



doctor
KNOWMAD
rōnin del conocimiento

by Robert Usach, PhD.

8

METODOLOGÍA DE INVESTIGACIÓN, IMUs, IA & ML

1

**Metodología de Investigación en
Biomecánica Deportiva**

2

**Validación de datos y consideraciones
técnicas en el uso de IMUs y
acelerómetros en biomecánica**

3

**Implementación de IA/ML con
Sensores Inerciales para Análisis de
Dominadas en Biomecánica Deportiva**

1

Metodología de Investigación en Biomecánica Deportiva



Glosario de términos técnicos

- **Captura de movimiento optoelectrónica:** sistema de medición del movimiento que utiliza cámaras (normalmente infrarrojas) y marcadores reflectantes colocados en el cuerpo. Las cámaras detectan la posición 3D de cada marcador en cada instante, permitiendo reconstruir la posición y ángulos de las partes del cuerpo con alta precisión. Es considerado un “estándar de oro” en biomecánica por su exactitud.
- **Fiabilidad (confiabilidad):** grado en el que una medición o un procedimiento produce resultados consistentes al repetirse en condiciones similares. Una prueba altamente fiable dará valores casi iguales si se repite pronto sin cambios reales en el sujeto. Se cuantifica con estadísticas como el coeficiente de correlación intraclass (ICC) o el error típico (desviación estándar de las diferencias entre mediciones repetidas).
- **IMU (Unidad de Medida Inercial):** dispositivo electrónico que combina típicamente un acelerómetro (mide aceleraciones lineales), un giroscopio (mide velocidades de rotación) y a veces un magnetómetro (mide el campo magnético) para estimar movimientos y orientación en 3D. Del inglés Inertial Measurement Unit. Son pequeños sensores portátiles utilizados en smartphones, drones y wearables deportivos para registrar el movimiento del cuerpo sin necesidad de cámaras externas. Varios IMUs colocados en segmentos corporales pueden usarse juntos para obtener la postura completa de una persona en movimiento mediante algoritmos de fusión sensorial.
- **Independent variable / Dependent variable (Variable independiente / dependiente):** en un experimento, la variable independiente es la que el investigador manipula o clasifica (p. ej., aplicar un tipo de entrenamiento, o comparar hombres vs. mujeres), mientras que la variable dependiente es el resultado medido que puede cambiar en respuesta (p. ej., la mejora en la técnica, el ángulo alcanzado, etc.). La dependiente “depende” de la independiente. Controlar la independiente (por ejemplo, quién entrena cómo) y observar cambios en la dependiente permite probar hipótesis causales.
- **Operacionalizar:** proceso de definir cómo se medirá un concepto abstracto en la práctica. Implica decidir los indicadores o variables observables que representarán ese concepto. Por ejemplo, operacionalizar “habilidad técnica” podría hacerse a través de ciertas métricas biomecánicas (precisión angular, estabilidad, etc.). Es un paso clave para convertir una idea en datos medibles.
- **Validez:** grado en que algo mide o refleja realmente lo que se pretende. Hay varios tipos:
 - **Validez de medición:** si un instrumento o método mide correctamente el valor verdadero (ej. una báscula válida da el peso real, un sensor válido da la aceleración real). Involucra exactitud y poca sesgo.
 - **Validez interna:** si un estudio está bien diseñado de forma que permite atribuir los resultados a las causas investigadas, sin interferencia de factores externos no controlados.
 - **Validez externa:** si los resultados de un estudio son generalizables a otras poblaciones, contextos o situaciones fuera del experimento.
 - **Validez de constructo:** si las variables medidas reflejan adecuadamente el fenómeno teórico de interés (ej. que un “índice de calidad de movimiento” realmente represente la calidad técnica).
 - **Validez de contenido:** si se han incluido todos los aspectos relevantes del concepto al medirlo (ej. para habilidad técnica en un deporte, considerar habilidad de pies, tronco y manos, no solo un aspecto).

• **Velocidad propulsiva media (MPV):** promedio de la velocidad durante la fase concéntrica (de empuje o tracción) de un movimiento, generalmente referido al levantamiento de pesas o ejercicios de fuerza. En el contexto de dominadas, podría adaptarse a la velocidad media de elevación del cuerpo en la subida. Es una métrica utilizada para cuantificar intensidad de esfuerzo; en halterofilia y entrenamiento de fuerza se usa mucho, por ejemplo, la MPV de un press de banca. Se mide en m/s. Una MPV más alta suele indicar un movimiento explosivo o poderoso, mientras que decrementos en MPV a través de repeticiones indican fatiga.

• **Coeficiente de correlación intraclass (ICC):** estadístico que evalúa cuánto concuerdan medidas del mismo sujeto bajo condiciones repetidas. Muy usado para la fiabilidad. Un $ICC = 1.0$ significa concordancia perfecta, 0 significa concordancia nula (solo variación aleatoria). Se interpreta comúnmente: <0.5 pobre, 0.5-0.75 moderada, 0.75-0.9 buena, >0.9 excelente fiabilidad (aunque rangos varían según autores). Se llama “intraclass” porque compara la variabilidad dentro del sujeto vs. entre sujetos; a diferencia de correlaciones de Pearson, considera también las diferencias en nivel medio.

• **Typical error / Error típico de medida:** desviación estándar de las diferencias entre mediciones repetidas en la misma condición. Representa el “ruido” aleatorio inherente a la medición. Se suele expresar también como coeficiente de variación (CV%) dividiendo ese error típico por el valor medio de la medición. Un error típico bajo implica que un solo valor medido está muy cerca del valor “verdadero” del individuo en esa condición.

• **Bland-Altman (gráfico o límites):** método para evaluar acuerdo entre dos técnicas de medición, plotteando la diferencia entre métodos (o entre test y retest) contra su promedio. Proporciona “límites de acuerdo” que son la media de las diferencias ± 1.96 desviaciones estándar. Si estos límites son estrechos y cerca de cero, las mediciones concuerdan bien. Es útil para verificar sesgos sistemáticos (si la media de diferencias se desvía de cero) y para visualizar heterogeneidad en el error (p. ej., si el error aumenta con el valor medido).

• **Análisis cinemático:** estudio del movimiento sin considerar las fuerzas, centrado en variables de posición, velocidad y aceleración de las partes del cuerpo. En técnica deportiva, el análisis cinemático implica registrar cómo se mueven los segmentos (trayectorias, ángulos en función del tiempo) durante el gesto atlético. Por ejemplo, la cinemática de una patada incluiría el ángulo de rodilla vs. tiempo, la velocidad del pie, etc. Es complementario al análisis cinético que trata fuerzas (que aquí no hemos detallado pero también es parte de biomecánica).

• **Confiabilidad intra/inter evaluador:** ver fiabilidad intra-observador e inter-observador arriba. Son medidas de cuán consistente es un mismo evaluador consigo mismo y cuán consistente es con otros evaluadores respectivamente en la medición de ciertos datos.



Formulación de preguntas de investigación



Pregunta clara y precisa

Define exactamente qué aspecto de la técnica deportiva se estudiará y en qué contexto específico.



Enfoque específico

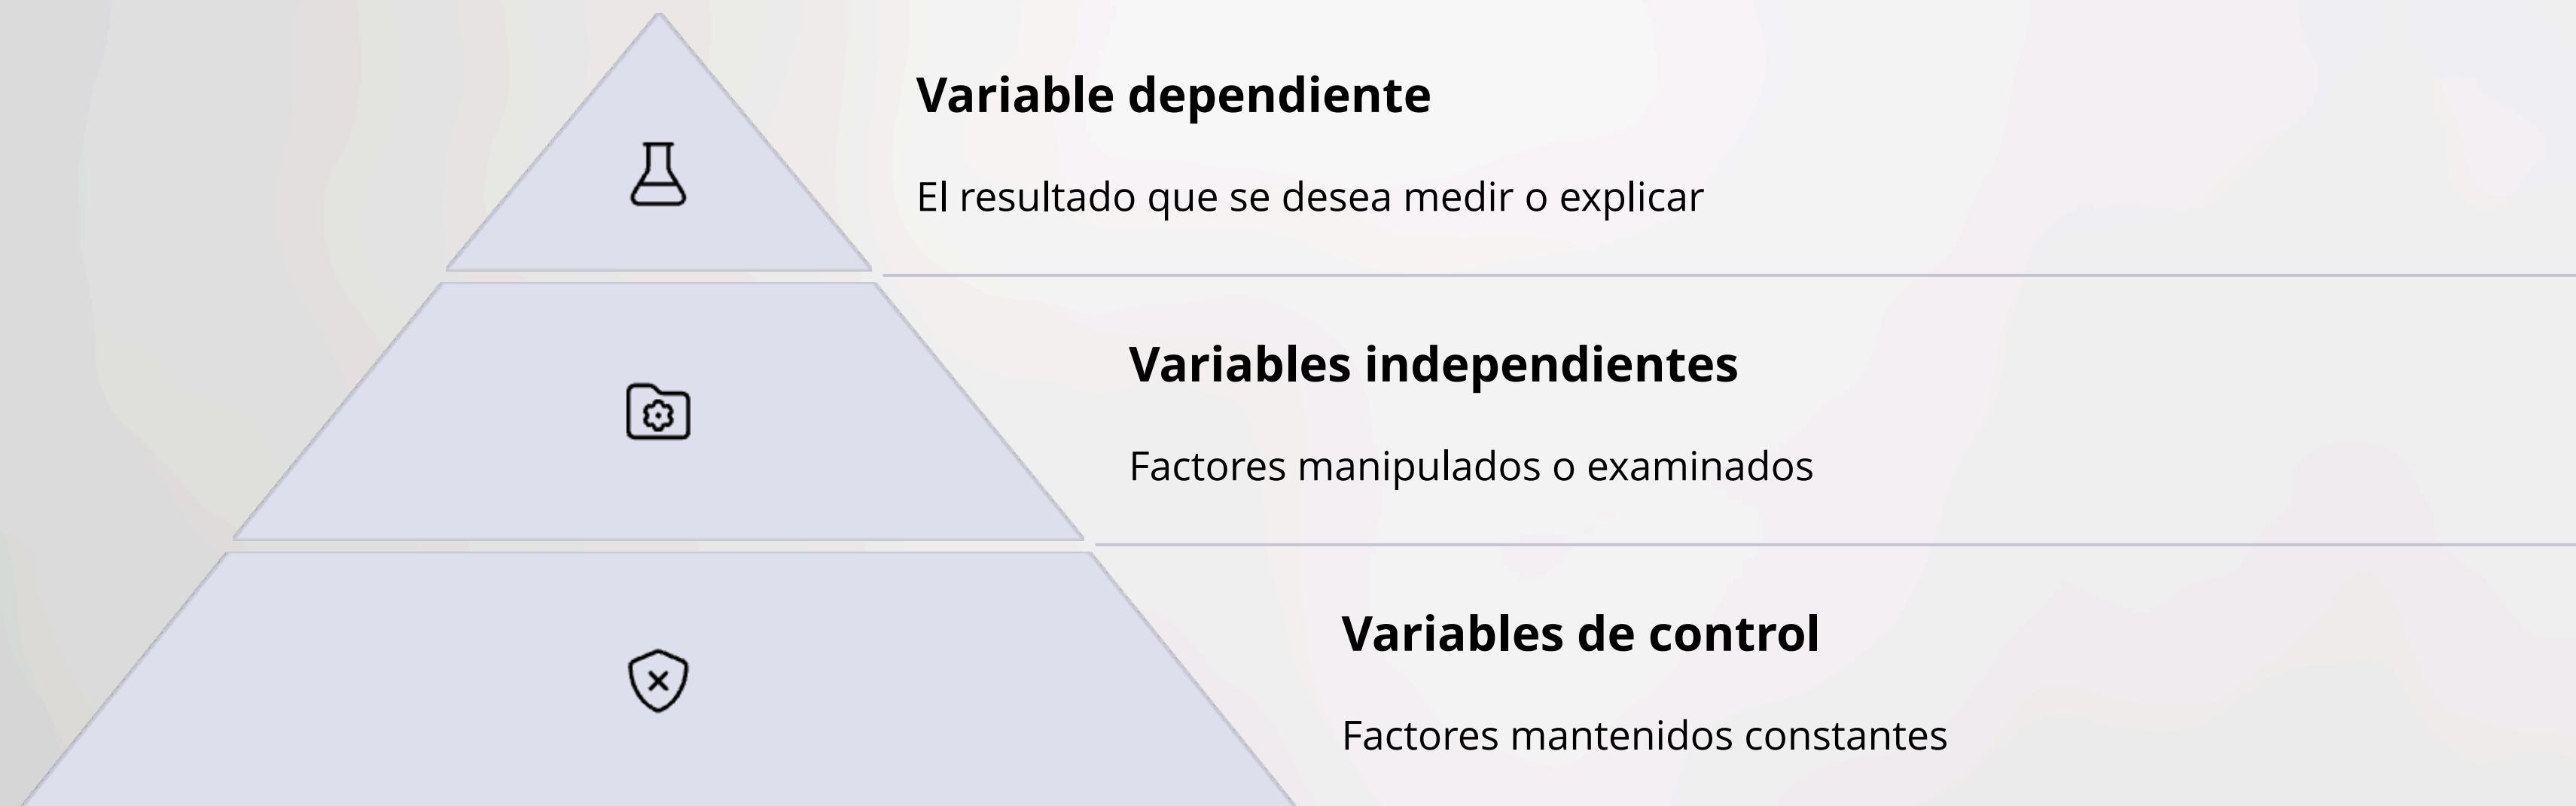
Por ejemplo: "¿Cómo afecta la fatiga muscular a la técnica de la dominada?"



Dirección clara

Una buena pregunta orienta todo el diseño metodológico y la recolección de datos.

Variables en la investigación biomecánica



Variable dependiente en dominadas

Rango de movimiento

Amplitud alcanzada durante la ejecución de la dominada, medida en grados o centímetros.

Velocidad media

Rapidez con la que se ejecuta la fase concéntrica, medida en metros por segundo.

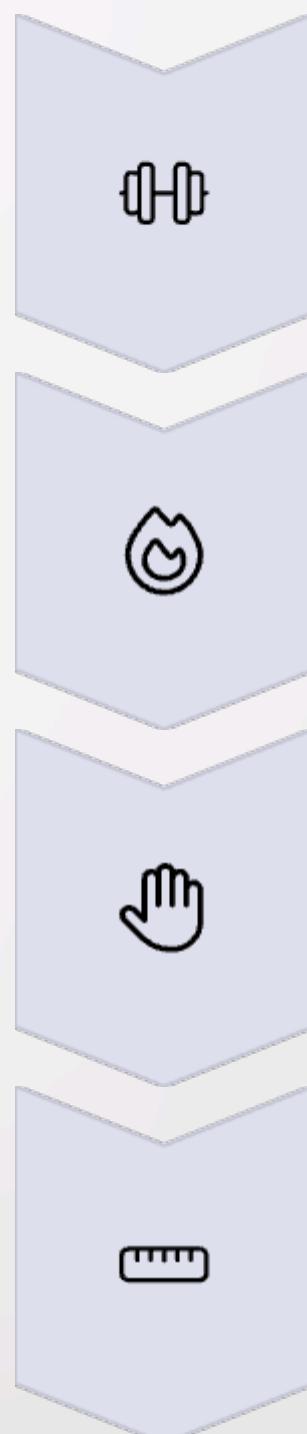
Ángulos articulares

Posiciones específicas de hombros, codos y muñecas durante las fases del movimiento.

Número de repeticiones

Cantidad de dominadas correctas completadas según criterios establecidos.

Variables independientes en dominadas



Tipo de entrenamiento

Programa específico aplicado

Nivel de fatiga

Presente vs. ausente

Técnica de agarre

Prono, supino o neutro

Anchura del agarre

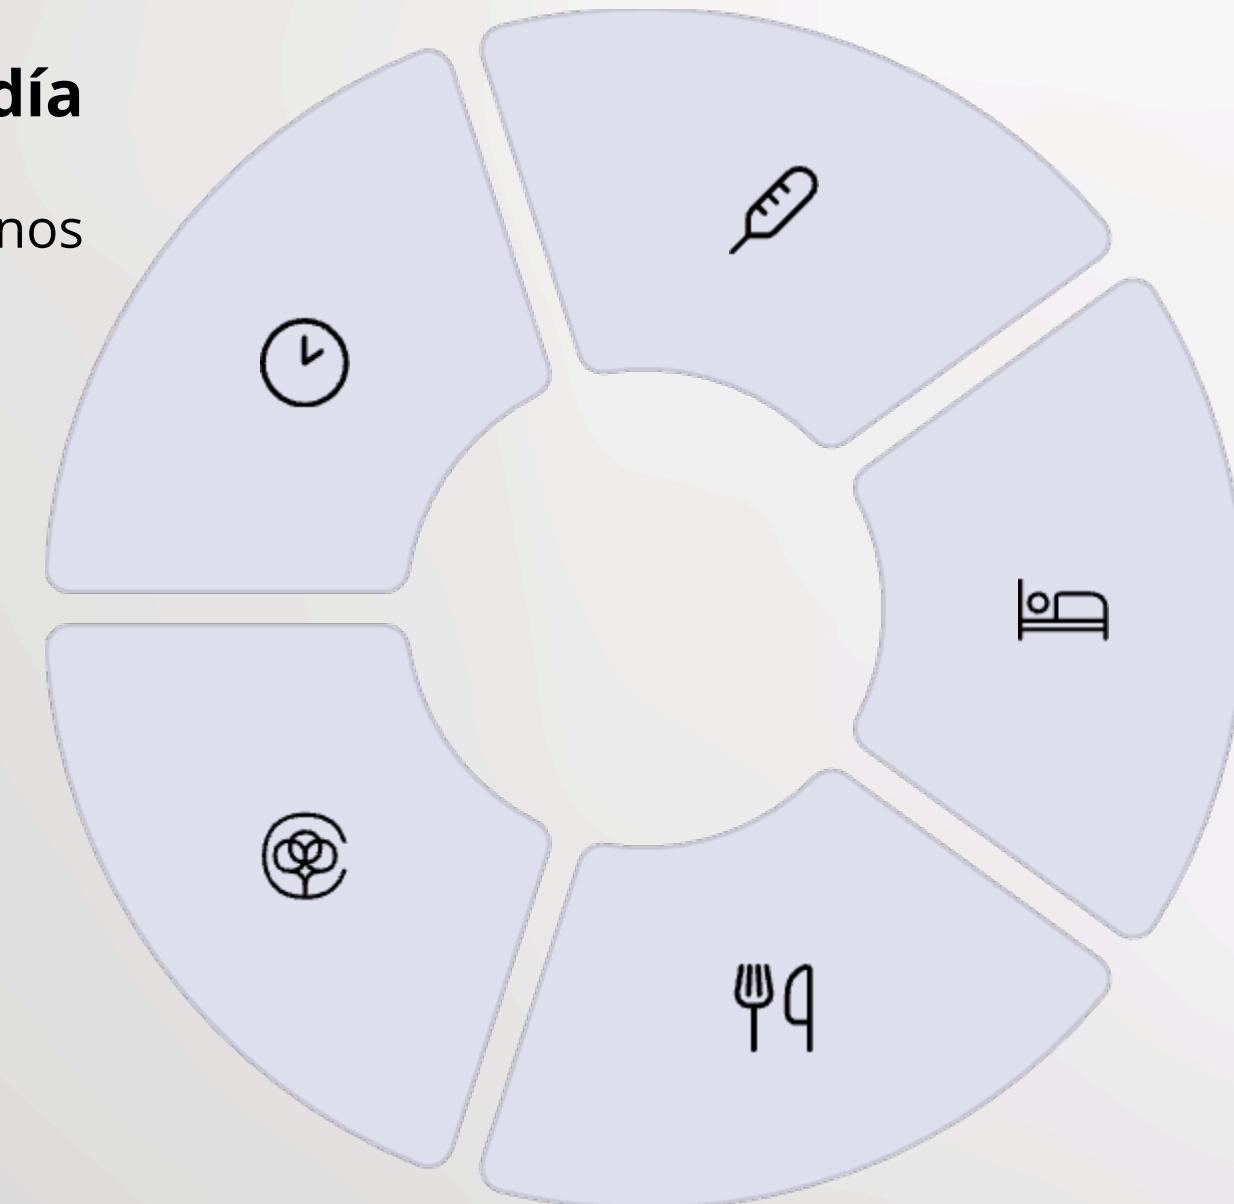
Estrecho, medio o ancho

Garavaglia et al. (2024)

Variables de control en dominadas

Garavaglia et al. (2024)

Hora del día
Control de efectos circadianos



Temperatura
Ambiente controlado

Descanso previo
Sin ejercicio intenso el día anterior

Alimentación
Tiempo desde última comida

Vestimenta
Ropa estandarizada

Operacionalización de variables

Identificar conceptos clave

Determinar qué aspectos de la técnica deportiva se medirán (ej. "calidad técnica de la dominada").

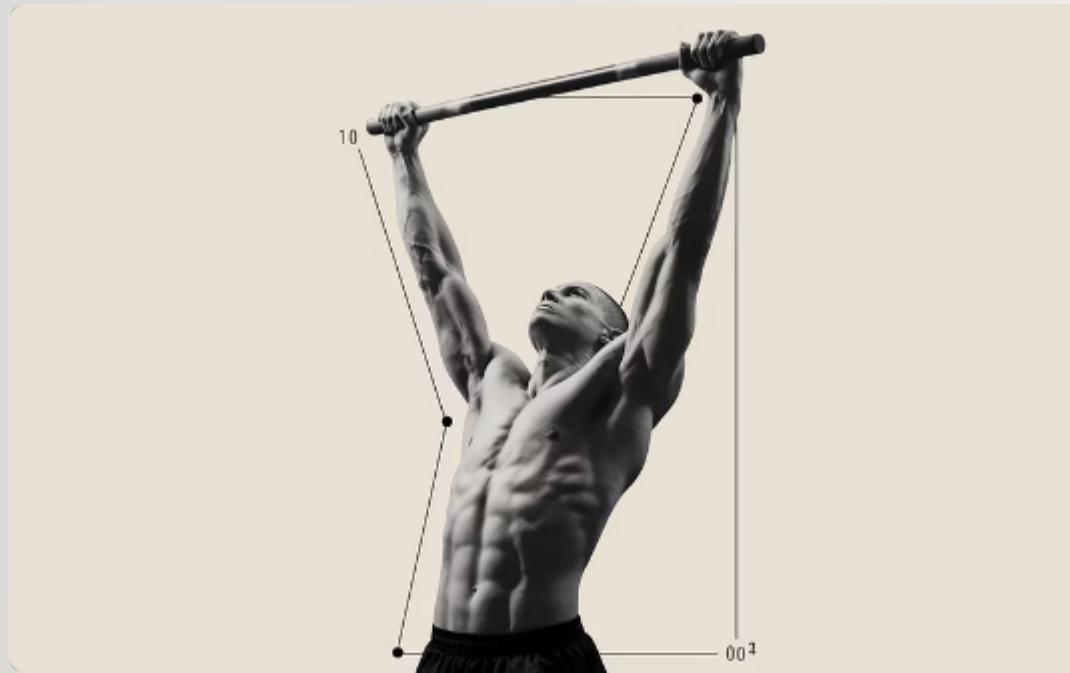
Definir indicadores medibles

Traducir conceptos abstractos en medidas concretas y observables (ej. ROM en hombros y codos).

Establecer unidades y métodos

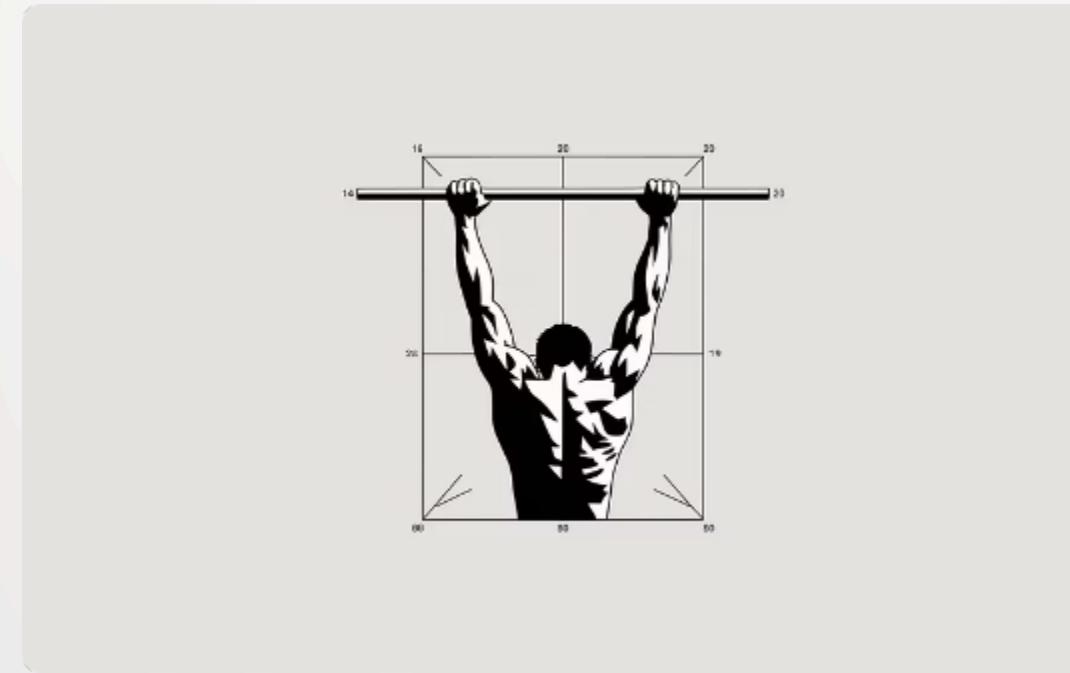
Especificar cómo se medirá cada variable, con qué instrumentos y en qué unidades.

Criterios objetivos: Rango de movimiento



Extensión completa

Brazos totalmente extendidos en la posición inferior. Ángulo de codo cercano a 180°.



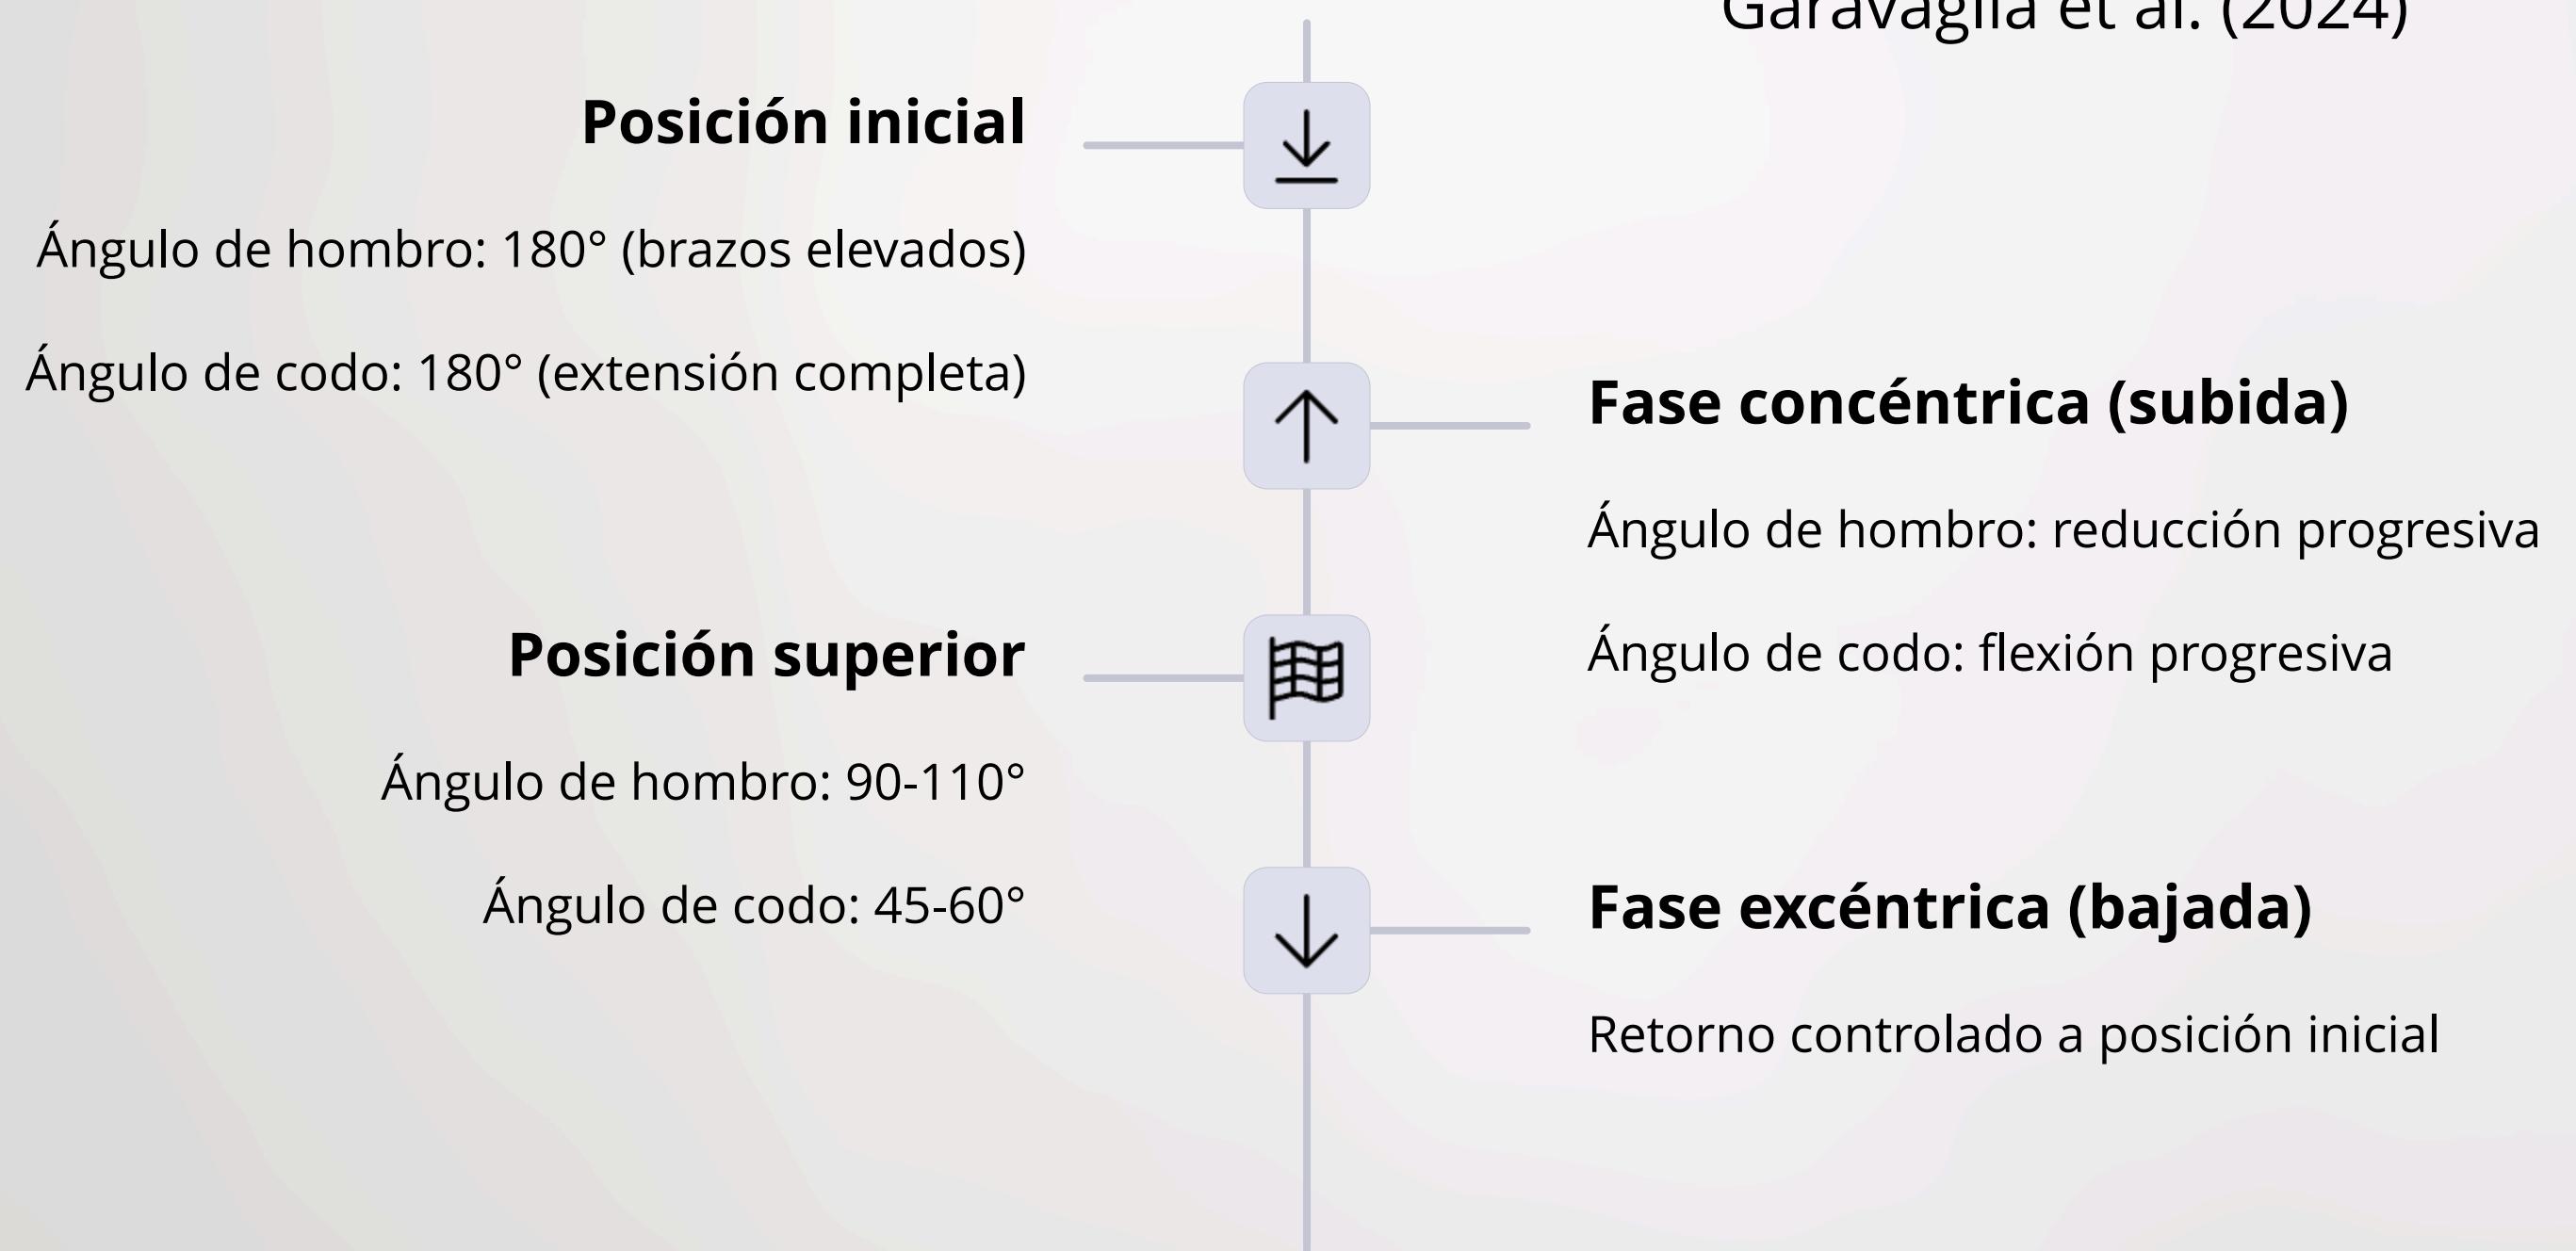
Flexión máxima

Barbilla por encima de la barra en la posición superior. Ángulo de codo entre 45-60°.



Criterios objetivos: Ángulos clave por fase

Garavaglia et al. (2024)



Criterios objetivos: Parámetros cinemáticos

Velocidad

- Velocidad media concéntrica: 0,5-0,7 m/s
- Velocidad pico: 0,8-1,2 m/s
- Velocidad propulsiva media (MPV)

Aceleración

- Aceleración vertical del centro de masa
- Aceleraciones angulares de segmentos
- Jerk (cambios bruscos de aceleración)

Trayectoria

- Linealidad del movimiento vertical
- Desviaciones laterales
- Suavidad de la curva de movimiento

Criterios objetivos: Detección de eventos

Inicio del movimiento

Velocidad vertical > 0,05 m/s

Fase concéntrica completa

Barbilla supera el nivel de la barra

Cambio de fase

Velocidad vertical = 0 m/s

Repetición válida

Cumplimiento de todos los criterios técnicos

Índices compuestos de técnica

Garavaglia et al. (2024)

Medición de parámetros

Registro de múltiples variables biomecánicas

Ponderación de factores

Algoritmo que integra múltiples aspectos



Comparación con rangos óptimos

Derivados de ejecuciones de atletas expertos

Cálculo de puntuaciones

Porcentaje de cercanía al rango ideal

Tecnologías para análisis de movimiento

Las tecnologías modernas permiten capturar el movimiento con alta precisión. Sistemas ópticos, sensores iniciales, plataformas de fuerza y modelado 3D proporcionan datos complementarios para análisis integral.

Sistemas de captura de movimiento ópticos

0.1mm

Precisión espacial

Exactitud submilimétrica en la posición de marcadores

120Hz

Frecuencia típica

Capturas por segundo en sistemas estándar

6-12

Cámaras necesarias

Para captura completa de movimiento en 3D

54

Marcadores reflectantes

Utilizados en estudios de dominadas (Garavaglia et al., 2024)

Sensores iniciales (IMU)



Portabilidad

Pequeños dispositivos que pueden usarse fuera del laboratorio, ideales para mediciones en campo.



Componentes

Integran acelerómetros, giroscopios y magnetómetros para registrar movimiento en 3D.



Fusión sensorial

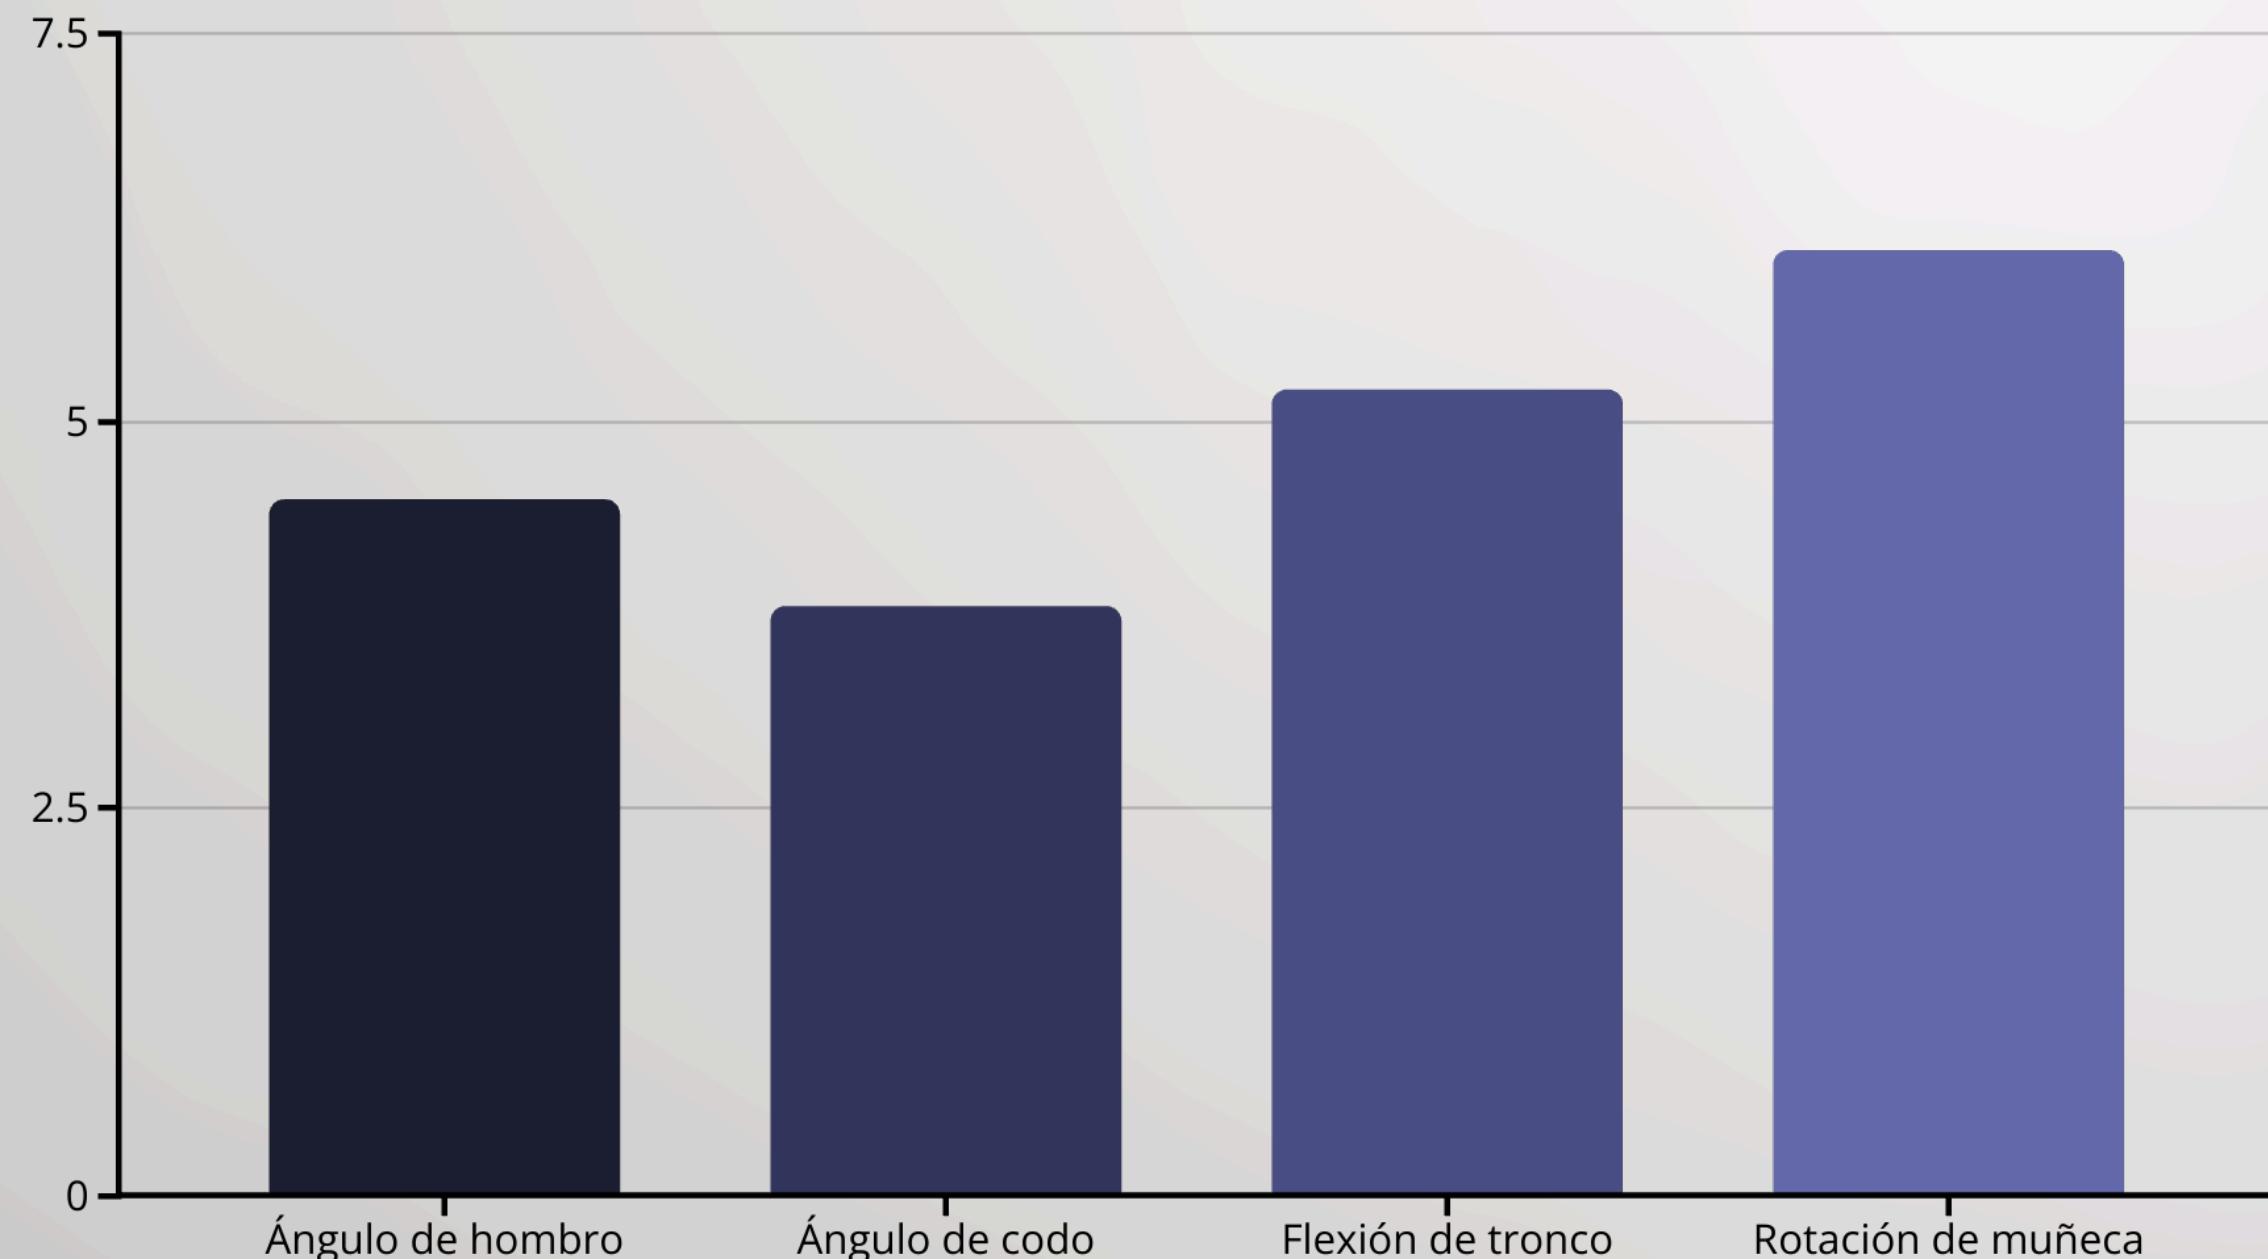
Algoritmos que combinan datos de múltiples sensores para estimar orientación precisa.



Autonomía

Funcionamiento inalámbrico durante horas para sesiones completas de entrenamiento.

Precisión de los sensores IMU



Los sensores IMU modernos muestran errores típicos de 4-6° comparados con sistemas ópticos. Presentan correlaciones de 0.95-0.99 con el gold standard en la mayoría de movimientos.

Diseño de protocolos experimentales

Tamaño muestral adecuado

Estudios metodológicos sugieren 30-50 sujetos para estimar fiabilidad con precisión. La mayoría de estudios utilizan 10-20 participantes.

Repeticiones suficientes

Múltiples ensayos por sujeto para obtener medidas representativas. Garavaglia et al. (2024) utilizaron series de 3 dominadas repetidas en dos ocasiones.

Estandarización rigurosa

Mismo entorno, equipamiento, instrucciones y calentamiento para todos los participantes. Control de variables extrañas.

Aleatorización y control

Orden aleatorio de condiciones para evitar efectos de aprendizaje o fatiga. Períodos de descanso estandarizados entre repeticiones.

Protocolo estandarizado para dominadas

Garavaglia et al. (2024)



Calentamiento

5 minutos de movilidad articular

3-5 dominadas submáximas



Preparación

Colocación de marcadores/sensores

Calibración del sistema



Ejecución

Series de 3 dominadas con técnica controlada

60 segundos de descanso entre series



Repetición

Segunda ronda tras 5 minutos de recuperación

Mismas condiciones que la primera

Validez en investigación biomecánica



Validez interna vs. externa

Validez interna

Grado en que podemos confiar en las relaciones causa-efecto dentro del estudio.

- Control riguroso de variables
- Aleatorización de condiciones
- Grupos control adecuados
- Cegamiento cuando sea posible

Validez externa

Grado en que los resultados son aplicables fuera del contexto del estudio.

- Representatividad de la muestra
- Realismo de las condiciones
- Aplicabilidad a situaciones reales
- Generalización a otras poblaciones

Fiabilidad en mediciones biomecánicas

Fiabilidad test-retest

Consistencia de mediciones repetidas en días diferentes

Fiabilidad intra-evaluador

Consistencia del mismo evaluador en análisis repetidos

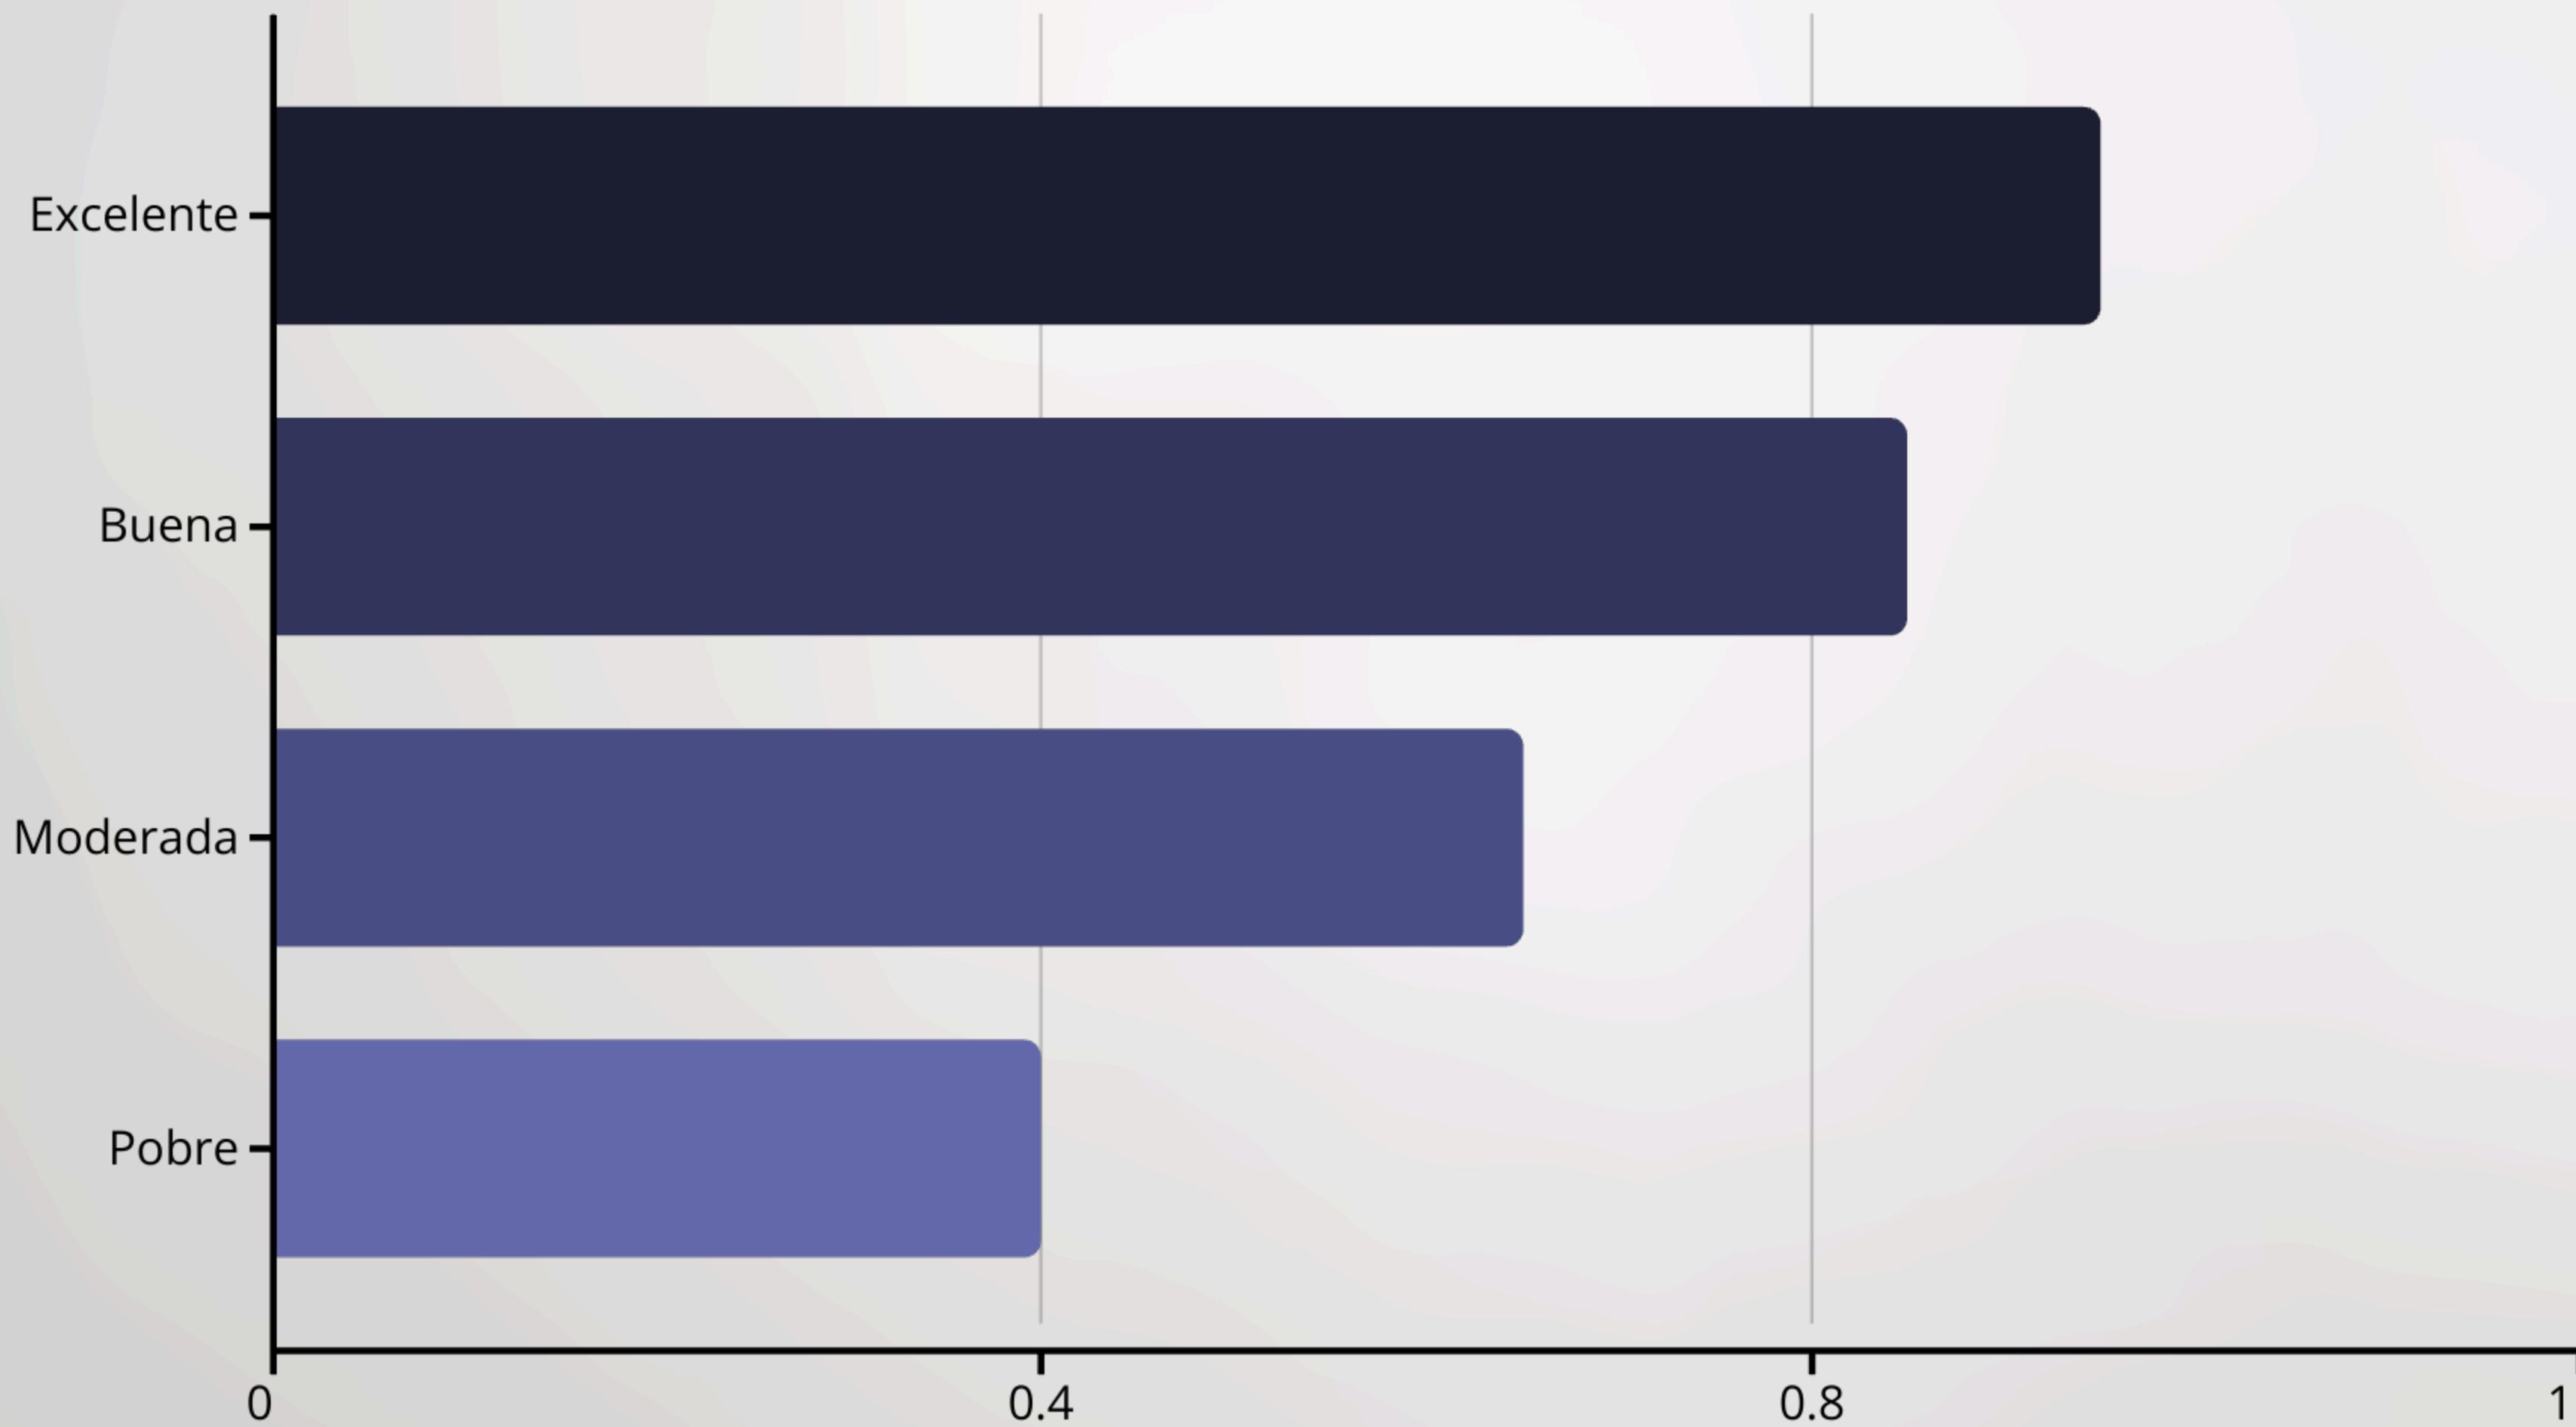
Fiabilidad inter-evaluador

Consistencia entre diferentes evaluadores

Fiabilidad del instrumento

Consistencia del aparato de medición

Coeficiente de correlación intraclass (ICC)



El ICC cuantifica la proporción de varianza total atribuible a diferencias entre sujetos. Valores cercanos a 1.0 indican alta fiabilidad.

Sordo-Vacas et al. reportaron ICC entre 0.73-0.96 para velocidad en dominadas.

Estudio de caso: Análisis de dominadas

Garavaglia et al. (2024)

Captura de movimiento

Sistema Vicon con 6 cámaras infrarrojas y 54 marcadores reflectantes en puntos anatómicos clave.

Modelado biomecánico

Reconstrucción 3D del movimiento con cálculo de 22 variables biomecánicas por fase.

Sistema de puntuación

Índices de rendimiento y seguridad basados en comparación con rangos óptimos de atletas expertos.

Resultados de investigación en dominadas

Parámetro	Principiantes	Intermedios	Expertos
ROM codo (grados)	110 ± 15	125 ± 10	135 ± 5
Velocidad media (m/s)	0.35 ± 0.1	0.45 ± 0.08	0.55 ± 0.05
Desviación tronco (grados)	12 ± 4	8 ± 3	4 ± 2
Asimetría brazos (%)	15 ± 5	10 ± 3	5 ± 2
Puntuación técnica (%)	65 ± 10	80 ± 8	92 ± 5



Conclusiones y aplicaciones prácticas



Metodología rigurosa

El análisis biomecánico requiere preguntas claras, variables bien definidas y protocolos estandarizados.



Criterios objetivos

ROM, ángulos articulares, velocidad y patrones de movimiento proporcionan medidas cuantificables de técnica.



Validez y fiabilidad

Fundamentales para garantizar conclusiones científicamente sólidas y aplicables al entrenamiento real.



Transferencia al entrenamiento

Los sistemas de puntuación técnica permiten feedback objetivo para mejorar el rendimiento y prevenir lesiones.

2

Validación de datos y consideraciones técnicas en el uso de IMUs y acelerómetros en biomecánica



Glosario de términos técnicos

- **IMU (Unidad de Medición Inercial):** Dispositivo electrónico que combina típicamente un acelerómetro triaxial, un giroscopio triaxial y opcionalmente un magnetómetro triaxial. Permite medir aceleraciones lineales, velocidades angulares y campo magnético en tres ejes ortogonales, a partir de lo cual se puede estimar la orientación y movimiento de un objeto o segmento corporal.
- **Acelerómetro:** Sensor que mide la aceleración lineal a lo largo de uno o más ejes. En las IMUs suelen ser MEMS capacitivos de tres ejes, midiendo la aceleración resultante (incluida la gravedad). Unidades: m/s^2 o "g" (donde $1 \text{ g} \approx 9.81 \text{ m/s}^2$).
- **Giroscopio:** Sensor que mide la velocidad de rotación (velocidad angular) alrededor de uno o más ejes. En IMUs se usan giroscopios MEMS que detectan la velocidad angular en $^\circ/\text{s}$ o rad/s .
- **Magnetómetro:** Sensor que mide la intensidad y dirección del campo magnético, usado para estimar orientación absoluta respecto al campo magnético terrestre (como una brújula). Suele expresarse en microteslas (μT). Su inclusión en IMUs permite corregir la deriva de orientación en el plano horizontal, aunque es propenso a interferencias por metales.
- **Kinovea:** Software de análisis de video 2D de uso libre, que permite extraer ángulos, posiciones y velocidades a partir de grabaciones de vídeo. En este contexto, se menciona como una herramienta de referencia (semi-manual) para validar mediciones de IMUs mediante el seguimiento de marcadores o puntos de referencia en grabaciones.
- **Vicon / OptiTrack:** Sistemas de captura de movimiento ópticos, considerados gold standard en biomecánica. Utilizan cámaras infrarrojas y marcadores reflectantes para reconstruir en 3D la posición de segmentos corporales con alta precisión (error típico $<1 \text{ mm}$ para posición, $<1^\circ$ para ángulos). Sirven como referencia para validar sistemas inerciales.
- **RMSE (Root Mean Square Error):** Raíz del error cuadrático medio. Métrica estadística que cuantifica la diferencia promedio (cuadrática) entre valores medidos por el IMU y valores de referencia. Un RMSE bajo indica alta precisión del sensor respecto al patrón.
- **ICC (Coeficiente de Correlación Intraclass):** Índice que evalúa la concordancia o fiabilidad entre mediciones. En validación de instrumentos, el ICC (generalmente en modelo de dos vías, tipo absolute agreement) cuantifica cuánto de la variabilidad total se debe a diferencias entre métodos vs. variabilidad residual. Los valores van de 0 a 1; >0.75 generalmente se considera adecuado, >0.90 excelente.
- **Correlación de Pearson (r):** Medida de asociación lineal entre dos conjuntos de datos. En este contexto, se usa para ver qué tanto las tendencias de la señal del IMU siguen a las del sistema de referencia. $r = 1$ sería correlación lineal perfecta (las señales tienen la misma forma, aunque puedan diferir en escala).

- **Bland-Altman (análisis o gráfica):** Método gráfico-estadístico para evaluar el acuerdo entre dos métodos de medida distintos. Muestra las diferencias contra el promedio de ambos métodos, permitiendo visualizar sesgo (diferencia media) y dispersión (límites de acuerdo, típicamente media $\pm 1.96 \times \text{SD}$). Es útil para detectar errores sistemáticos o si la discrepancia depende del valor medido.
- **Bias (sesgo):** Diferencia sistemática entre la medición del IMU y la referencia. Un bias positivo significa que el IMU mide consistentemente más alto que el estándar, y viceversa. Idealmente el bias debería ser cercano a 0 tras calibración.
- **Límites de acuerdo (LOA):** En Bland-Altman, son los límites dentro de los cuales caerá el ~95% de las diferencias entre métodos (usualmente calculados como bias ± 1.96 desviaciones estándar de las diferencias). Indican el rango de discrepancia esperable entre los dos métodos.
- **Lin's CCC (Coeficiente de Correlación de Concordancia de Lin):** Métrica que combina precisión y exactitud para evaluar concordancia entre dos métodos. Penaliza tanto desplazamientos (bias) como desviaciones de la línea identidad. Un CCC = 1 indica que las medidas del IMU caen exactamente sobre la línea ideal 1:1 contra la referencia.
- **Soft tissue artifact (artefacto de tejido blando):** Error introducido en la medición debido al movimiento relativo del sensor con respecto al hueso subyacente, causado por la deformación o desplazamiento de los tejidos blandos (músculo, grasa, piel) a los que está sujeto el sensor. Esto puede filtrar o amortiguar la señal verdadera del movimiento óseo.
- **Slippage (deslizamiento):** Movimiento no deseado del sensor desplazándose o rotando sobre la piel desde su posición inicial. Provoca que la orientación/posición del sensor ya no represente fielmente al segmento, introduciendo error.
- **Frecuencia de muestreo:** Número de muestras por segundo con que el IMU registra datos. Se mide en Hertz (Hz). Determina la resolución temporal de la captura; frecuencias bajas pueden perder eventos rápidos (aliasing), frecuencias excesivamente altas generan muchos datos redundantes y ruido.
- **Filtro (paso-bajo, paso-alto, etc.):** Herramienta digital para procesar la señal eliminando ciertas frecuencias. Paso-bajo deja pasar las bajas frecuencias (suaviza la señal removiendo ruido rápido), paso-alto deja pasar altas (remueve componente lenta, como gravedad), pasa-banda deja pasar un rango específico. Un filtro Butterworth es un tipo de filtro digital con respuesta suave (sin ondulaciones en banda pasante).
- **Calibración (de sensores):** Proceso de ajustar las lecturas del sensor para que correspondan a valores físicos reales. Incluye corregir bias (offset), escala (ganancia), alineación de ejes y a veces distorsión no lineal. Puede ser realizada por el fabricante o por el usuario mediante procedimientos específicos (p. ej., dejar el sensor quieto para calibrar el cero del giroscopio).
- **Test-retest:** Método para evaluar fiabilidad repitiendo exactamente el mismo procedimiento de medición en dos momentos diferentes. Si el resultado es igual (dentro del error esperado), se considera que el instrumento tiene buena fiabilidad test-retest.

- **Intraobservador / Interobservador:** Se refiere a la variabilidad debida al observador (quien realiza la medición). "Intraobservador" mira la consistencia de un mismo observador (operador) midiendo varias veces; "Interobservador" compara las mediciones hechas por diferentes observadores sobre el mismo fenómeno. Diferencias grandes indicarían falta de estandarización o aspectos subjetivos en la medición.
- **SEM (Standard Error of Measurement):** Desviación estándar de los errores de medición; se calcula a menudo como $SD * \sqrt{1-ICC}$. Indica en unidades de la variable, cuánto varía típicamente una medición repetida por error aleatorio.
- **CV (Coeficiente de Variación):** Desviación estándar expresada como porcentaje de la media. Útil para cuantificar variabilidad relativa de una medida. En fiabilidad, un CV bajo implica variabilidad relativa pequeña entre repeticiones.
- **SWC (Smallest Worthwhile Change):** Mínimo cambio relevante. En contexto deportivo, es la magnitud de cambio en una métrica que se considera relevante o beneficiosa. Se compara con el error de medición (SEM); si $SEM < SWC$, el instrumento puede detectar cambios significativos.
- **Filtro de Kalman:** Algoritmo recursivo de estimación óptima que fusiona múltiples fuentes de datos (acelerómetro, giroscopio, magnetómetro) considerando sus incertidumbres, para obtener una estimación refinada (por ej., orientación). Es común en sistemas comerciales de IMUs para proveer orientaciones suaves y sin deriva.



Ventajas de los sistemas IMU



Portabilidad

A diferencia de los sistemas ópticos tradicionales, los sensores inerciales son portátiles y ligeros.



Bajo costo

Representan una alternativa económica frente a sistemas como Vicon u OptiTrack.



Uso en campo abierto

Permiten evaluar movimientos reales en ambientes naturales sin restricciones de laboratorio.

Comparación con sistemas de referencia

Sistemas IMU

Portátiles y económicos

Medición en cualquier entorno

Requieren validación rigurosa

Sistemas ópticos (Gold Standard)

Alta precisión (error <1mm)

Limitados al laboratorio

Costosos y complejos

Sincronización temporal

Captura simultánea

Iniciar y detener ambos sistemas (IMU y referencia) al mismo tiempo.

Eventos conocidos

Usar un golpe o impacto visible en ambas señales como punto de referencia.

Correlación cruzada

Calcular la correlación entre señales para encontrar el desfase óptimo.

Ajuste de series temporales

Recortar inicio o final para igualar duración y fase temporal.

Alineación espacial



Alineación manual

Colocar el IMU con orientación conocida respecto al segmento corporal.

Calibración funcional

Realizar movimientos específicos para calcular transformaciones necesarias.

Referencia anatómica

Alinear el sensor con ejes anatómicos para mayor exactitud.

Métricas de validez

RMSE

Error cuadrático medio entre la serie del IMU y la referencia. Valores cercanos a cero indican alta precisión.

ICC

Coeficiente de correlación intraclass. Valores $> 0,75$ se consideran buenos, $> 0,90$ excelentes.

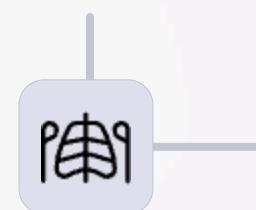
Correlación (r , R^2)

Evalúa relación lineal entre medidas. Valores $r > 0,9$ indican excelente concordancia lineal.

Bland-Altman

Análisis gráfico que visualiza sesgo sistemático y límites de acuerdo al 95%.

Ejemplos de validación



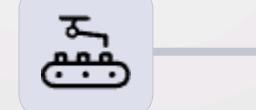
Hallbeck et al. (2017)

Compararon sistema de 6 IMUs con Vicon para medir ángulos de hombro, codo y tronco. Errores medios bajos ($2-8^\circ$).



Blandeau et al. (2022)

Validación en hexapodo robótico y con sujetos haciendo sentadillas. Alta precisión con CCC cerca de 0,99.



Validación de movimientos de brazo

Sensores mostraron correlaciones altas (r hasta 0,94) y ICC altos comparados con sistema óptico.

Colocación de sensores

Región lumbar (L5)

Ideal para aproximar el centro de masa y obtener datos integrales del tronco.

Esternón

Eficaz para capturar el movimiento vertical del cuerpo en ejercicios de tracción.

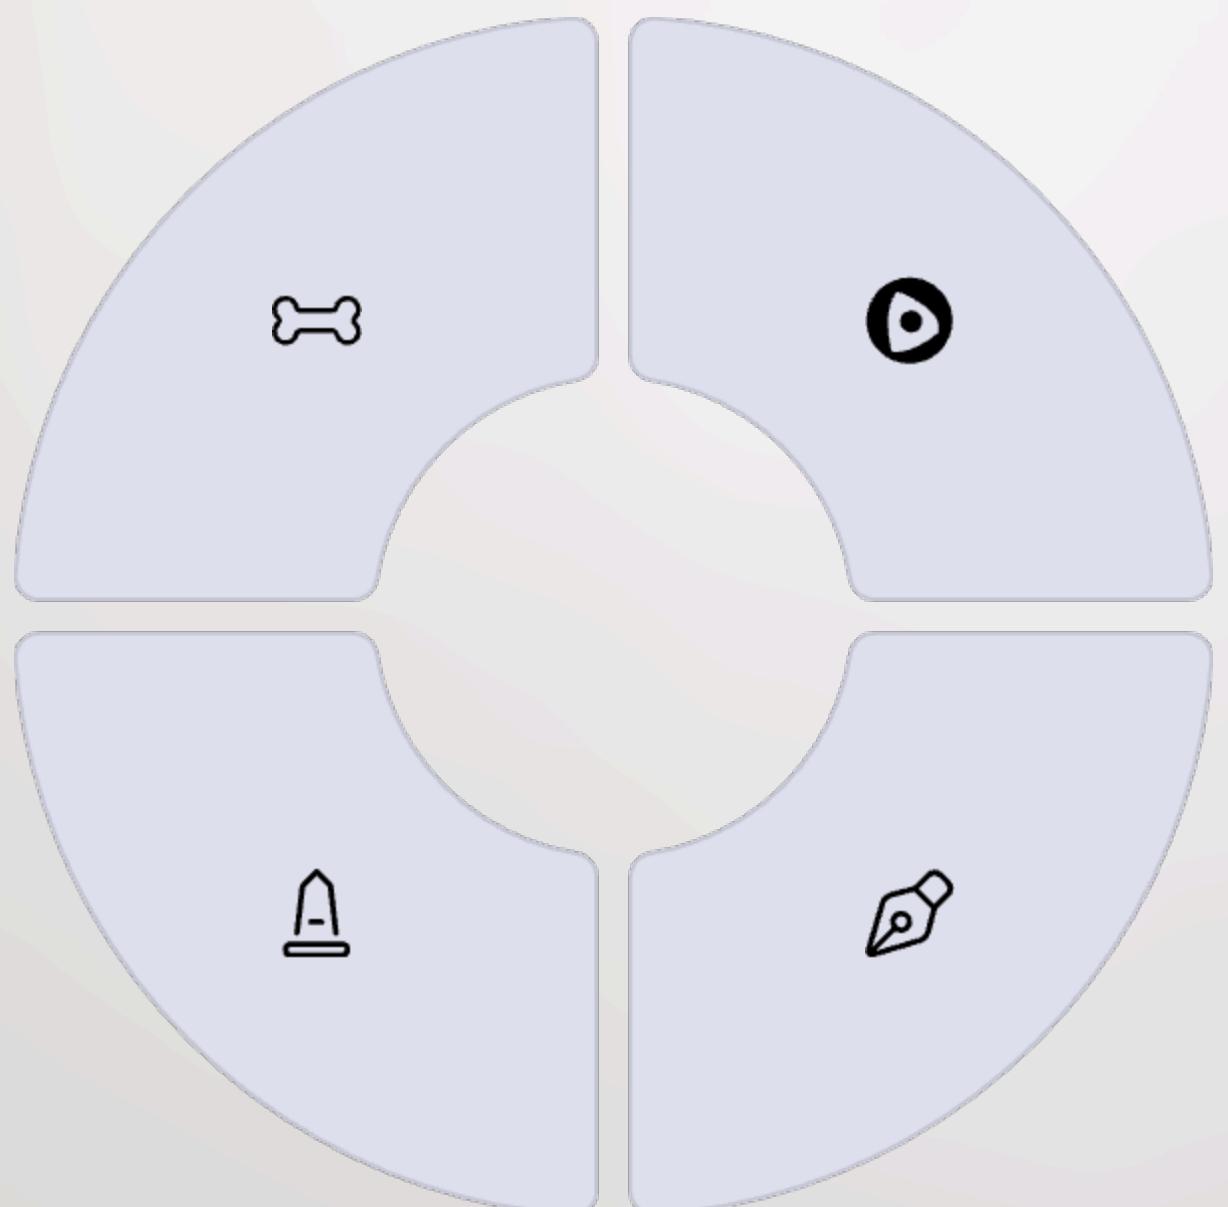
Extremidades

Sensores en muñecas o brazos para evaluar la dinámica de las extremidades superiores.

Ubicación anatómica óptima

Prominencias óseas

Zonas con menor amortiguación por tejido blando.



Menor movimiento relativo

Zonas donde la piel se desplaza menos respecto al hueso.

Centro del segmento

Proximidad al centro de masa del segmento corporal.

Minimizar tejido muscular

Evitar zonas con gran masa muscular que generen artefactos.

Fijación y sujeción del sensor



Cintas elásticas con velcro

Proporcionadas por fabricantes para sujetar sensores a extremidades o torso.



Cinta médica adhesiva

Refuerzo adicional para movimientos dinámicos y reducción de artefactos.



Trajes ceñidos

Con bolsillos especiales para IMUs en gestos explosivos o de alta aceleración.



Fajines o arneses

Con bolsillos para mayor comodidad en aplicaciones clínicas con pacientes.

Minimización de artefactos

Sensores ligeros

Menor masa del sensor reduce el artefacto de tejido blando.

Sujeción firme

Mayor rigidez en la fijación minimiza el desplazamiento.

Zonas de piel estable

Menor cantidad de movimiento de la piel respecto al hueso.

Orientación consistente del sensor

Marcas de orientación

Flechas o figuras impresas indicando la dirección correcta.

Ejes estandarizados

Eje Z hacia arriba y X hacia adelante en posición anatómica.

Protocolo consistente

Mantener la misma orientación en todas las pruebas.

Frecuencia de muestreo

Tipo de movimiento	Frecuencia recomendada	Justificación
Caminar (~1.2 m/s)	100 Hz	Movimiento relativamente lento
Correr (~2.2 m/s)	200 Hz	Mayor velocidad de movimiento
Movimientos cílicos rápidos	400 Hz	Captura componentes de alta frecuencia
Dominadas	100-200 Hz	Suficiente para fase de vuelo y amortiguación

Filtrado digital de señales

Filtro paso-bajo

Elimina ruido de alta frecuencia que no corresponde al movimiento humano real.

Técnicas avanzadas

Filtros de Kalman o complementarios que fusionan acelerómetro y giroscopio.

Filtro paso-alto

Aísla componentes como la gravedad de la señal del acelerómetro.

Filtro pasa-banda

Selecciona cierta banda específica de frecuencias de interés.

Frecuencias de corte recomendadas

5-6 Hz

Análisis de marcha

Para datos cinemáticos en gestos lentos como caminar.

20 Hz

Datos de IMU

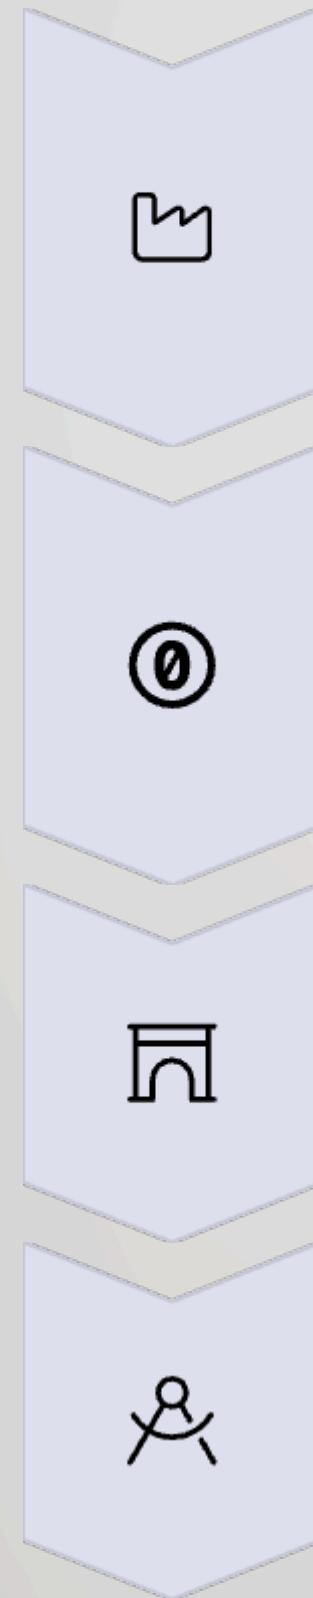
Para aceleraciones que incluyen más contenido de alta frecuencia.

0.5 Hz

Aislamiento de gravedad

Filtro paso-bajo para estimar el vector gravedad.

Niveles de calibración



Calibración de fábrica

Escala de acelerómetros y giroscopios predeterminada por el fabricante.

Calibración inicial

Posición estática conocida para "poner a cero" los ángulos iniciales.

Calibración funcional

Movimientos controlados para alinear sensor-segmento.

Calibración magnetómetro

Movimiento en figura de 8 para eliminar offsets y escalar.

Mantenimiento de dispositivos

Batería

Asegurar carga completa antes de cada sesión y monitorear durante el ensayo.

Firmware

Mantener actualizaciones al día para mejorar estabilidad y precisión.

Cuidado físico

Proteger de impactos, polvo o humedad y limpiar conectores.

Verificación periódica

Comprobar calibración regularmente, especialmente tras golpes fuertes.

Almacenamiento de datos

Formatos estándar

Usar CSV, C3D, TXT o HDF5 para facilitar la futura reutilización.
Incluir metadatos como frecuencia de muestreo y calibración.

Respaldo inmediato

Tras cada sesión, respaldar archivos en otro medio como disco externo o nube para prevenir pérdidas.

Sincronización múltiple

Guardar información de sincronización entre varios IMUs mediante timestamps comunes o marcas de evento.

Transparencia en procesamiento

Documentar filtros aplicados o guardar también datos brutos sin procesar para reproducibilidad.

Fiabilidad test-retest

La fiabilidad test-retest evalúa la consistencia de mediciones repetidas en el mismo sujeto.

Los valores de ICC superiores a 0,90 y CV inferiores al 5% indican excelente fiabilidad en la mayoría de las aplicaciones.

Variabilidad intra e interobservador

Intraobservador

Mismo técnico colocando el sensor en la misma persona en días distintos.

Evalúa consistencia del mismo evaluador en diferentes momentos.

Afectada por técnica de colocación y experiencia.

Interobservador

Diferentes técnicos colocando el sensor en la misma persona.

Evalúa si distintos evaluadores obtienen resultados comparables.

Requiere protocolo de colocación bien estandarizado.

Fuentes de inconsistencia

Las principales fuentes de inconsistencia incluyen: repetibilidad de la colocación, deriva de calibración, cambios en el sujeto (fatiga, aprendizaje) y procesamiento de señal inconsistente.

Estrategias para mejorar la fiabilidad

Capacitación del evaluador

Asegurar que quien coloca los sensores siga exactamente el protocolo establecido.

Múltiples repeticiones

Registrar varios intentos y promediar para reducir el error aleatorio.

Estandarizar instrucciones

Misma entrada en calor y cadencia de movimiento para reducir variabilidad biológica.

Control ambiental

Realizar pruebas en condiciones similares (hora, fatiga, calzado).

Análisis de dominadas con IMUs



Colocación en pecho

El sensor en el esternón registra la aceleración vertical y la inclinación del tronco durante cada repetición.



Colocación en espalda alta

Permite detectar correctamente el inicio/fin de cada repetición y la altura alcanzada.



Análisis de fases

El IMU detecta cambios de aceleración al inicio y final de la fase concéntrica.

Métricas en dominadas con IMUs

0.8s

Tiempo de ascenso

Duración de la fase concéntrica desde inicio hasta punto máximo.

1.2m/s

Velocidad media

Velocidad promedio durante la fase de ascenso.

2.5g

Aceleración pico

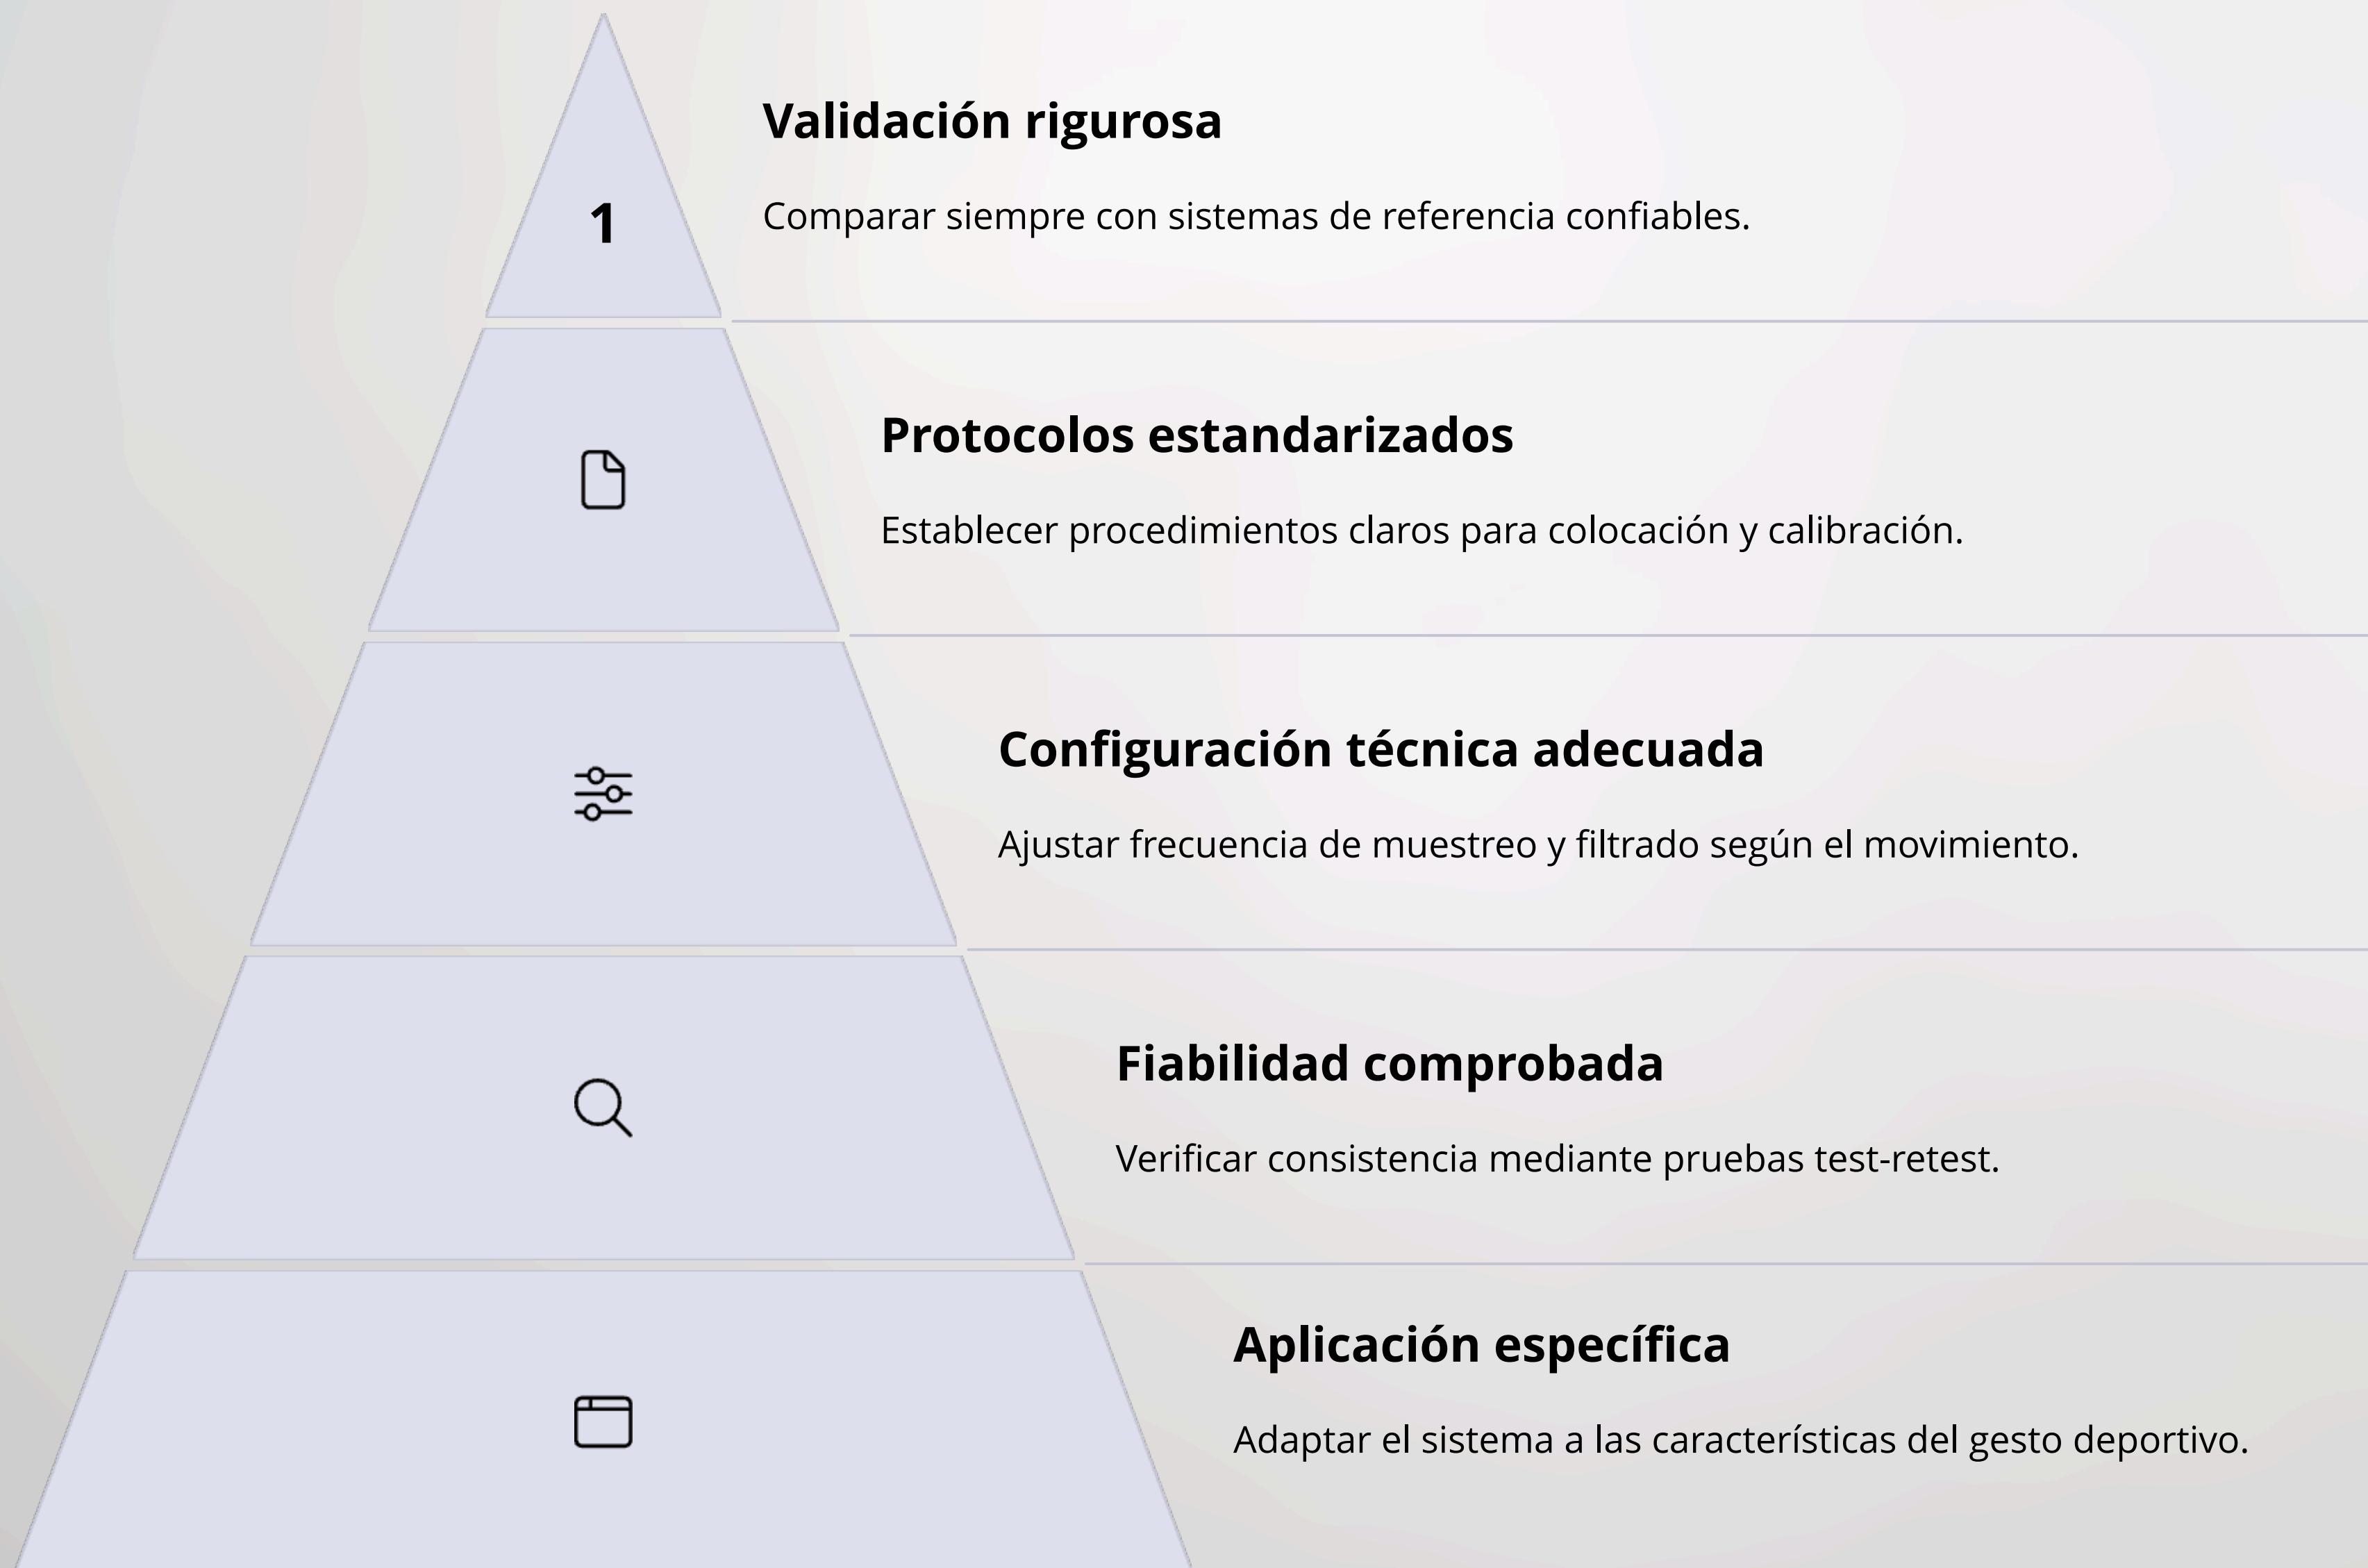
Máxima aceleración registrada durante el impulso inicial.

45cm

Rango vertical

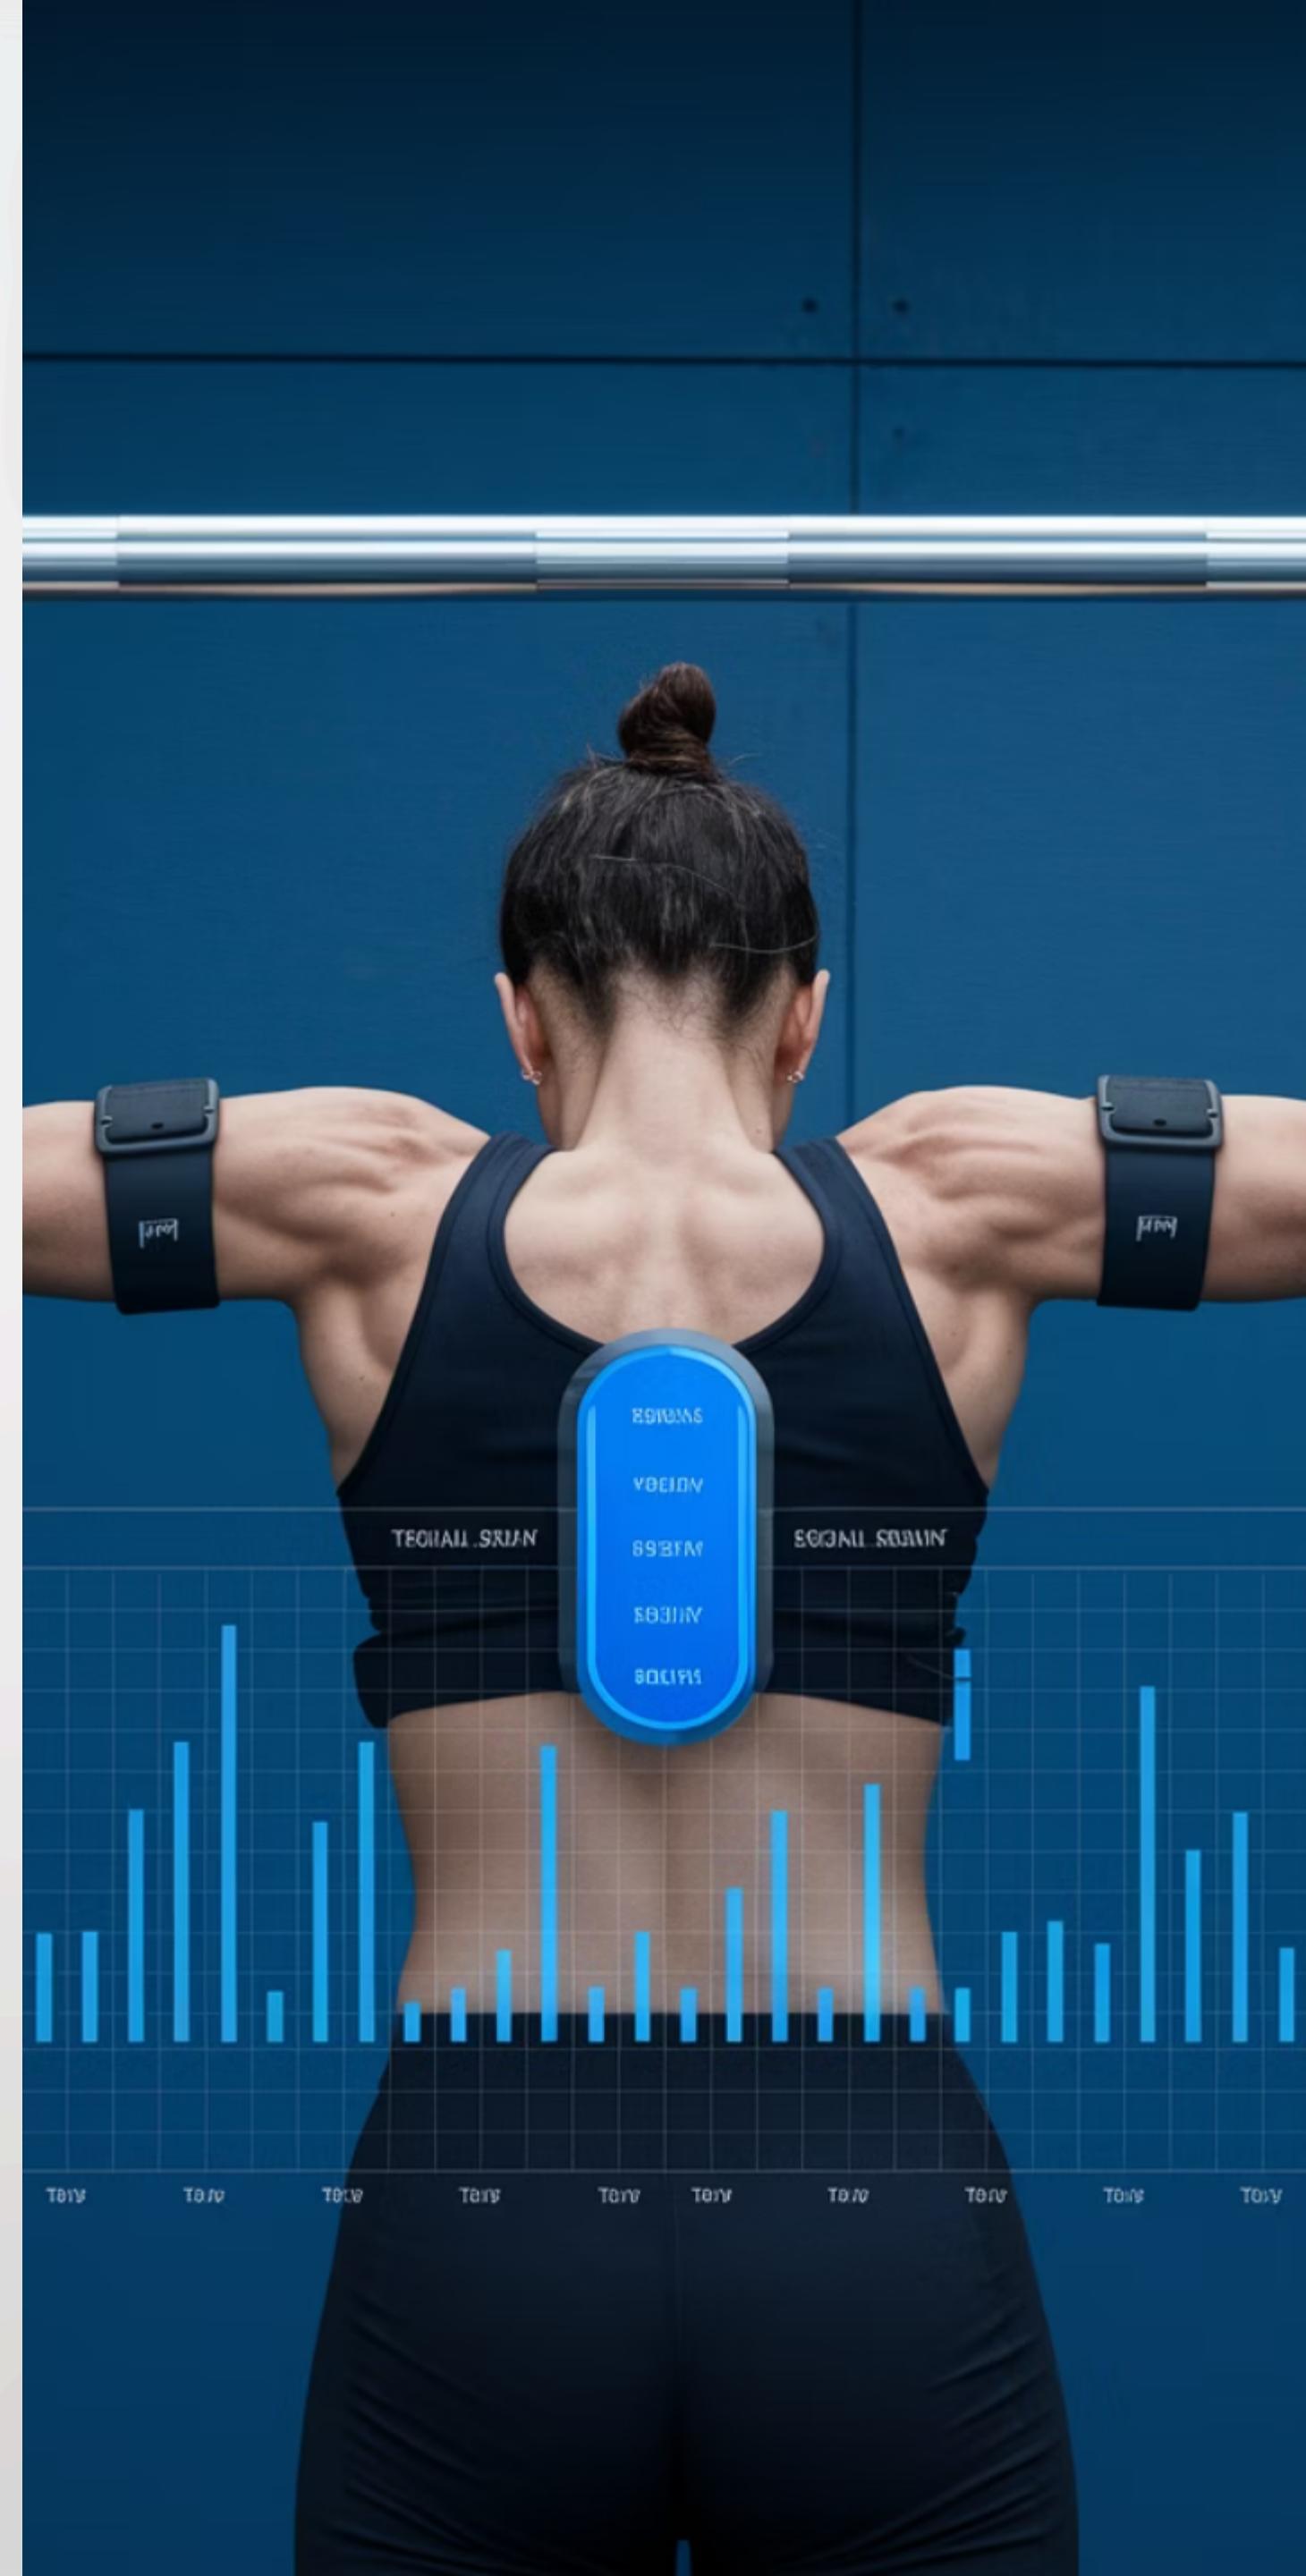
Desplazamiento total desde posición inicial hasta máxima altura.

Conclusiones y recomendaciones



3

Implementación de IA/ML con Sensores Inerciales para Análisis de Dominadas en Biomecánica Deportiva



Glosario de términos técnicos

- **Inteligencia Artificial (IA):** Área de la computación que busca crear sistemas capaces de realizar tareas que normalmente requieren inteligencia humana. Incluye muchos subcampos, desde planificación y razonamiento hasta percepción. El ML y DL son sub-disciplinas de la IA.
- **Aprendizaje Automático (Machine Learning, ML):** Conjunto de técnicas dentro de la IA que permiten a un sistema aprender patrones a partir de datos, en lugar de ser programado explícitamente con reglas fijas. Incluye algoritmos supervisados, no supervisados y por refuerzo. En biomecánica se usa para reconocer actividades, predecir valores biomecánicos, etc.
- **Aprendizaje Profundo (Deep Learning, DL):** Subcampo de ML que utiliza redes neuronales artificiales con múltiples capas (profundas) para modelar datos complejos. Puede descubrir automáticamente representaciones de alto nivel en los datos. Ejemplo: una red profunda puede aprender características de la señal de un IMU que correspondan a patrones de movimiento, sin intervención humana.
- **Sensor Inercial (IMU):** Dispositivo que combina usualmente un acelerómetro (mide aceleración lineal en 3 ejes) y un giroscopio (mide velocidad angular en 3 ejes), a veces también un magnetómetro (campo magnético, usado para orientación absoluta). Proporciona mediciones de movimiento del cuerpo donde esté colocado. Son pequeños y se usan como wearables para captar la cinemática humana.
- **CRISP-ML:** Adaptación del estándar CRISP-DM (Cross-Industry Standard Process for Data Mining) al ciclo de vida de proyectos de Machine Learning. Consta de fases: 1) Entendimiento del negocio/problema, 2) Entendimiento de los datos, 3) Preparación de los datos, 4) Modelado, 5) Evaluación, 6) Despliegue. Es iterativo y ... Es iterativo y adaptado a los proyectos de ML, asegurando retroalimentación constante y control de calidad en cada fase.
- **HAR (Human Activity Recognition):** Reconocimiento automático de actividades humanas. En español a veces Reconocimiento de Actividad Humana. Consiste en clasificar qué acción realiza una persona (caminar, correr, saltar, etc.) a partir de sensores. En biomecánica deportiva, HAR abarca distinguir diferentes ejercicios o fases de un movimiento mediante datos de IMUs, videos, etc.
- **Sobreajuste (Overfitting):** Ocurre cuando un modelo aprende demasiado los detalles o ruido del conjunto de entrenamiento y pierde capacidad de generalizar a nuevos datos. Un signo de sobreajuste es rendimiento casi perfecto en entrenamiento pero pobre en validación. Se combate con regularización, más datos, o modelos más simples.
- **Regularización:** Conjunto de técnicas para impedir el sobreajuste penalizando la complejidad del modelo. Por ejemplo, la regularización L2 agrega un término que fuerza a que los pesos de un modelo sean lo más pequeños posibles, simplificando la solución. Otra forma es regularización por abandono (dropout), que aleatoriamente desconecta neuronas durante el entrenamiento para que la red no dependa de combinaciones específicas de características.

- **Dropout:** Técnica de regularización en redes neuronales donde se “apagan” aleatoriamente un porcentaje de neuronas en cada iteración de entrenamiento. Esto obliga a la red a ser más robusta, ya que no puede confiar en una ruta específica para hacer una predicción. En validación/prueba, todas las neuronas están activas pero el efecto es equivalente a promediar muchos sub-modelos, reduciendo el sobreajuste.

- **Métricas de clasificación:**

- **Accuracy (Exactitud):** Fracción de predicciones correctas sobre el total. Útil como indicador global, pero puede ser engañosa si las clases están desbalanceadas.
- **Precisión (Precision):** Porcentaje de instancias predichas como positivas que realmente lo son ($TP/(TP+FP)$). Alta precisión significa pocas alarmas falsas.
- **Exhaustividad o Recall:** Porcentaje de instancias positivas reales que el modelo logra identificar ($TP/(TP+FN)$). Alto recall significa pocos falsos negativos (no se le escapan muchos positivos verdaderos).
- **F1-Score:** Media armónica de precisión y recall, útil para resumir ambas en un solo valor.
- **AUC-ROC:** Área bajo la curva ROC, mide la capacidad de separabilidad de clases del modelo en diferentes umbrales (1.0 es perfecta, 0.5 es aleatoria).
- **MCC (Matthews Correlation Coefficient):** Métrica entre -1 y 1 que considera verdaderos y falsos de ambas clases; es informativa aun con clases desequilibradas (1 es perfecto, 0 aleatorio, -1 totalmente erróneo).

- **Algoritmos y modelos comunes:**

- **Árbol de decisión:** Modelo de clasificación/regresión basado en reglas if-then anidadas en forma de árbol. Fácil de interpretar pero puede sobreajustar si es muy profundo.
- **Random Forest (Bosque aleatorio):** Ensamble de muchos árboles de decisión entrenados sobre distintas muestras; suele mejorar generalización y manejar bien datos tabulares.
- **SVM (Support Vector Machine):** Clasificador que encuentra el hiperplano que mejor separa las clases en el espacio de características, utilizando kernels para casos no lineales. Eficaz en conjuntos de tamaño moderado y alta dimensión, aunque menos usado hoy en día frente a redes neuronales para grandes datasets.
- **Red Neuronal Convolucional (CNN):** Tipo de red profunda especializada en extraer características espaciales o temporales usando filtros (convoluciones). En señales de tiempo, las CNN 1D pueden captar patrones locales (ej. un pico de aceleración). Han demostrado alto rendimiento en reconocimiento de patrones complejos.
- **Red Neuronal Recurrente (RNN):** Red diseñada para secuencias, que mantiene estados internos para recordar información previa. Las variantes modernas como LSTM (Long Short-Term Memory) o GRU solucionan problemas de memoria a largo plazo en secuencias. Se usan para modelar dependencias temporales largas (p. ej., en series de IMU para captar dinámica en el tiempo).
- **Transformer:** Arquitectura de red basada en mecanismos de atención en lugar de recurrencia. Permite capturar relaciones de largo alcance en secuencias de forma eficiente. En HAR empieza a usarse para secuencias largas de sensores, aunque es más común en NLP y visión.

- **Cuantización (Quantization):** Proceso de reducir la precisión numérica de un modelo, por ejemplo pasar de pesos en coma flotante de 32 bits a enteros de 8 bits. Esto comprime el modelo (menos memoria) y puede acelerar la inferencia en hardware sencillo sin unidad de coma flotante, con mínima pérdida de precisión si se hace correctamente.
- **Poda de modelo (Pruning):** Técnica de compresión donde se eliminan (ponen a cero) pesos o neuronas poco relevantes de la red neuronal. El modelo resultante es más ligero y rápido, manteniendo casi el mismo rendimiento si la poda se hace sobre componentes realmente "irrelevantes". Puede realizarse iterativamente con re-entrenamiento para recuperar desempeño.
- **SHAP: Acrónimo de SHapley Additive exPlanations.** Método post-hoc de explicabilidad que atribuye a cada característica un valor que representa su contribución a la predicción de un modelo para una instancia dada. Se basa en la idea de los valores de Shapley de la teoría de juegos. Útil para explicar por qué el modelo tomó cierta decisión (p. ej., "esta variación en aceleración sumó +0.2 a la probabilidad de ser dominada correcta") de manera consistente y localmente precisa.
- **LIME: Local Interpretable Model-Agnostic Explanations.** Otro método de XAI que genera explicaciones locales ajustando un modelo interpretable (lineal o árbol corto) en la vecindad de la predicción a explicar. Ayuda a aproximar qué características impulsaron la decisión en esa región del espacio de datos.
- **Model Card (Tarjeta de modelo):** Documento estandarizado que acompaña a un modelo de ML, describiendo sus características de rendimiento, datos de entrenamiento, alcance previsto y limitaciones conocidas. Propuesto para fomentar la transparencia, especialmente en modelos usados por públicos no expertos. Una model card para nuestro modelo de dominadas incluiría, por ejemplo: "Entrenado con 1000 reps de 20 individuos (15H/5M), preciso 95% en conteo de repeticiones, probado en edades 20-40; no validado para dominadas asistidas; puede fallar si el sensor se mueve del pecho."
- **Deriva de concepto (Concept drift):** Fenómeno donde la relación estadística entre las características de entrada y la salida objetivo cambia con el tiempo. El modelo "aprendido" se vuelve menos válido porque el proceso subyacente evolucionó. En biomecánica, esto puede suceder si el atleta modifica su técnica o condición física, o si se usa el modelo en un contexto diferente al original. Requiere recalibrar o reentrenar periódicamente el modelo para mantener la precisión.

Marco Teórico General



Relevancia de IA/ML en Biomecánica

La IA y ML permiten analizar datos de movimiento humano de manera objetiva y automatizada.



Metodologías de Desarrollo

Se sigue un flujo similar a CRISP-DM adaptado a ML (CRISP-ML) con fases iterativas.



Aplicaciones Deportivas

Ya implementado en sentadillas, saltos y carrera con alta precisión.

Tareas de Modelado en Biomecánica



Estas tareas permiten analizar el movimiento humano desde diferentes perspectivas, adaptándose a los objetivos específicos del análisis biomecánico. La elección del enfoque depende de la información que se desea extraer de los datos iniciales.

Técnicas de ML Utilizadas

</>

Algoritmos Clásicos

k-NN, árboles de decisión, SVM, análisis discriminante



Aprendizaje Profundo

CNN, RNN con celdas LSTM para datos temporales



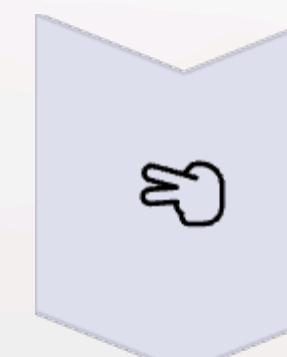
Arquitecturas Avanzadas

Mecanismos de atención y modelos transformer

La evolución de técnicas ha permitido mejorar la precisión en reconocimiento de actividades humanas. Jeong et al. lograron hasta un 96% de exactitud en clasificación multi-ejercicio con CNN profunda.

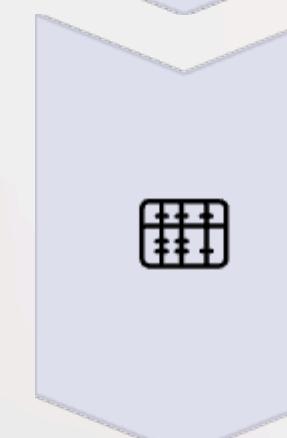


Aplicación Específica en Dominadas



Segmentación del gesto en fases

División en inicio, ascenso hasta "catch" y descenso/fin.



Detección automática de repeticiones

Conteo preciso mediante identificación de ciclos en datos.



Estimación de ángulos articulares

Inferencia de parámetros cinemáticos como ángulos de codo y hombro.



Clasificación de variantes técnicas

Reconocimiento de diferentes tipos de dominadas y errores técnicos.

Resultados de Investigaciones Previas

96%

Exactitud en clasificación

En reconocimiento de ejercicios como dominadas mediante CNN.

93%

Precisión en conteo

Con error $\leq \pm 1$ repetición en sistemas automáticos.

97%

Fiabilidad ampliada

Permitiendo un error de ± 2 repeticiones en el conteo.

Estos resultados demuestran la viabilidad de sistemas basados en IA para análisis de dominadas con alta precisión, comparable a la observación humana experta.

Arquitectura del Sistema

Módulo de Reconocimiento (ARM)

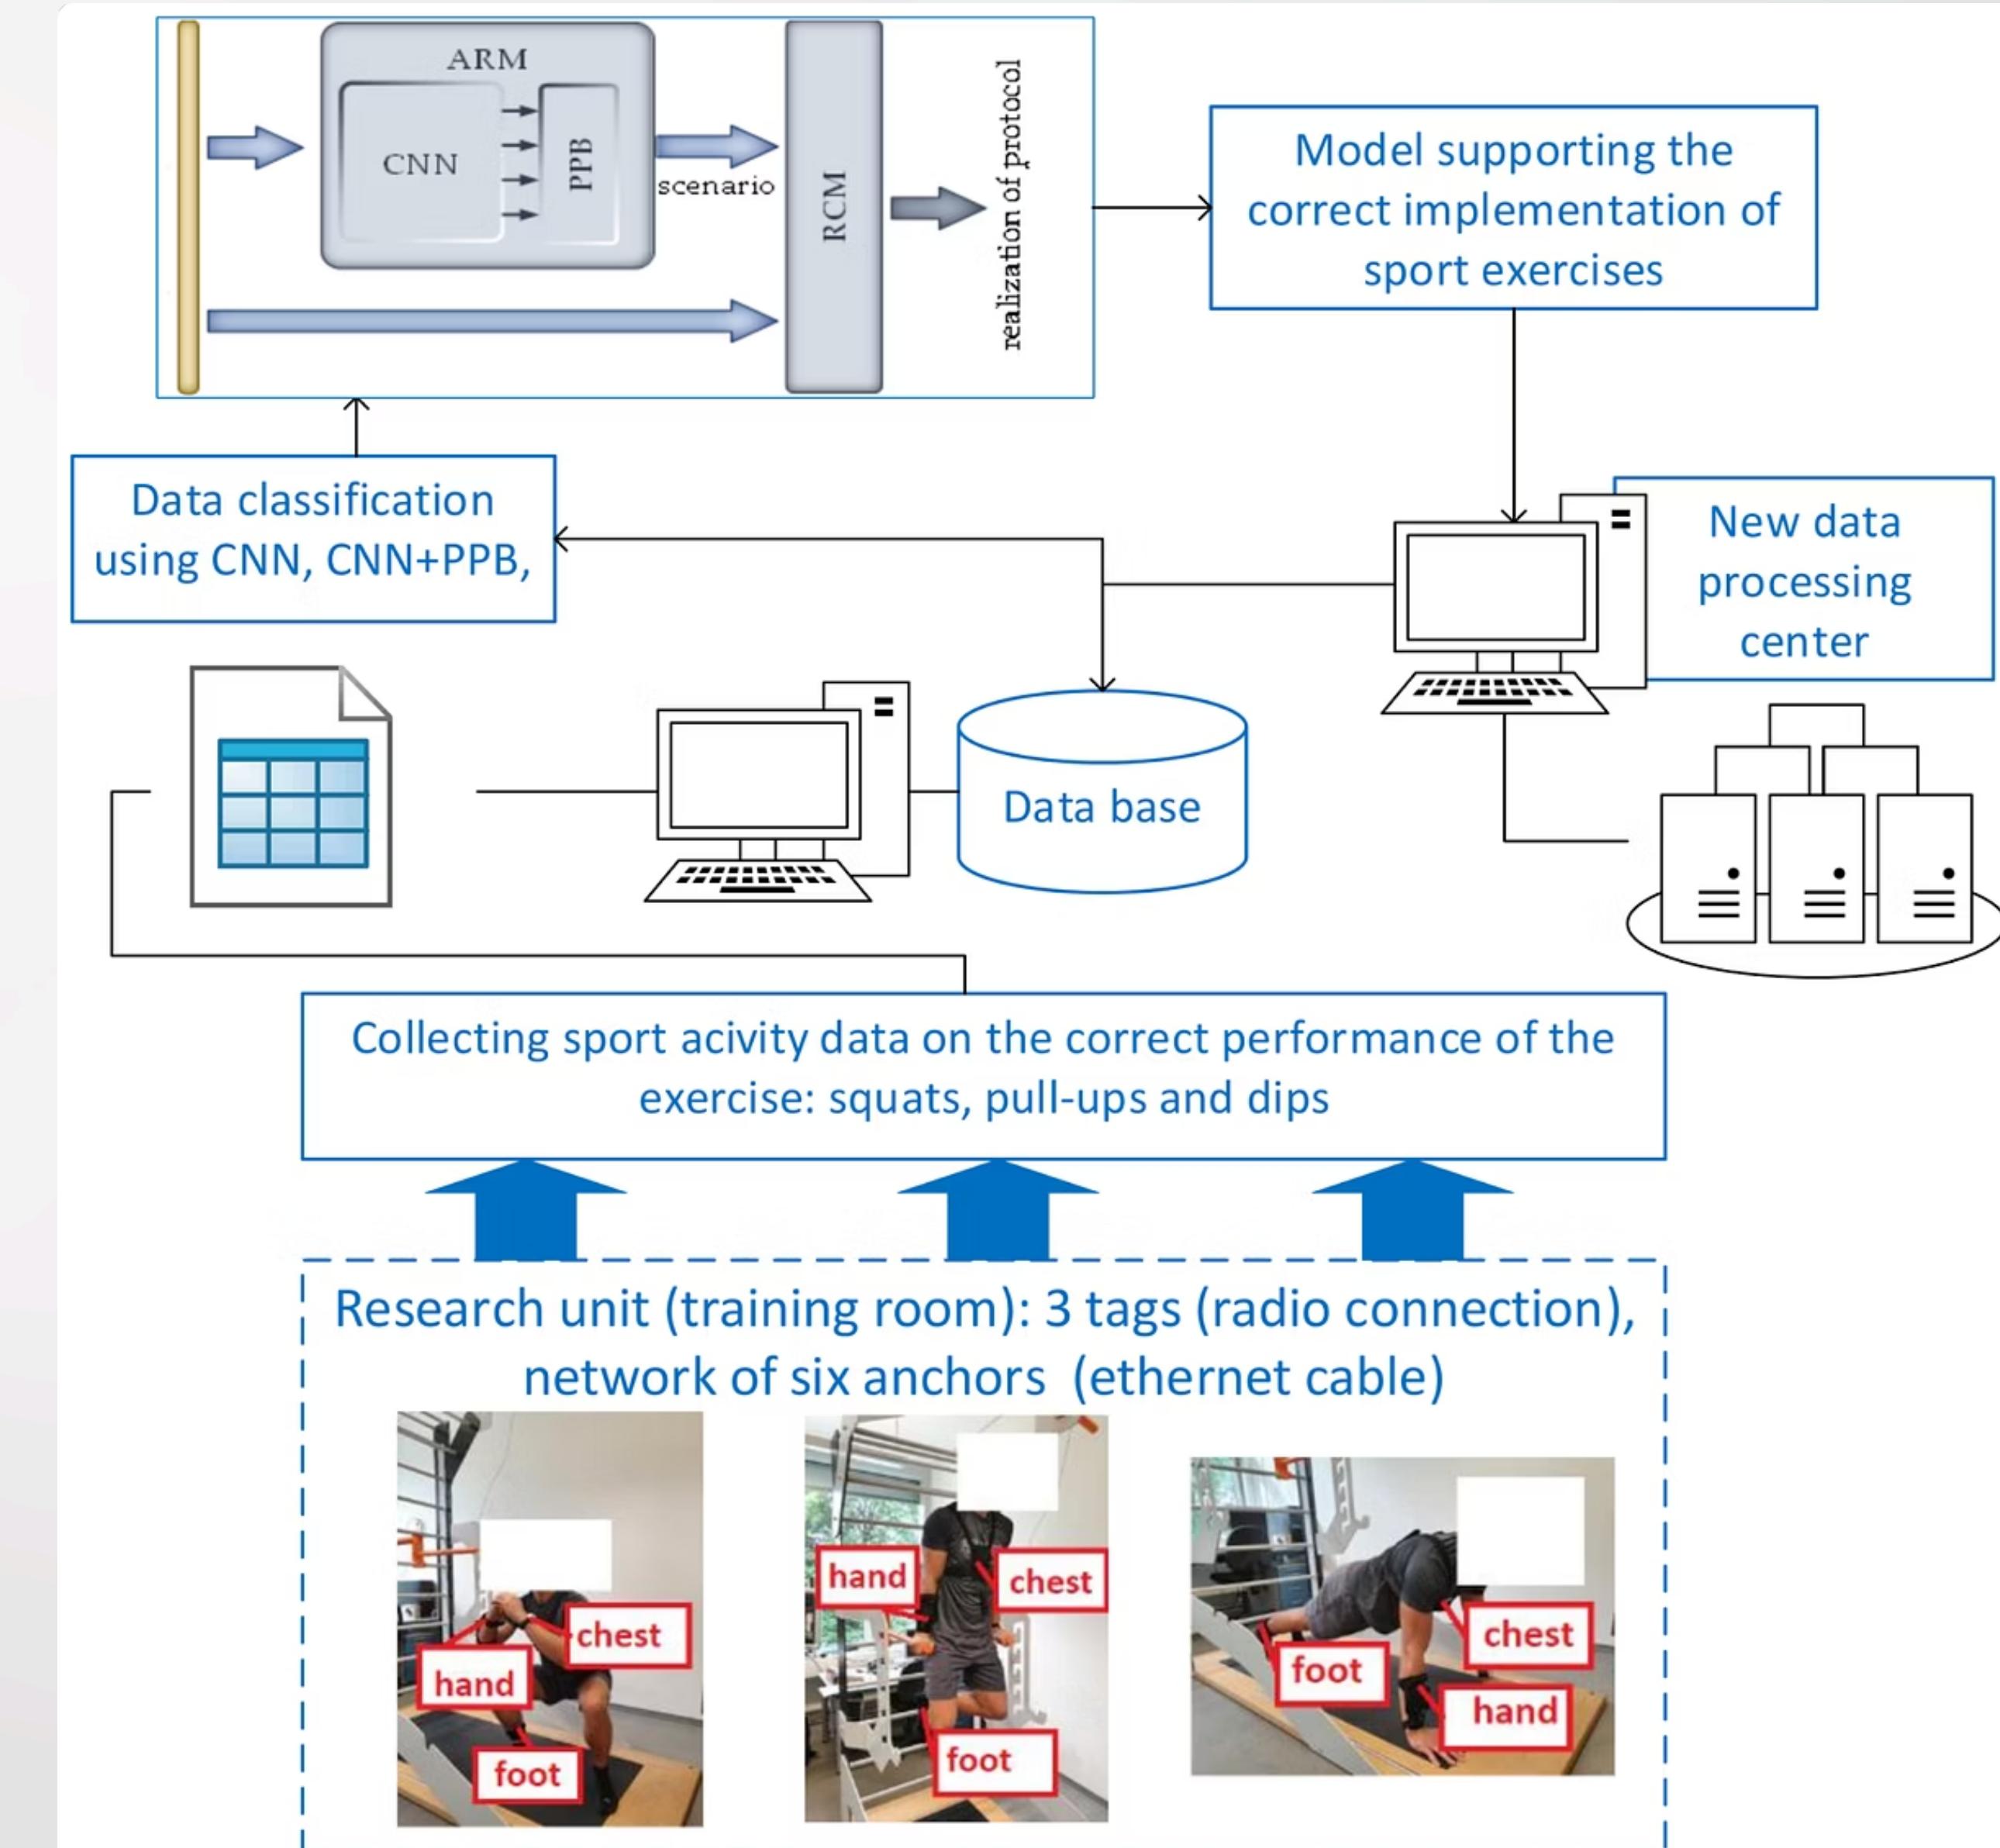
CNN con bloque de post-procesamiento para segmentar ejercicios.

Módulo de Conteo (RCM)

Detecta y cuenta repeticiones de forma automática.

Sensores Iniciales

Colocados en mano, pecho y pie del deportista para capturar movimiento.



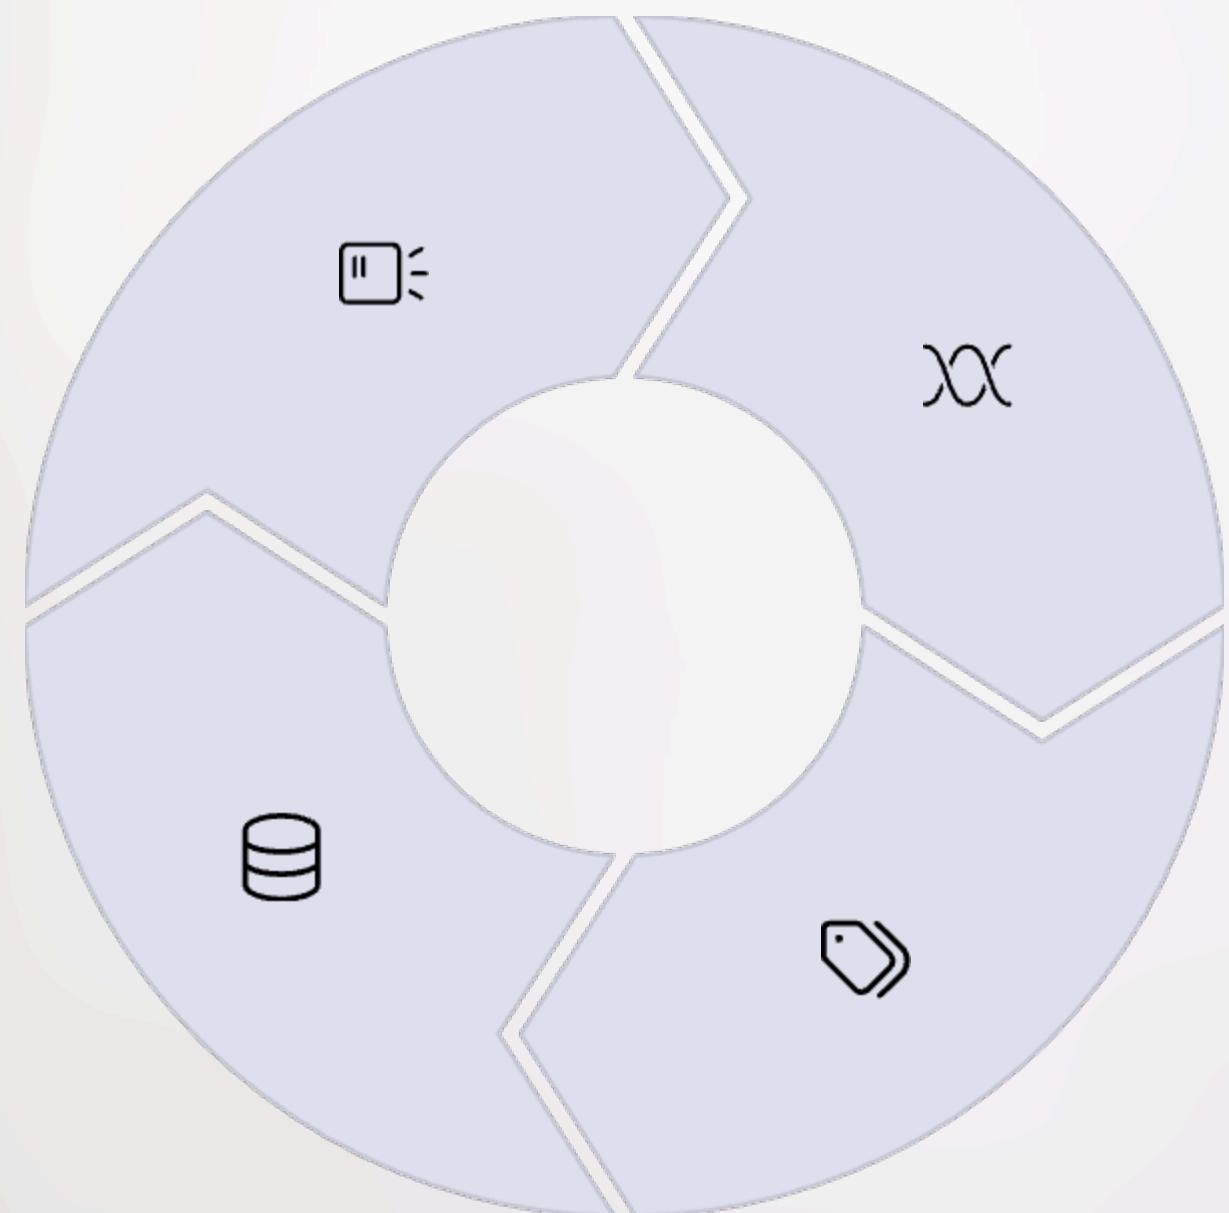
Preparación de Datos: Estructuración

Colocación de sensores

Ubicación estratégica en pecho o muñeca para capturar movimiento relevante

Organización de trazas

Estructuración por sujeto, sesión y ejercicio para facilitar análisis



Frecuencia de muestreo

Entre 50-200 Hz para captura óptima de movimiento humano

Etiquetado temporal

Anotación precisa de intervalos y repeticiones como ground truth

Preprocesamiento de Señales



Filtrado

Pasa-bajos (5-10 Hz)
para eliminar ruido de
alta frecuencia.



Calibración

Alineación de ejes con
referencias
anatómicas.



Normalización

Estandarización
estadística para
mejorar convergencia.



Segmentación

División en ventanas
para análisis
individualizado.

Extracción de Características

Características Temporales

- Media y desviación estándar
- Máximos y mínimos por eje
- Número de picos o cruces por cero
- Pendiente máxima (RFD: explosividad)

Características Frecuenciales

- Energía en bandas específicas
- Frecuencia dominante
- Entropía espectral
- Transformadas FFT o wavelets

Características Cinemáticas

- Ángulos relativos
- Detección de posturas extremas
- Diferencias entre sensores
- Orientación mediante quaterniones

Segmentación en Ventanas Móviles

1 Tamaño de Ventana

2-5 segundos para capturar estructura completa de una repetición.

2 Solapamiento

50-75% para no perder transiciones entre ventanas.

3 Etiquetado

Cada ventana recibe etiqueta según la tarea (actividad, fase, etc.).

El estudio de Patalas-Maliszewska demostró que con ventanas solapadas se logra mejor accuracy (0.92 vs 0.88) en la detección de actividad, evidenciando la utilidad de esta técnica.

Balanceo de Clases

Sobremuestreo

SMOTE genera muestras sintéticas de la clase minoritaria mediante interpolación.

Submuestreo

Descarte aleatorio de muestras de la clase mayoritaria para equilibrar.

Pesos de Clase

Penalización mayor para errores en la clase minoritaria durante el entrenamiento.

División de Datos y Prevención de Leakage

Separación por Sujeto

Entrenar con datos de algunos participantes y reservar otros para prueba (Leave-One-Subject-Out).

Separación por Sesión

Dividir por sesiones distintas para evitar que patrones específicos de una sesión se filtren.

Gestión de Ventanas Solapadas

Asegurar que ventanas que se traslapan queden en el mismo grupo (entrenamiento o prueba).

Normalización Independiente

Calcular parámetros de normalización solo con datos de entrenamiento, no incluyendo los de prueba.

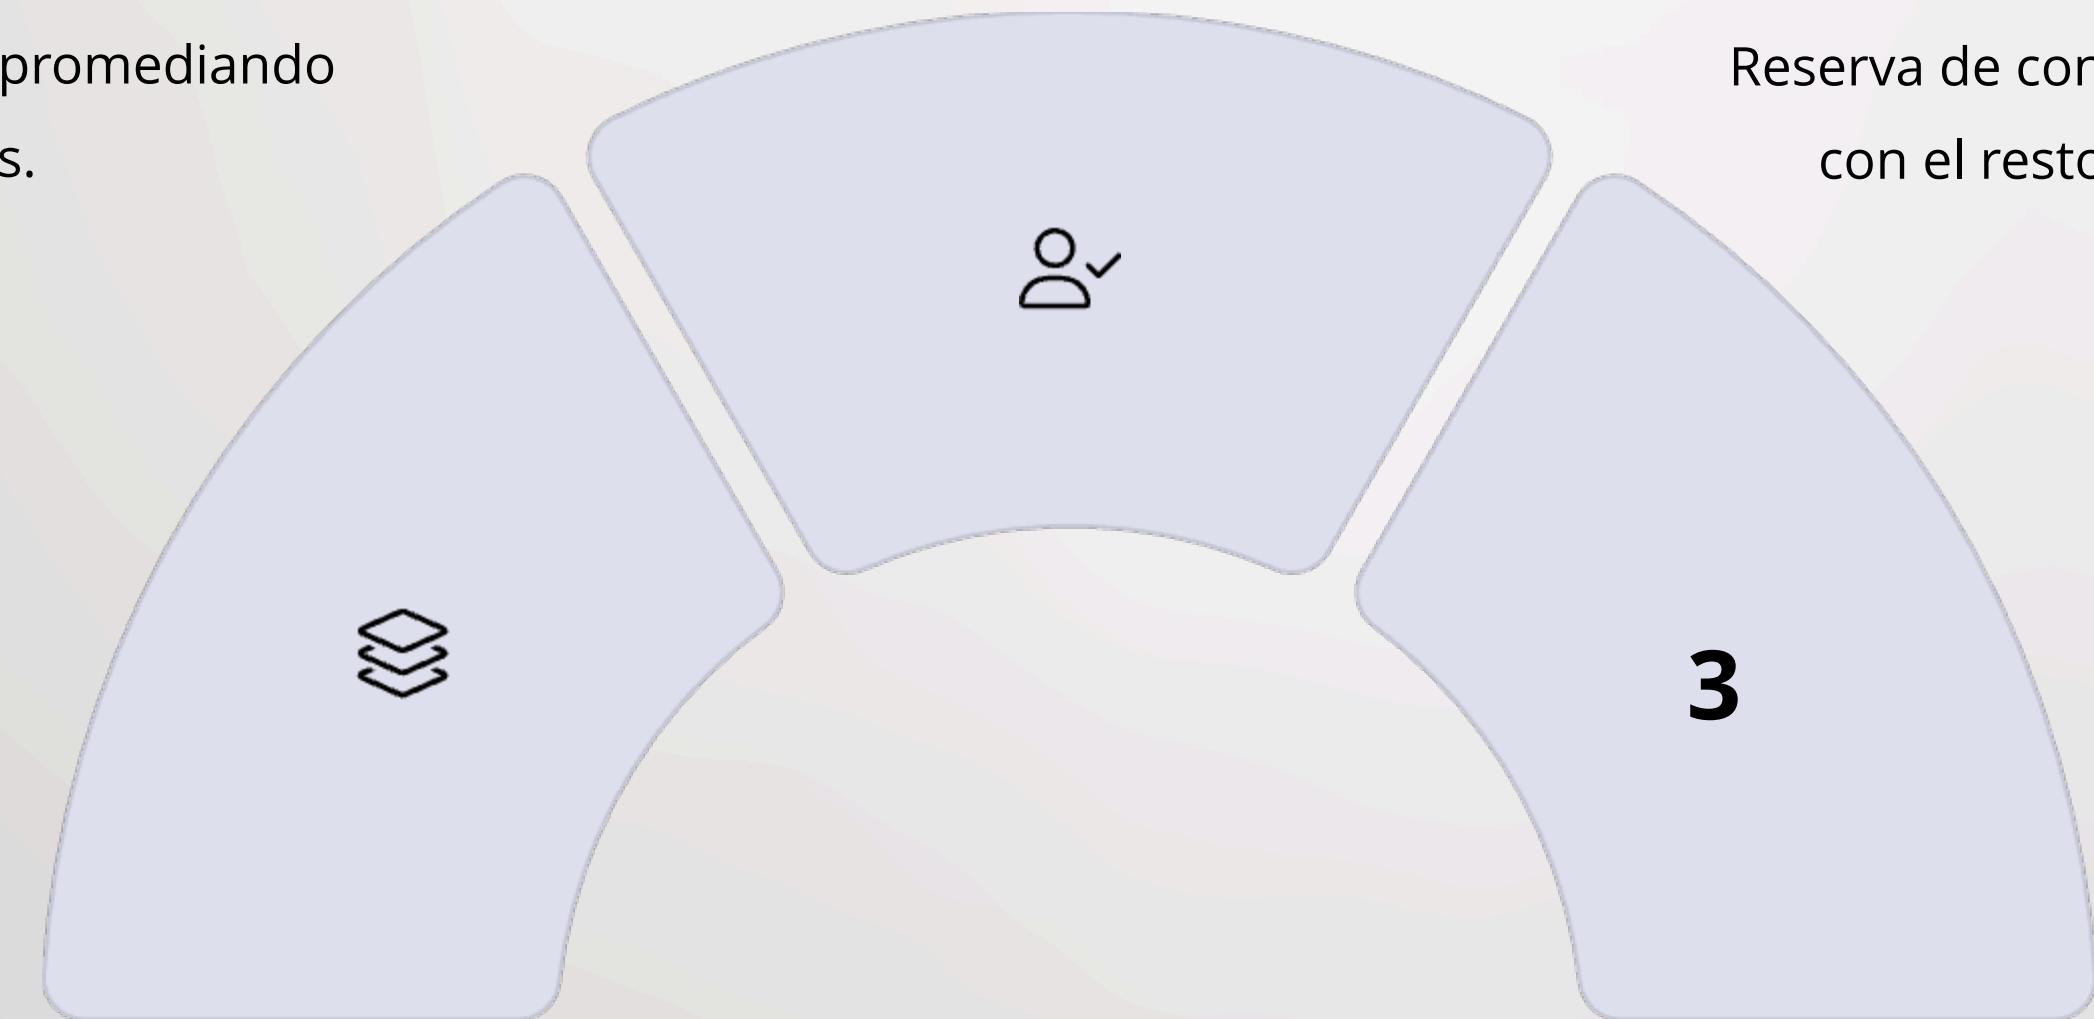
Procedimientos de Validación Cruzada

Leave-One-Subject-Out (LOSO)

Iteración tomando datos de un sujeto como prueba y entrenando con los demás.

k-fold cross-validation

División en k subconjuntos, entrenando k modelos diferentes y promediando resultados.



Hold-out con validación interna

Reserva de conjunto fijo (20%) y k-fold CV con el resto (80%) para desarrollo.

Métricas de Desempeño

Métrica	Fórmula	Interpretación
Precisión (Precision)	$TP / (TP + FP)$	Proporción de predicciones positivas correctas
Exhaustividad (Recall)	$TP / (TP + FN)$	Proporción de positivos reales detectados
F1-Score	$2 * (Prec * Rec) / (Prec + Rec)$	Media armónica de precisión y recall
AUC-ROC	Área bajo curva ROC	Capacidad de discriminación (1=perfecta, 0.5=azar)
MCC	Coeficiente entre -1 y 1	Correlación entre predicción y realidad

Regularización y Prevención de Sobreajuste

Regularización L2

Añade penalización proporcional al cuadrado de los pesos, evitando que crezcan demasiado y manteniendo el modelo simple.

Dropout

Desconecta aleatoriamente un porcentaje de neuronas en cada iteración, obligando a la red a aprender representaciones redundantes.

Early Stopping

Interrumpe el entrenamiento cuando la métrica de validación empeora, evitando el sobreajuste a los datos de entrenamiento.

Data Augmentation

Añade perturbaciones a las señales durante el entrenamiento, como ruido o variaciones temporales, aumentando la robustez.

Frameworks y Herramientas



TensorFlow/Keras

Ofrece funciones listas para usar como capas CNN1D, optimizadores con regularización y callbacks para early stopping.



PyTorch

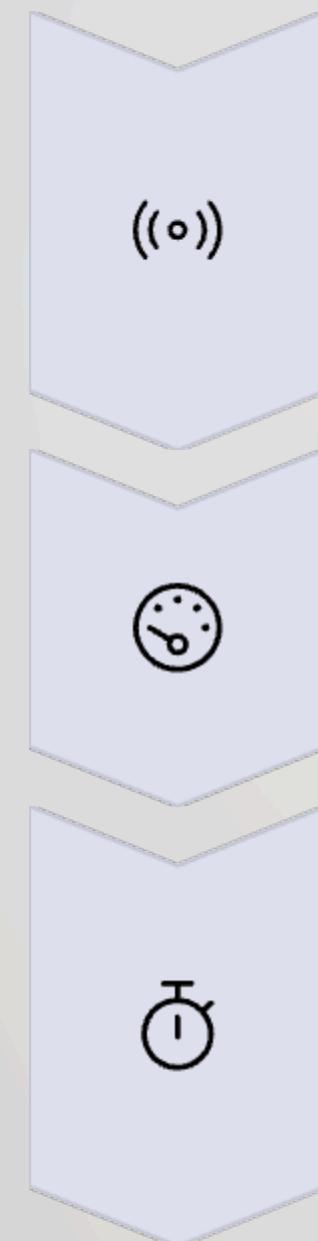
Muy flexible para personalizar arquitecturas complejas y experimentar con nuevos modelos.



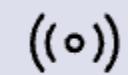
Scikit-learn

Popular para algoritmos tradicionales como árboles, SVM y utilidades para validación cruzada.

Inferencia en Tiempo Real



Ventanas deslizantes



Buffer de tamaño N que se actualiza con nuevas muestras.

Optimización de tiempo



Cómputo más rápido que el intervalo entre ventanas.

Profiling



Medición de tiempos para ajustar complejidad del modelo.

La latencia total desde que ocurre el evento hasta la notificación debe ser corta (0.1-0.2s) para una experiencia fluida. En conteo de repeticiones, un ligero retraso es tolerable.

Optimización y Compresión de Modelos



Cuantización

Reducción de precisión numérica de 32 bits a 8 bits, disminuyendo tamaño y aumentando velocidad.



Pruning (Poda)

Eliminación de conexiones poco importantes, creando un modelo más esparso y eficiente.



Distillation

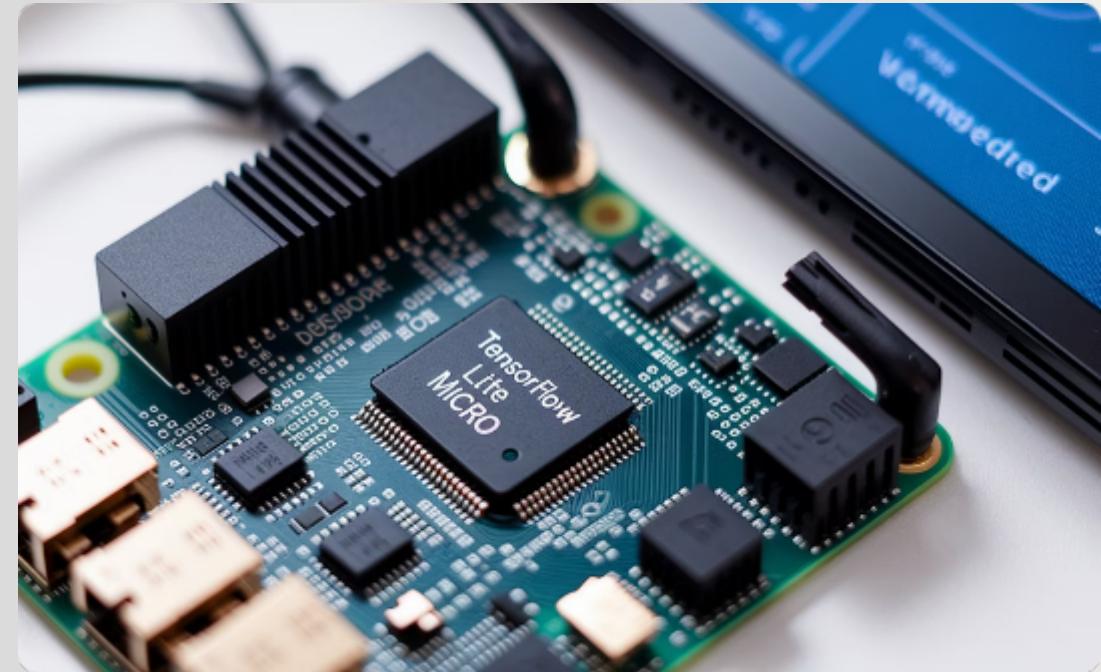
Entrenamiento de modelo pequeño para imitar salidas de uno grande, transfiriendo conocimiento.



Optimización de arquitectura

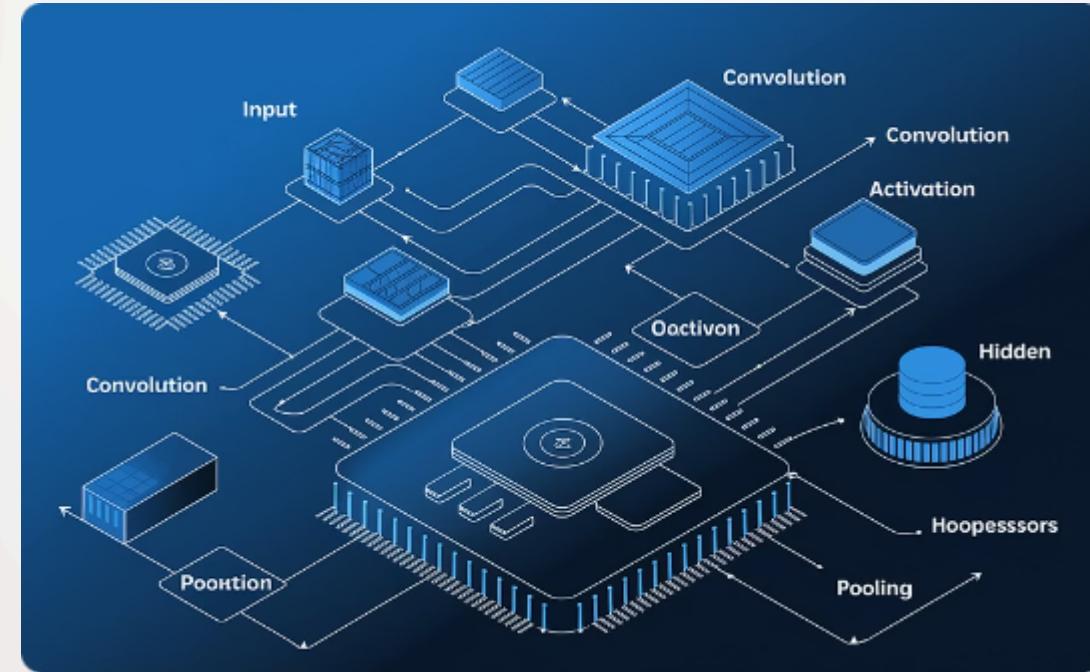
Diseño de modelos más simples adaptados a las restricciones del dispositivo objetivo.

Herramientas para Dispositivos Portables



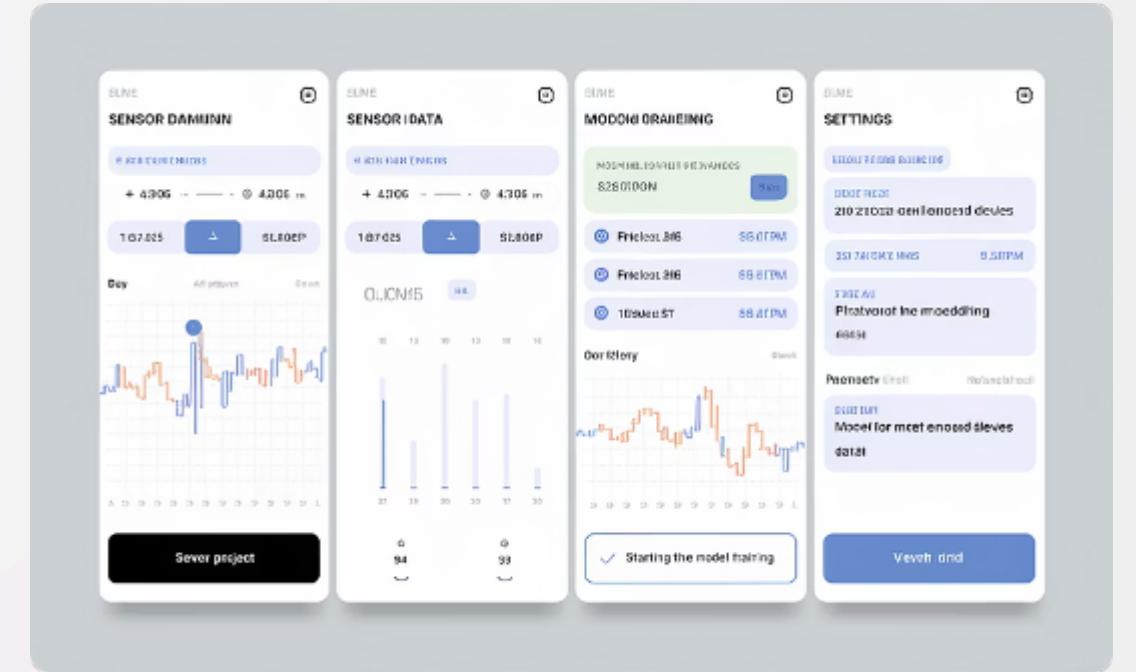
TensorFlow Lite Micro

Versión de TF Lite para microcontroladores sin sistema operativo, funciona con muy poca RAM (decenas de KB).



CMSIS-NN

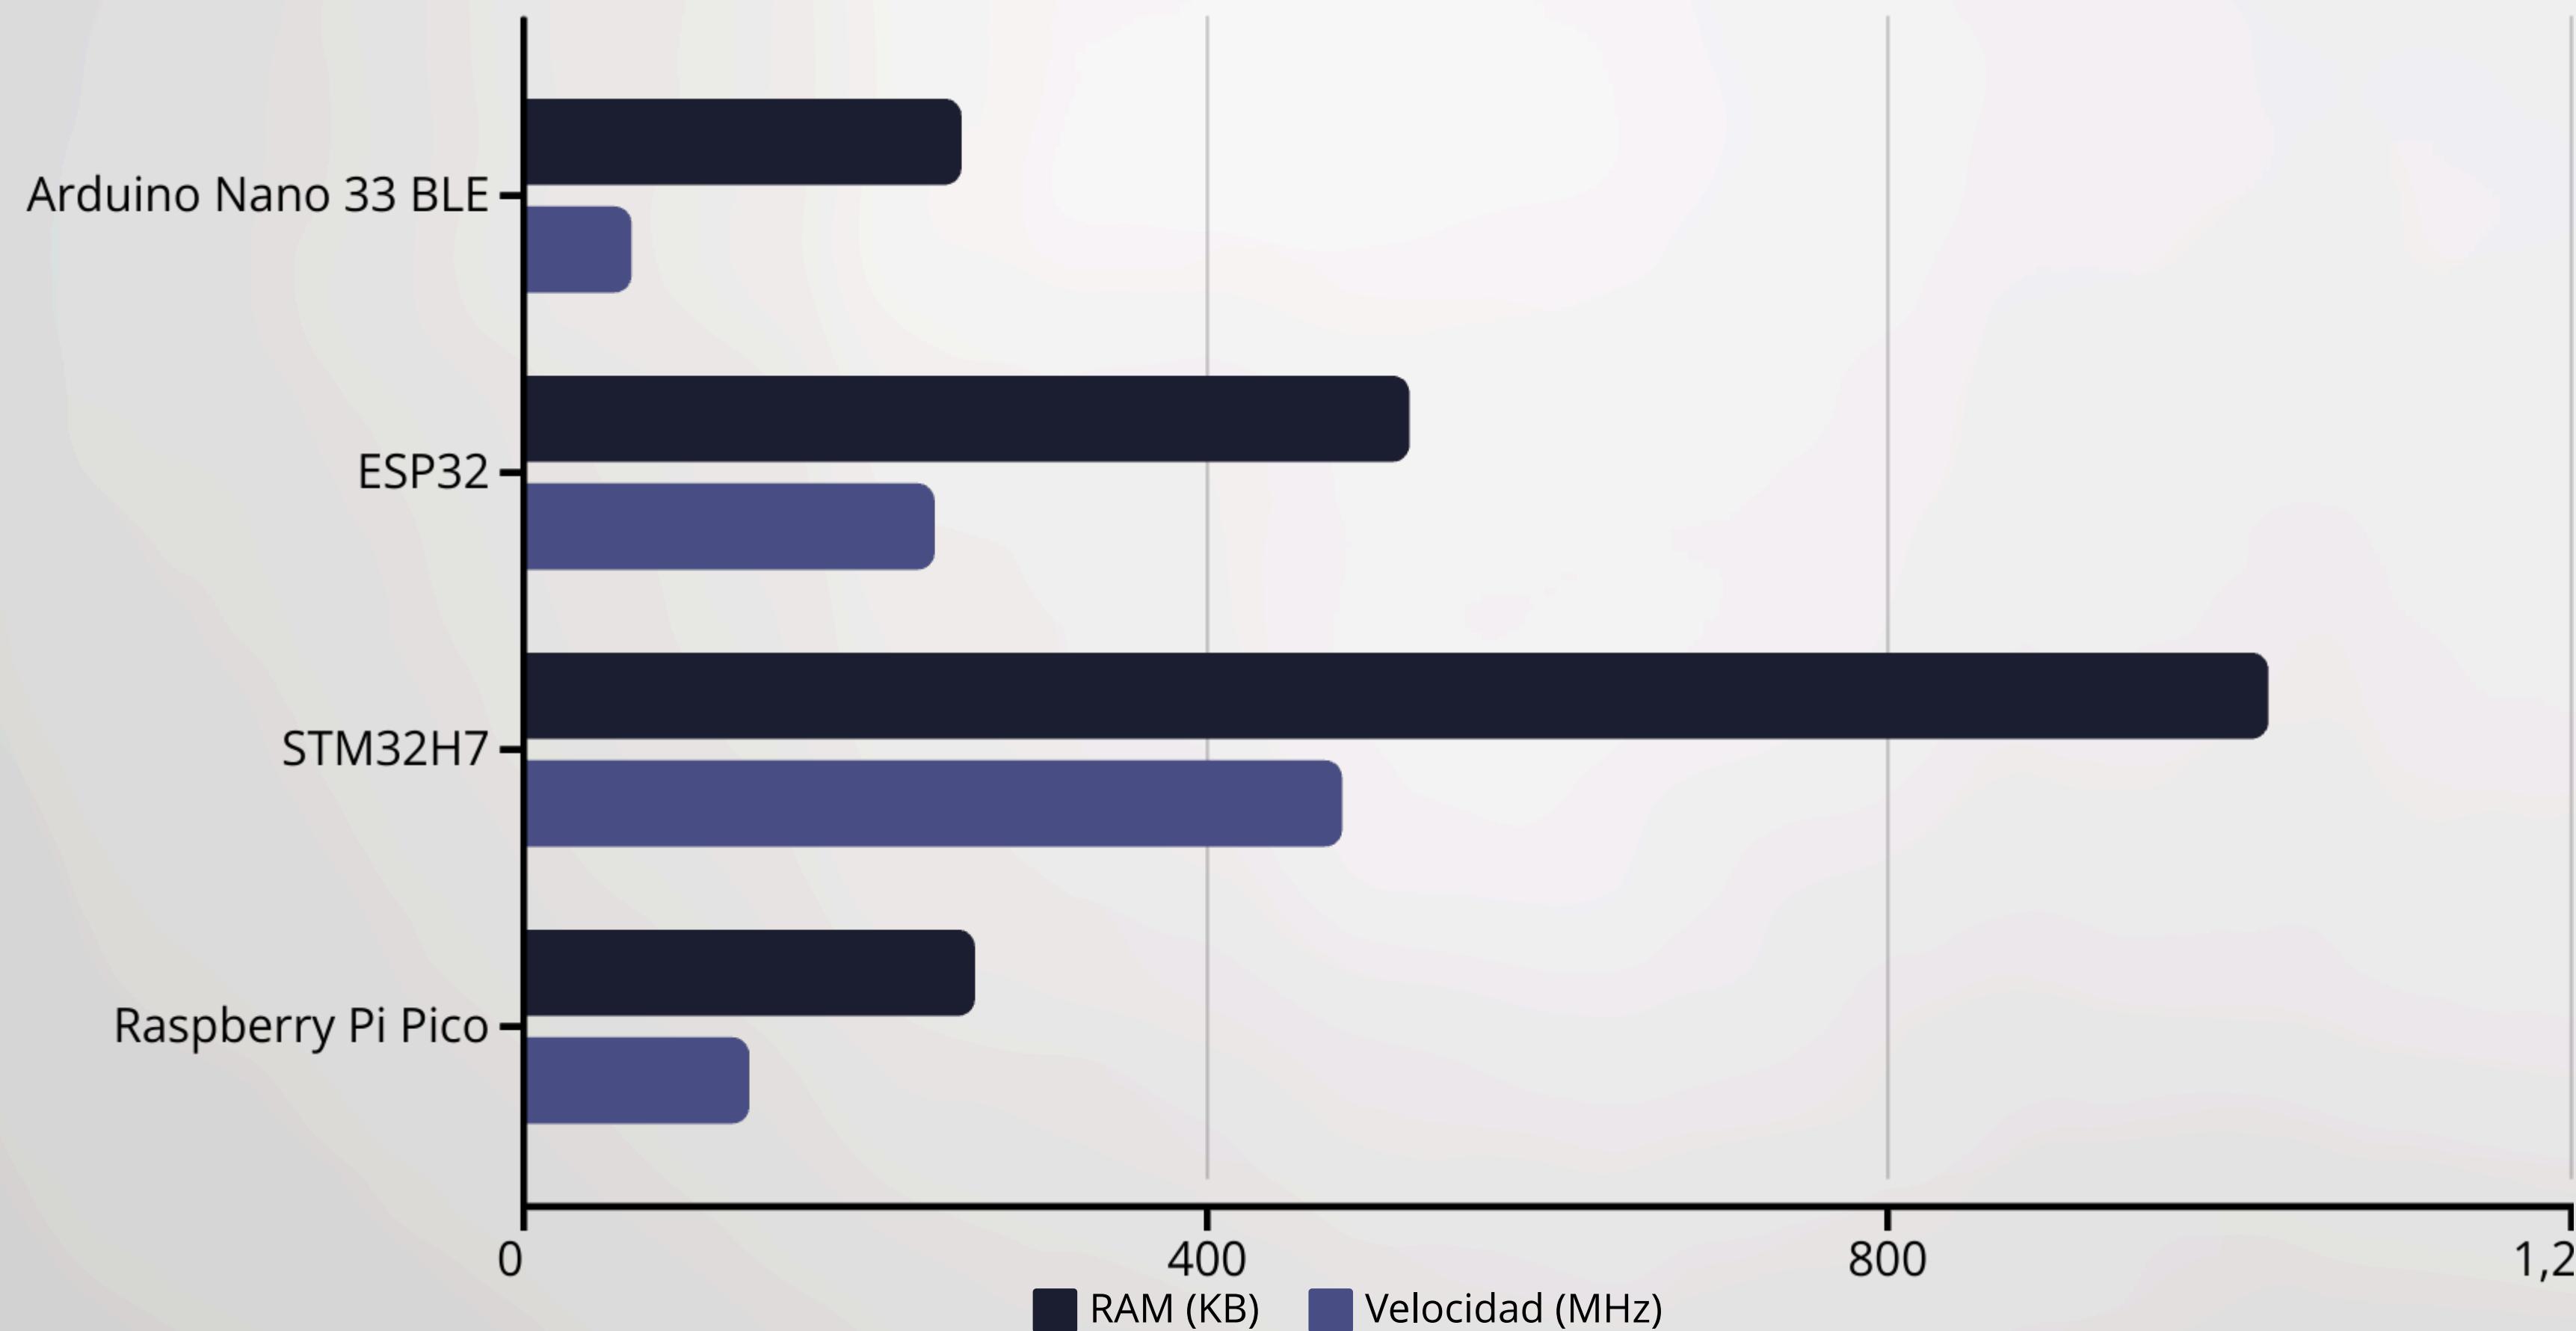
Librerías optimizadas de redes neuronales específicamente para procesadores ARM Cortex-M.



Edge Impulse

Plataforma que facilita entrenar e implementar modelos en diferentes placas como Arduino Nano 33 BLE Sense.

Dispositivos Compatibles



Estos microcontroladores ofrecen diferentes capacidades para ejecutar modelos de ML. El objetivo es lograr que incluso la plataforma más sencilla pueda ejecutar el modelo optimizado con precisión aceptable.

Pipeline Completo de Análisis

Adquisición

Sensores IMU obtienen datos continuamente mediante interrupciones de temporizador para asegurar periodicidad.

Preprocesamiento local

Filtrado y segmentación en tiempo real, manteniendo buffer circular de muestras para la ventana actual.

Inferencia del modelo

Normalización de datos y ejecución del modelo para producir predicciones sobre clase o parámetros biomecánicos.

Post-procesamiento

Aplicación de lógica adicional como filtrado de mediana para suavizar predicciones y conteo de repeticiones.

Feedback/Visualización

Presentación de resultados al usuario mediante pantalla, LED, vibración o transmisión Bluetooth.

Explicabilidad del Modelo

Importancia de Características

Cálculo de la influencia de cada feature en la predicción, basado en la reducción de impureza que genera.

Ejemplo: "Amplitud de aceleración vertical" como atributo más influyente para detectar repeticiones.

SHAP

Asignación de valores de contribución a cada característica, fundamentado en teoría de juegos.

Muestra qué características específicas influyeron en clasificar una repetición como correcta o incorrecta.

LIME

Construcción de modelo lineal simple alrededor de la vecindad de la instancia a explicar.

Permite descubrir qué cambios en la señal modificarían la predicción del modelo.

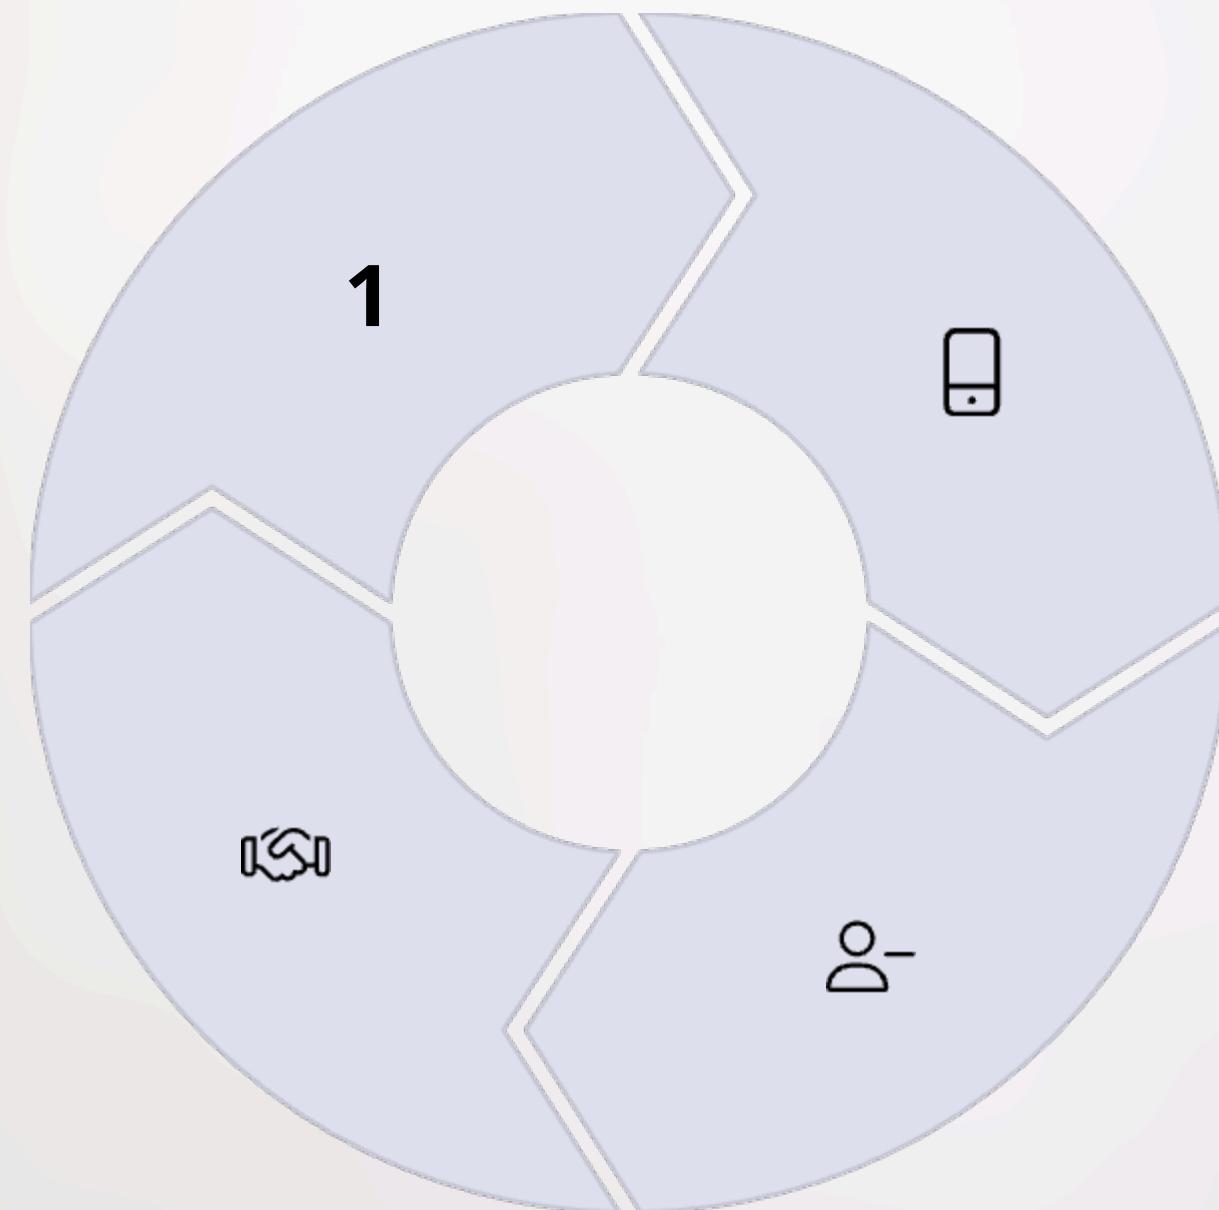
Conclusiones y Futuras Direcciones

Viabilidad demostrada

Alta precisión en detección y análisis de dominadas con sensores iniciales y ML

Integración multidisciplinar

Colaboración entre biomecánica, ciencias del deporte e inteligencia artificial



Portabilidad creciente

Modelos optimizados funcionando en dispositivos de bajos recursos

Personalización adaptativa

Sistemas que evolucionan con el usuario mediante aprendizaje continuo

La combinación de sensores iniciales con IA/ML representa un avance significativo en el análisis biomecánico, ofreciendo herramientas accesibles y precisas para mejorar el rendimiento deportivo y prevenir lesiones.

