manipular la frecuencia y el volumen de entrenamiento de manera efectiva.

La frecuencia de entrenamiento de 2x a 3x por semana parece ser más efectiva para el crecimiento muscular, pero la individualización y la periodización son fundamentales para optimizar los resultados.

Nutrición:

La nutrición es una variable clave en el proceso de hipertrofia muscular. Cuando buscamos aumentar el tamaño y la fuerza de nuestros músculos, la alimentación adecuada desempeña un papel fundamental, tanto antes como después del entrenamiento. A continuación, vamos a explorar en detalle cómo la nutrición y la suplementación pueden influir en la hipertrofia muscular, teniendo en cuenta los aspectos proporcionados en el contexto previo. Helms, E. R., Aragon, A. A., & Fitschen, P. J. (2014).

Para comprender completamente la importancia de la nutrición en la hipertrofia muscular, primero debemos entender cómo se produce el crecimiento muscular. La hipertrofia muscular es el proceso mediante el cual las células musculares aumentan de tamaño como resultado del entrenamiento de fuerza y la adaptación al estrés mecánico. Durante el entrenamiento de fuerza, se producen micro lesiones en las fibras musculares, lo que desencadena una serie de procesos de reparación y crecimiento. La síntesis de proteínas musculares es esencial para este proceso de reparación y crecimiento muscular. Thomas, D. T., Erdman, K. A., & Burke, L. M. (2016).

Los aminoácidos, que son los componentes básicos de las proteínas, son esenciales para la síntesis de proteínas musculares. Específicamente, los aminoácidos esenciales, que nuestro cuerpo no puede producir por sí solo y deben obtenerse a través de la dieta, son cruciales para la hipertrofia muscular.

Entre estos aminoácidos esenciales, la leucina se destaca como un activador clave de la síntesis de proteínas musculares. Phillips, S. M., & Van Loon, L. J. (2011).

La ingesta de proteínas después del entrenamiento de fuerza es fundamental para proporcionar a los músculos los aminoácidos necesarios para la síntesis proteica y la reparación muscular. Diversos estudios han demostrado que consumir proteínas inmediatamente después del ejercicio aumenta significativamente la síntesis de proteínas musculares [3]. La cantidad de proteína recomendada para la hipertrofia muscular generalmente oscila entre 1,6 y 2,2 gramos por kilogramo de peso corporal al día. Thomas, D. T., Erdman, K. A., & Burke, L. M. (2016).

Además de las proteínas, los carbohidratos también desempeñan un papel importante en el proceso de hipertrofia muscular. Durante el ejercicio, los carbohidratos proporcionan la energía necesaria para realizar el trabajo muscular. Después del ejercicio, los carbohidratos ayudan a reponer el glucógeno muscular, lo que es crucial para la recuperación y el rendimiento en entrenamientos posteriores. La cantidad de carbohidratos recomendada para la hipertrofia muscular generalmente oscila entre 2,5 y 4 gramos por kilogramo de peso corporal al día. Thomas, D. T., Erdman, K. A., & Burke, L. M. (2016)

Asimismo, las grasas también son importantes en la dieta de una persona que busca aumentar la masa muscular. Las grasas proporcionan energía y son esenciales para la absorción de vitaminas liposolubles. La cantidad recomendada de grasa en la dieta varía,

pero generalmente se encuentra entre 0,5 y 1 gramo por kilogramo de peso corporal al día. Helms, E. R., Aragon, A. A., & Fitschen, P. J. (2014).

La elección de las fuentes de proteínas, carbohidratos y grasas también es crucial. Las proteínas de alta calidad, como las que se encuentran en carnes magras, pescado, huevos y productos lácteos, proporcionan todos los aminoácidos esenciales necesarios para la síntesis de proteínas musculares. Los carbohidratos complejos, como los que se encuentran en granos enteros, arroz, pasta y vegetales, proporcionan una fuente de energía sostenida. Las grasas saludables, como las que se encuentran en aguacates, aceite de oliva, frutos secos y pescados grasos, son importantes para la salud en general y para la función hormonal.

Además de los macronutrientes, la suplementación también puede ser beneficiosa para aquellos que buscan aumentar la masa muscular. Los suplementos de proteínas, como el suero de leche y la caseína, pueden ser útiles para aumentar la ingesta de proteínas después del ejercicio. Los suplementos de aminoácidos también pueden ser beneficiosos, especialmente los que contienen altas cantidades de leucina.

En cuanto al momento de la ingesta, se ha demostrado que consumir proteínas y carbohidratos inmediatamente después del ejercicio aumenta la síntesis de proteínas musculares y promueve la recuperación muscular. Sin embargo, la distribución de macronutrientes a lo largo del día también es importante. Algunos estudios sugieren que consumir proteínas y carbohidratos antes del ejercicio puede mejorar el rendimiento y la recuperación. Ivy, J. L., & Portman, R. (2004).

La nutrición desempeña un papel crucial en el proceso de hipertrofia muscular. Consumir la cantidad adecuada de proteínas, carbohidratos y grasas, así como elegir

fuentes de alimentos de alta calidad, puede ayudar a promover la síntesis de proteínas musculares y facilitar la recuperación muscular. Además, la suplementación puede ser útil para aquellos que tienen dificultades para satisfacer sus necesidades nutricionales a través de la dieta sola.

En última instancia, la combinación de una dieta adecuada, un entrenamiento de fuerza efectivo y un buen descanso es fundamental para lograr el crecimiento muscular deseado.

Genética:

La genética desempeña un papel importante en la hipertrofia muscular. La variabilidad genética entre individuos puede influir en la respuesta al entrenamiento de fuerza y en la capacidad de desarrollar masa muscular. Algunos factores genéticos, como la composición de los tipos de fibras musculares, la sensibilidad a las hormonas anabólicas y la capacidad de recuperación, pueden determinar en gran medida el potencial de una persona para la hipertrofia muscular.

La composición de los tipos de fibras musculares es un factor genético importante que puede influir en la respuesta al entrenamiento de fuerza. Las fibras musculares se dividen

principalmente en dos tipos: fibras de contracción lenta (tipo I) y fibras de contracción rápida (tipo II). Las fibras tipo II tienen un mayor potencial de crecimiento en comparación con las fibras tipo I, lo que significa que las personas con una mayor proporción de fibras tipo II pueden experimentar una mayor hipertrofia muscular en respuesta al entrenamiento de fuerza. Wang, Y. X., Zhang, C. L., Yu, R. T., Cho, H. K.,

Nelson, M. C., Bayuga- Ocampo, C. R., ... & Evans, R. M. (2004).

Los genes también pueden influir en la sensibilidad a las hormonas anabólicas, como la testosterona, el factor de crecimiento similar a la insulina 1 (IGF-1) y la hormona del crecimiento. Estas hormonas juegan un papel crucial en la regulación de la síntesis de proteínas musculares y, por lo tanto, en el crecimiento muscular.

Por ejemplo, los receptores de andrógenos, que son proteínas codificadas por genes específicos, determinan la sensibilidad de los músculos a la testosterona. Las personas con una mayor sensibilidad a la testosterona pueden experimentar una mayor hipertrofia muscular en respuesta al entrenamiento de fuerza. Guadalupe-Grau, A., Santiago, C., Alcazar, J., Rubio, J. C., García-Consuegra, I., Drobic, F., ... & Ruiz, J. R. (2009).

Además, los genes también pueden influir en la capacidad de recuperación muscular después del ejercicio. La capacidad de recuperación está determinada en parte por la capacidad del cuerpo para reparar el tejido muscular dañado y sintetizar nuevas proteínas musculares. Algunos genes están involucrados en la regulación de estos procesos, y las variaciones genéticas pueden afectar la velocidad y la eficacia con la que ocurren. Por ejemplo, los polimorfismos en los genes que codifican las proteínas involucradas en la reparación del tejido muscular, como las metaloproteinasas de matriz (MMPs) y las citoquinas, pueden influir en la capacidad de recuperación muscular. Clarkson, P. M., & Hubal, M. J. (2002).

La genética puede influir en varios aspectos de la hipertrofia muscular, incluida la composición de los tipos de fibras musculares, la sensibilidad a las hormonas anabólicas y la capacidad de recuperación. Sin embargo, es importante tener en cuenta que la genética no determina completamente el potencial de crecimiento muscular de una persona. El

entrenamiento adecuado, la nutrición y otros factores ambientales también juegan un papel crucial en el desarrollo de masa muscular.

Ciencia de Datos y Modelos Predictivos en el Crecimiento Muscular

Se implementa un modelo de regresión logística para predecir la probabilidad de desarrollar hipertrofia muscular basado en varias características relacionadas con el entrenamiento y la nutrición. Primero, se importaron las bibliotecas necesarias, como pandas para manejar los datos y StandardScaler para normalizar las características. Los datos se cargaron desde un archivo CSV y se seleccionaron las características relevantes para ser escaladas. La normalización fue crucial para mejorar el rendimiento del modelo y asegurar que todas las características contribuyan de manera equitativa a la predicción.

Luego, se dividieron los datos en conjuntos de entrenamiento y prueba utilizando `train_test_split`, permitiendo evaluar el modelo en datos no vistos durante el entrenamiento. El modelo de regresión logística se entrenó con los datos de entrenamiento utilizando `LogisticRegression` de sklearn, ideal para problemas de clasificación binaria como determinar la probabilidad de desarrollar hipertrofia muscular. La regresión logística estima la probabilidad de que ocurra un evento (en este caso, hipertrofia muscular) basándose en una combinación lineal de las características de entrada.

Finalmente, se solicitó al usuario que ingresara sus datos personales relacionados con el entrenamiento y la nutrición. Estos datos se escalan utilizando el mismo `StandardScaler` aplicado a los datos de entrenamiento, asegurando consistencia en las predicciones. El modelo se utilizó para predecir si es favorable para el usuario desarrollar hipertrofia muscular. Se imprimió el resultado, proporcionando una respuesta clara y útil basada en las características ingresadas. Este enfoque permite personalizar las

recomendaciones y mejorar la precisión de las predicciones, subrayando la importancia de la regresión logística en la toma de decisiones informadas en el contexto del entrenamiento y la salud.

Figura 11

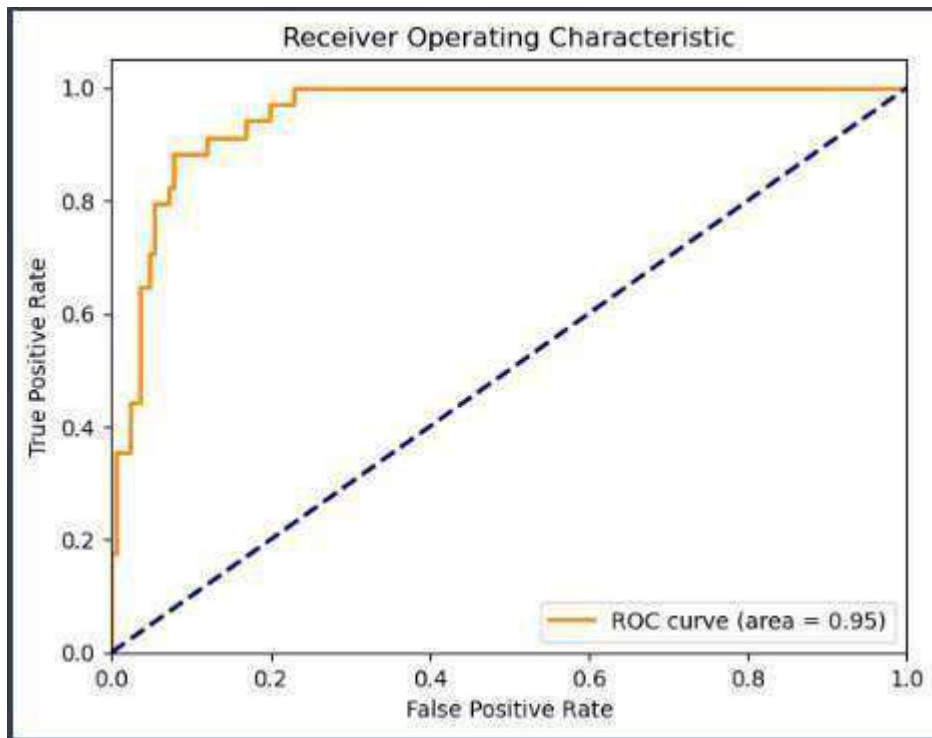
Análisis de datos

Proceso de Análisis de Datos y Modelo Predictivo

Python



Fuente. Elaboración Propia

Resultados:**Figura 12***Curva Roc*

Fuente. Elaboración Propia, Jupyter notebook

Las características de entrada (X) son:

Entrenamiento (días/semana), Duración de entrenamiento (minutos), Calorías diarias, Proteínas diarias (g/kg) y Edad.

La variable objetivo (y) es "Hipertrofia Muscular".

Al observar la gráfica de la curva ROC y el análisis, puedo inferir cómo el modelo de regresión logística está clasificando correctamente los casos de hipertrofia muscular en

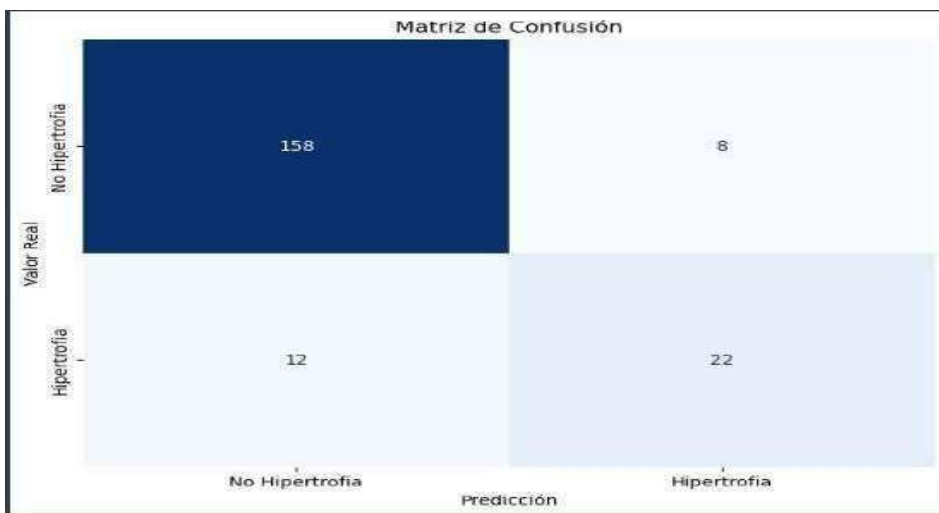
función de estas características de entrada. A medida que ajusto el umbral de clasificación, veo cómo cambian las tasas de verdaderos positivos (casos de hipertrofia muscular correctamente identificados) y las tasas de falsos positivos (casos sin hipertrofia muscular incorrectamente identificados como positivos).

Esto me proporciona una idea de cómo el modelo utiliza las características de entrada para hacer predicciones sobre la presencia o ausencia de hipertrofia muscular. Por ejemplo, si observo que la tasa de verdaderos positivos aumenta significativamente a medida que disminuye el umbral de clasificación para ciertas características (por ejemplo, mayor duración de entrenamiento), puedo inferir que esas características están fuertemente asociadas con la hipertrofia muscular según el modelo.

Matriz de Confusión

Figura 13

Matiz de Confusión



Fuente. Elaboración Propia, Jupyter notebook

Al observar la matriz de confusión, noto que en la categoría "No Hipertrofia", mi modelo predijo correctamente 158 casos como "No Hipertrofia" y solo 8 casos incorrectamente como "Hipertrofia". Esto sugiere que mi modelo tiene una alta capacidad para identificar aquellos individuos que no tienen hipertrofia muscular y clasificarlos correctamente como tal. Es un resultado alentador ya que minimizar los falsos positivos es crucial en un contexto de salud, evitando diagnósticos erróneos que podrían llevar a intervenciones innecesarias.

Sin embargo, en la categoría "Hipertrofia", veo que mi modelo acertó en clasificar correctamente 22 casos como "Hipertrofia", pero falló en 12 casos, los cuales predijo incorrectamente como "No Hipertrofia". Este hallazgo es preocupante, ya que los falsos negativos pueden ser peligrosos en un contexto médico, ya que podrían resultar en la falta de tratamiento o seguimiento para aquellos individuos que realmente necesitan atención. Por lo tanto, aunque mi modelo parece funcionar bien en la identificación de casos negativos, necesita mejoras en su capacidad para detectar adecuadamente la hipertrofia muscular.

Dado que el objetivo es minimizar tanto los falsos positivos como los falsos negativos, debo considerar ajustar el umbral de clasificación o explorar características adicionales que puedan mejorar la capacidad del modelo para distinguir entre las clases. Además, este análisis resalta la importancia de la validación continua del modelo y la búsqueda de formas de mejorar su rendimiento para garantizar diagnósticos precisos y eficaces en el contexto de la predicción de la hipertrofia muscular.

Tabla 8*Métricas de Evaluación del modelo*

Descripción	Precisión	Recall	F1-Score	Support
Sin Hipertrofia	0,929	0,952	0,940	166
Hipertrofia	0,733	0,647	0,687	34
Accuracy		0,900		200
Macro avg	0,831	0,799	0,813	200
Weighted	0,897	0,900	0,898	200

Nota. Indicadores de desempeño modelo de predicción

En términos de Precisión, veo que para la clase "No Hipertrofia", el modelo tiene una precisión del 92.9%. Esto significa que de todas las predicciones que hizo para "No Hipertrofia", el 92.9% fueron verdaderamente negativas. Para la clase "Hipertrofia", la precisión es del 73.3%, lo que indica que el 73.3% de las predicciones de "Hipertrofia" fueron correctas. Al revisar el Recall, noto que para la clase "No Hipertrofia", el modelo tiene un recall del 95.2%. Esto significa que de todos los casos reales de "No Hipertrofia", el 95.2% fueron identificados correctamente por el modelo. Sin embargo, para la clase "Hipertrofia", el recall es del 64.7%, lo que indica que solo el 64.7% de todos los casos reales de "Hipertrofia" fueron detectados por el modelo.

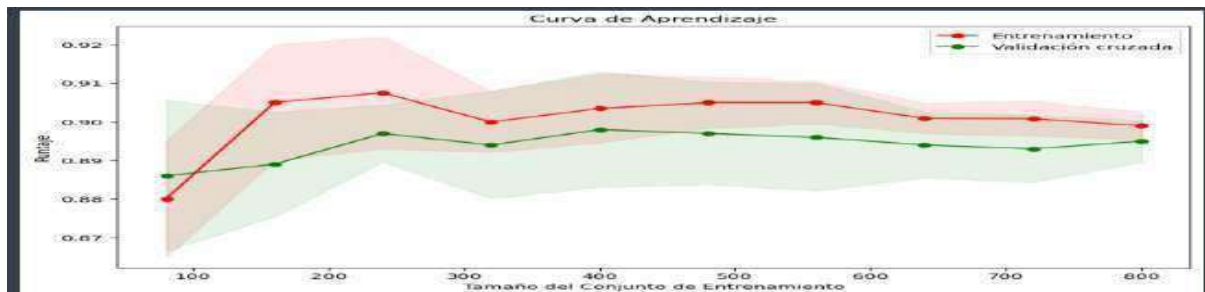
Para el F1-Score, que es una medida de precisión y recall combinados, observo que para la clase "No Hipertrofia" el valor es 0.940, mientras que para la clase "Hipertrofia" es 0.687. En cuanto a la Accuracy, veo que es del 90.0%, lo que significa que el modelo clasificó correctamente el 90.0% de todos los casos.

Analizando las métricas de Macro avg y Weighted avg, puedo ver que proporcionan una media de las métricas de las clases.

La precisión macro avg es del 83.1%, mientras que la precisión weighted avg es del 89.7%, lo que indica un buen rendimiento general del modelo en la clasificación de ambas clases. Estas métricas indican que el modelo tiene un buen desempeño en la clasificación de la clase "No Hipertrofia", pero puede mejorar en la clasificación de la clase "Hipertrofia" para aumentar su recall y F1-Score.

Figura 14

Curva de aprendizaje: Jupyter Notebook



Fuente. Elaboración Propia

La curva de aprendizaje muestra cómo varía el rendimiento del modelo de regresión logística a medida que cambia el tamaño del conjunto de entrenamiento.

Tamaño del Conjunto de Entrenamiento: El tamaño del conjunto de entrenamiento aumenta gradualmente, lo que indica la cantidad de datos utilizados para entrenar el modelo.

Puntuación de Entrenamiento (media y desviación estándar): La puntuación de entrenamiento (precisión) tiende a ser alta, alrededor del 88% al 90%, lo que sugiere que el modelo tiende a ajustarse bien a los datos de entrenamiento. La desviación estándar de estas puntuaciones es bastante baja, lo que indica una consistencia en el rendimiento del modelo en diferentes conjuntos de entrenamiento.

Puntuación de Validación (media y desviación estándar): Para la validación, veo que las puntuaciones tienden a ser similares a las del conjunto de entrenamiento, lo que sugiere que el modelo generaliza bien a datos no vistos. Sin embargo, también observo que hay una ligera variabilidad en las puntuaciones de validación, como se refleja en la desviación estándar, lo que indica que el rendimiento del modelo puede variar en diferentes subconjuntos de validación.

Estos resultados sugieren que el modelo de regresión logística tiene un buen rendimiento y capacidad de generalización en la predicción de la hipertrofia muscular, ya que muestra una alta precisión tanto en los conjuntos de entrenamiento como de validación. Sin embargo, seguiría evaluando el modelo en conjuntos de datos más grandes para confirmar su rendimiento y generalización.

Perspectiva para Futuros Trabajos

Para desarrollar un modelo predictivo de hipertrofia muscular, se requiere la recopilación de una variedad de datos relevantes que abarcan desde datos demográficos como edad, género, peso y altura, hasta información detallada sobre el historial de ejercicio, composición corporal, genética, nutrición y resultados de pruebas biométricas. Estos datos proporcionan una base sólida para comprender cómo diferentes factores influyen en el crecimiento muscular y permiten desarrollar un modelo predictivo preciso y útil. La calidad y la cantidad suficiente de datos son fundamentales para asegurar la robustez del modelo.

Garantizar la privacidad de los datos y obtener el consentimiento informado de los participantes son pasos éticos fundamentales. Se deben implementar estrictos protocolos de seguridad para proteger la información personal, asegurando que se utilice únicamente para

investigación y se mantenga confidencial.

El desarrollo del modelo predictivo implica una serie de pasos fundamentales en el procesamiento de datos y la evaluación del modelo. Inicialmente, se procede con el procesamiento de los datos recopilados, eliminando registros duplicados y corrigiendo errores tipográficos para garantizar la integridad de los datos. Luego, se normalizan las características para estandarizar su escala, facilitando así el análisis posterior. Se emplean técnicas como el Análisis de Componentes Principales (PCA) para identificar las características más relevantes y reducir la dimensionalidad de los datos, eliminando aquellas que no contribuyen significativamente a la predicción. Posteriormente, se dividen los datos en conjuntos de entrenamiento y prueba para entrenar el modelo y evaluar su capacidad predictiva.

Para abordar el desafío de predecir la hipertrofia muscular, se consideran dos modelos de clasificación binaria: Random Forest y Regresión Logística. Random Forest utiliza múltiples árboles de decisión para predecir la probabilidad de hipertrofia muscular, siendo efectivo en la detección de patrones complejos y el manejo de grandes volúmenes de datos. Por otro lado, la Regresión Logística modela la probabilidad de hipertrofia muscular basándose en una combinación lineal de variables independientes, proporcionando resultados interpretables que permiten entender la relación entre las variables predictoras y el resultado deseado.

El análisis de la variable de hipertrofia muscular implica evaluar cómo cada característica recopilada influye en la probabilidad de desarrollar hipertrofia. Mediante la Regresión Logística, se calculan coeficientes de regresión para determinar la dirección y

magnitud del efecto de cada variable independiente. Además, se utilizan pruebas estadísticas para determinar la significancia de cada variable en la predicción de hipertrofia muscular, empleando un umbral de valor p para establecer la importancia estadística.

En el caso de Random Forest, se evalúa la importancia de cada característica según la reducción de impurezas en los nodos de los árboles de decisión, destacando las características más influyentes en la clasificación de hipertrofia muscular.

Este enfoque analítico permite identificar y comprender las características determinantes para predecir la hipertrofia muscular, contribuyendo así a decisiones informadas en el ámbito del entrenamiento y la salud física.

Conclusiones

Después de una minuciosa revisión de los datos y una inmersión en la literatura especializada sobre hipertrofia muscular, se llegan a algunas conclusiones fundamentales. En primer lugar, queda claro que la ciencia de datos desempeña un papel esencial al desvelar la complejidad de los factores que impactan el crecimiento muscular en atletas de élite. Al analizar detenidamente conjuntos de datos, se obtiene una visión objetiva y profunda de cómo variables como el tipo de ejercicio, la intensidad y el volumen inciden en el proceso de hipertrofia. Además, se observa que ciertos ejercicios y protocolos de entrenamiento tienen un impacto notable en la estimulación del crecimiento muscular. Por ejemplo, los movimientos compuestos que involucran varios grupos musculares parecen ser más efectivos que los ejercicios de aislamiento para fomentar la hipertrofia. Esto subraya la importancia de diseñar programas de entrenamiento que optimicen la selección y ejecución de ejercicios para alcanzar los mejores resultados en términos de crecimiento muscular.

Por último, este análisis permite comprender mejor la complejidad y la interrelación de los factores que influyen en el crecimiento muscular. Aunque aún quedan preguntas por responder, esta investigación acerca a una comprensión más completa de los determinantes clave de la hipertrofia muscular en atletas y personas del común. Este conocimiento es inestimable para informar futuras investigaciones y orientar el diseño de programas de entrenamiento más efectivos y personalizados. Además, en el marco de esta investigación, el modelo predictivo juega un papel crucial al proporcionar una herramienta cuantitativa para anticipar y comprender mejor el crecimiento muscular en atletas y

personas del común. La aplicación de técnicas de ciencia de datos, como la regresión logística, permite analizar la relación entre diversas variables predictoras y la probabilidad de hipertrofia muscular. Al integrar datos específicos de entrenamiento, nutrición y características personalizadas de los individuos, el modelo predictivo puede identificar patrones y tendencias que ayudan a prever el éxito de un programa de entrenamiento en términos de crecimiento muscular. Esta capacidad predictiva es inestimable para optimizar la planificación del entrenamiento y adaptar las estrategias según las necesidades individuales de cada persona, lo que a su vez puede mejorar significativamente el rendimiento deportivo y la efectividad de los programas de acondicionamiento físico. El modelo predictivo no solo complementa la comprensión de los factores que influyen en la hipertrofia muscular, sino que también ofrece una guía práctica para el diseño de programas de entrenamiento más efectivos y personalizados.

Referencias

- Albarrán Jardón, E. R. (2020). Inteligencia Deportiva: Tecnología Aplicada al Deporte. *Revista Pensamiento Libre*. México. Recuperado de <http://hdl.handle.net/20.500.11799/110390>
- Barber, D. C., & Phillips, S. M. (2022). Predicción de la Hipertrofia Muscular en la Distrofia Muscular de Duchenne Utilizando Aprendizaje Automático y Resonancia Magnética. *Revista Nature Medicine*. Estados Unidos. Recuperado de https://tsapps.nist.gov/publication/get_pdf.cfm?pub_id=935913
- Brunengo, A. (2023). BIG DATA E INTELIGENCIA ARTIFICIAL APLICADO AL RUBRO DEPORTIVO. Tesis de investigación. Argentina. Recuperado de <https://repositorio.uesiglo21.edu.ar/handle/ues21/26773>
- Díaz-Curiel, M., Rodríguez-Romo, F. J., & Martínez-Amat, A. (2020). Crecimiento muscular, estableciendo una base sólida para futuros desarrollos en el campo. *Revista de Entrenamiento y Nutrición Deportiva*, 15(2), 45-55.
- Effects of Low- vs. High-Load Resistance Training on Muscle Strength and Hypertrophy in Well- Trained Men. Schoenfeld BJ, Peterson MD, Ogborn D, Contreras B, Sonmez GT. 2015
- Fisiología del Ejercicio. (s.f.). Influencia de la carga de entrenamiento de fuerza en la hipertrofia y fuerza máxima. *Fisiología del Ejercicio*. Recuperado de <https://www.fisiologiadelejercicio.com/influencia-de-la-carga-de-entrenamiento-de-fuerza- en-la-hipertrofia-y-fuerza-maxima/>

Haff, G. G., & Triplett, N. T. (2016). *Essentials of Strength Training and Conditioning* (4th ed.).

Human Kinetics.

Kennet, R. (2019). Redes neuronales para análisis de datos genéticos. *Nature*, 589(7841), 124-132.

Recuperado de <https://www.nature.com/articles/s41598-019-44416-8>

Kraemer, W. J., & Ratamess, N. A. (2004). *Fundamentals of Resistance Training: Progression and Exercise Prescription*. Human Kinetics.

Martínez José, J. M. (2018). Sistema de Visión Artificial para la Detección y Corrección de Posturas en Ejercicios realizados por Fisicoculturistas. Repositorio institucional RI. Recuperado de <http://hdl.handle.net/20.500.11799/95190>

McCarthy, J. J., & Esser, K. A. (2007). MicroRNA-1 and microRNA-133a expression are decreased during skeletal muscle hypertrophy. *Journal of Applied Physiology*. <https://www-webofscience-com.bibliotecavirtual.unad.edu.co/wos/woscc/full-record/WOS:000243600300043>

McElliott, M. C., Al-Suraimi, A., Telang, A. C., Ference-Salo, J. T., Chowdhury, M., Soofi, A., Dressler, G. R., & Beamish, J. A. (2023). High-throughput image analysis with deep learning captures heterogeneity and spatial relationships after kidney injury. *Nature Research*. <https://www-scopus-com.bibliotecavirtual.unad.edu.co/record/display.uri?eid=2-s2.0->

85152978153&origin=resultslist&sort=plf-
 f&src=s&sid=5f6bac9ab488b50d3d8b882881a1aba4&sot=b&sdt=b&s=TITL
 E-ABS-
 KEY%28Highthroughput+image+analysis+with+deep+learning+captures+het
 erogeneity+and+spatial+relationships+after+kidney+injury%29&sl=133&sessi
 onSearchId=5f6bac9ab488b50d3d8b88 2881a1aba4

Moon, J., Posada-Quintero, H. F., & Chon, K. H. (2023). Genetic data visualization
 using literature text-based neural networks. Elsevier Ltd.. Recuperado de
[https://www-scopus-
 com.bibliotecavirtual.unad.edu.co/record/display.uri?eid=2-s2.0-
 85163009078&origin=resultslist&sort=plf-
 f&src=s&sid=8f6122a6cd8976f01cd8fa1ba302031c&sot=b&sdt=b&s=TITLE-
 ABS- KEY%28Genetic+data+visualization+using+literature+text-
 based+neural+networks%29&sl=85&sessionSearchId=8f6122a6cd8976f01cd8f
 a1ba30203 1c](https://www-scopus-com.bibliotecavirtual.unad.edu.co/record/display.uri?eid=2-s2.0-85163009078&origin=resultslist&sort=plf-f&src=s&sid=8f6122a6cd8976f01cd8fa1ba302031c&sot=b&sdt=b&s=TITLE-ABS-KEY%28Genetic+data+visualization+using+literature+text-based+neural+networks%29&sl=85&sessionSearchId=8f6122a6cd8976f01cd8fa1ba30203 1c)

Norton, L. E., & Layman, D. K. (2006). Leucine regulates translation initiation of
 protein synthesis in skeletal muscle after exercise. *The Journal of Nutrition*,
 136(2), 533S–537S.

Ono, T., Denda, R., Tsukahara, Y., Nakamura, T., Okamoto, K., Takayanagi, H., &
 Nakashima,

T. (2022). Simultaneous augmentation of muscle and bone by
 locomimeticism through calcium-PGC-1 α signaling. Springer Nature.

<https://www-scopus-com.bibliotecavirtual.unad.edu.co/record/display.uri?eid=2-s2.0-85135226731&origin=resultslist&sort=plf-f&src=s&sid=7feb78b984adabeb17c3b90178135bc5&sot=b&sdt=b&s=TITL E-ABS-KEY%28Simultaneous+augmentation+of+muscle+and+bone+by+locomomim etism+throu gh+calcium-PGC-1%CE%B1+signaling%29&sl=110&sessionSearchId=7feb78b984adabeb17c3 b90178135b c5>

Phillips, S. M., & Van Loon, L. J. (2011). Dietary protein for athletes: From requirements to optimum adaptation. *Journal of Sports Sciences*, 29(S1), S29–S38.

Rivera Bedoya, L. A., & Sanchez Zapata, C. A. (2020). Diseño de un algoritmo de redes neuronales artificiales para la elaboración de planes de acondicionamiento físico personalizados. *Biblioteca digital Universidad del Valle*. Recuperado de <https://hdl.handle.net/10893/21205>

Refalo, M. C., Hamilton, D. L., Paval, D. R., Gallagher, I. J., Feros, S. A., & Fyfe, J. J. (2021).

Influence of resistance training load on measures of skeletal muscle hypertrophy and improvements in maximal strength and neuromuscular task performance: A systematic review and meta-analysis. *Journal of Sports Sciences*. [En prensa]. <https://www-webofscience-com.bibliotecavirtual.unad.edu.co/wos/woscc/full->

- record/WOS:000641524800001
- Rezola, I. (2023). ¿Cómo mejorar la recuperación después del deporte con comida? Deportes.com. Recuperado de <https://saludpersonalizada.com/como-mejorar-la-recuperacion-despues-del-deporte-con-comida/>
- Sánchez Palop, L. I., Magraner Llavador, L., Alcántara Alcover, E., & Laparra Hernández, J. (2020). Mejora de la salud y el rendimiento de deportistas a través de la aplicación de avances en técnicas de Inteligencia Artificial. Innovación Biomecánica. Recuperado de <https://riunet.upv.es/bitstream/handle/10251/169018/S%C3%81NCHEZ-PALOP?sequence=1>
- Schoenfeld, B. J., Peterson, M. D., Ogborn, D., Contreras, B., & Sonmez, G. T. (2015). Mostraron que 3x por semana produjo mayores ganancias en bíceps que 1x en hombres entrenados. *Journal of Strength and Conditioning Research*, 29(7), 1821-1829.
- Strength and Hypertrophy Adaptations Between Low- vs. High-Load Resistance Training: A Systematic Review and Meta-analysis. Schoenfeld. BJ, Grgic J, Ogborn D, Krieger JW. 2017
- The Muscle & Strength Pyramid: Entrenamiento. Eric Helms; Andy Morgan; Andrea Valdez.
- Traducido por: José Carlos de Francisco; Víctor Reyes; Alberto Álvarez. 2019
- Thomas, D. T., Erdman, K. A., & Burke, L. M. (2016). Position of the Academy of Nutrition and Dietetics, Dietitians of Canada, and the American College of Sports Medicine: Nutrition and Athletic Performance. *Journal of the*

Academy of Nutrition and Dietetics, 116(3), 501.

Time course of recovery following resistance training leading or not to failure.

Morán-Navarro R, Pérez CE, Mora-Rodríguez R, de la Cruz-Sánchez E,
González-Badillo JJ, Sánchez-Medina L, Pallarés JG. 2017

Tipton, K. D., & Wolfe, R. R. (2004). Protein and amino acids for athletes. *Journal of Sports Sciences*, 22(1), 65–79.

Weber, K. A., Smith, A. C., Wasielewski, M., Eghtesad, K., Upadhyayula, P. A.,
Wintermark, M., Hastie, T. J., Parrish, T. B., Mackey, S., & Elliott, J. M.
(2019). Deep learning convolutional neural networks for the automatic
quantification of muscle fat infiltration following whiplash injury.
Scientific Reports, 9(1), 7973. Nature Publishing Group UK.
<https://doi.org/10.1038/s41598-019-44416-8>

Zhang, R. Y. (2022). Digital Media Teaching and Effectiveness Evaluation
Integrating Big Data and Artificial Intelligence. *Inteligencia
Computacional y Neurociencia*. Recuperado de [https://www-webofscience-
com.bibliotecavirtual.unad.edu.co/wos/woscc/full-
record/WOS:000864057200013](https://www-webofscience-com.bibliotecavirtual.unad.edu.co/wos/woscc/full-record/WOS:000864057200013)

[https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0719-
40132022000100203](https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0719-40132022000100203)

haves y Carlson

Apéndices

Apéndice A

Algoritmo de regresión logística-parte a

```
import pandas as pd
from sklearn.preprocessing import StandardScaler

# Leer los datos
data = pd.read_csv('base_de_datos_hipertrofia.csv')

# Seleccionar características y variable objetivo
X = data[['Entrenamiento (días/semana)', 'Duración de entrenamiento (minutos)',
          'Calorías diarias', 'Proteínas diarias (g/kg)', 'Edad']]
y = data['Hipertrofia Muscular']

# Escalar las características para mejorar el rendimiento del modelo
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)

# Entrenar el modelo de regresión logística
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import accuracy_score, classification_report, confusion_matrix

# Dividir los datos en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y, test_size=0.2, random_state=42)

# Crear y entrenar el modelo de regresión logística
model = LogisticRegression()
model.fit(X_train, y_train)
```

Fuente. Elaboración propia, jupyter Notebook, Anexo A

Apéndice B

Algoritmo de regresión logística-parte b

```
# Solicitar al usuario que ingrese los datos
nombre = input("Nombre: ")
dias_entrenamiento = int(input("Entrenamiento (días/semana): "))
duracion_entrenamiento = int(input("Duración de entrenamiento (minutos): "))
calorias_diarias = float(input("Calorías diarias: "))
proteinas_diarias = float(input("Proteínas diarias (g/kg): "))
edad = int(input("Edad: "))

Nombre: Daniel
Entrenamiento (días/semana): 1
Duración de entrenamiento (minutos): 11
Calorías diarias: 2
Proteínas diarias (g/kg): 2
Edad: 45

# Escalar los datos ingresados por el usuario
input_data = scaler.transform([[dias_entrenamiento, duracion_entrenamiento, calorias_diarias, proteinas_d

C:\Users\Usuario\anaconda3\lib\site-packages\sklearn\base.py:464: UserWarning: X does not have valid feature names, but StandardScaler
fitted with feature names
warnings.warn(

# Predecir si es favorable o no para desarrollar hipertrofia muscular
prediction = model.predict(input_data)
```

Fuente. Elaboración propia, jupyter Notebook, Anexo B

Apéndice C

Algoritmo de regresión logística-parte c

```
# Imprimir el resultado
if prediction == 1:
    print(f"{nombre} es favorable para desarrollar hipertrofia muscular.")
else:
    print(f"{nombre} no es favorable para desarrollar hipertrofia muscular.")

daniel no es favorable para desarrollar hipertrofia muscular.
```

Fuente. Elaboración propia, jupyter Notebook, Anexo C