



Machine learning models for predicting hand grip and pinch strength from hand anthropometry in occupational populations: a systematic review

Modelos de aprendizaje automático para la predicción de la fuerza de prensión y pinza a partir de antropometría de mano en poblaciones trabajadoras

Misael Ron¹  
Evelin escalona¹ 

¹ Universidad de Carabobo, Facultad de Ciencias de la Salud, Área de Postgrado. Aragua, Venezuela.

Recibido: 20-04-2026 | Revisado: 25-06-2026 | Aceptado: 21-07-2026 | Publicado: 23-07-2026

ABSTRACT

In occupational ergonomics, handgrip and pinch strength are functional indicators of the first order: they inform tool design, fitness-for-task assessment, and the surveillance of upper-limb musculoskeletal disorders. For years, predicting these variables from hand anthropometry relied on linear regression. The problem is well known. The biomechanical relationships involved are not linear, and that caps how precise the method can be. The past decade brought an alternative —machine learning models able to capture those nonlinearities. Objective. To gather the evidence on the performance and predictor variables of these models when estimating grip and pinch strength from hand anthropometry in working populations. Methods. Systematic review following the PRISMA 2020 statement. PubMed, Scopus, Web of Science, IEEE Xplore, and Google Scholar were searched for documents published between 2000 and 2025. Primary studies on adult workers that applied at least one algorithm and reported performance metrics were included. Methodological quality was assessed with an adapted version of PROBAST. Results. Twelve studies, more than 9,000 participants from Malaysia, Taiwan, Turkey, South Korea, and Iran. The dominant method was artificial neural networks. Reported R^2 values ranged from 0.52 to 0.97, with a consistent edge for machine learning over regression. The most stable variables: sex, hand length and breadth, hand shape index, and wrist circumference. Conclusions. Machine learning improves on classical regression in a modest but reproducible way, with real usefulness for ergonomic design and occupational surveillance. Methodological heterogeneity and the scarcity of external validation still limit how far the findings transfer across populations.

Keywords: machine learning, hand grip strength, hand anthropometry, ergonomics, occupational health, artificial neural networks.

RESUMEN

En ergonomía ocupacional, la fuerza de prensión manual y la de pinza son indicadores funcionales de primer orden ya que sirven para diseñar herramientas, evaluar la aptitud al puesto y vigilar los trastornos musculoesqueléticos de miembro superior. Durante años, para predecir estas variables desde la antropometría de mano se usaba como técnica la regresión lineal. El problema es conocido: las relaciones biomecánicas implicadas no son lineales, y esto limita la precisión del método. La última década trajo una alternativa, los modelos de aprendizaje automático, capaces de capturar esas no linealidades. Objetivo: Reunir la evidencia sobre el desempeño y las variables predictoras de estos modelos al estimar fuerza de prensión y pinza desde la antropometría de mano en poblaciones trabajadoras. Métodos: Revisión sistemática bajo la declaración PRISMA 2020. Se rastrearon documentos en las bases de datos PubMed, Scopus, Web of Science, IEEE Xplore y Google Scholar entre 2000 y 2025. Entraron estudios primarios con trabajadores adultos que aplicaran al menos un algoritmo y reportaran métricas. La calidad se evaluó con una adaptación de PROBAST. Resultados. Doce estudios, más de 9.000 participantes de Malasia, Taiwán, Turquía, Corea del Sur e Irán. El método principal fueron redes neuronales artificiales. Los R^2 fueron de 0,52 a 0,97, con ventaja sostenida del aprendizaje automático sobre la regresión. Las variables más estables: sexo, longitud y ancho de la mano, índice de forma y circunferencia de muñeca. Conclusiones. El aprendizaje automático mejora a la regresión clásica de forma modesta pero reproducible, con utilidad real para el diseño ergonómico y la vigilancia ocupacional. La heterogeneidad metodológica y la escasa validación externa todavía limitan trasladar los hallazgos entre poblaciones.

Palabras clave: aprendizaje automático, fuerza de prensión, antropometría de la mano, ergonomía, salud laboral, redes neuronales artificiales.

INTRODUCCION

La fuerza de mano y la fuerza de pinza figuran entre los indicadores funcionales más relevantes del miembro superior del ser humano. En el ámbito ocupacional su medición cumple varios cometidos: orienta el diseño de herramientas, sirve para evaluar la aptitud física en tareas de manipulación de carga, permite hacer seguimiento a las exposiciones biomecánicas que se acumulan con el tiempo y ayuda a detectar de forma temprana los trastornos musculoesqueléticos(Lo et al., 2021; Sayadizadehet al., 2024). Las tablas normativas propuestas por Mathiowetz et al. (1985) todavía operan como referencia en muchos países. Ahora bien, aplicar dichas tablas a colectivos de trabajadores determinados resulta debatible, porque entre unos grupos y otros existen diferencias antropométricas y ocupacionales que esas tablas no contemplan(Hajaghazadehet al., 2022).

Durante décadas, lo habitual ha sido estimar la fuerza a partir de las dimensiones de la mano mediante regresión lineal múltiple. Predictores como la longitud de la mano, el ancho de la palma, la circunferencia de la muñeca, la talla y el peso dan cuenta de entre el 40% y el 70% de la varianza de la prensión en muestras de personas sanas(Klum et al., 2012). Sin embargo, la relación entre antropometría y fuerza no es del todo lineal: la activación muscular, la mecánica de las articulaciones y la propiocepción introducen no linealidades que la regresión clásica apenas aproxima. Si a esto se añade el papel modulador de la edad, el sexo, la lateralidad y la propia exposición laboral, se entiende por qué estos modelos pierden precisión en cuanto se les traslada fuera de la población donde se construyeron.

En ese contexto, los algoritmos de aprendizaje automático abren otro camino. Las redes neuronales artificiales, los métodos basados en árboles como random forest y extreme gradient boosting, las máquinas de vector soporte y otras técnicas afines consiguen modelar relaciones no lineales y de orden elevado sin necesidad de fijar de antemano una forma funcional(Hwang et al., 2021). Conviene recordar que su aplicación a la fuerza de mano no es nueva: inició a comienzos de los años dos mil con trabajos pioneros en entornos industriales(Taha yNazaruddin, 2005). De ahí en adelante el campo se ha ido ampliando, sobre todo en la última década, de la mano de cohortes organizacionales más amplias y de procedimientos de optimización cada vez más afinados(Rostamzadeh et al., 2024; Sayadizadehet al., 2024).

Sin embargo, pese a que los estudios primarios se han ido acumulando, falta todavía una revisión sistemática que reúna la evidencia en la población trabajadora. Las revisiones disponibles han apuntado a otros blancos: unas se ocupan de los datos normativos de carácter general(Tomkinson et al., 2025), otras de factores biológicos y funcionales ajenos al ámbito ocupacional(Myles et al., 2024), y otras de aplicaciones clínicas como la sarcopenia o el envejecimiento. Esta brecha tiene consecuencias debido a que frena la transferencia del conocimiento hacia el diseño ergonómico y la vigilancia de la salud laboral, justo en los terrenos donde predecir la fuerza de forma individualizada permitiría un beneficio más directo.

Por lo antes expuesto, esta revisión propone sintetizar la evidencia existente sobre los modelos de aprendizaje automático que predicen la fuerza de prensión y la fuerza de pinza a partir de la antropometría de la mano en poblaciones trabajadoras. En concreto, persigue cinco fines: caracterizar los algoritmos utilizados, contrastar su desempeño frente al de la regresión tradicional, identificar qué variables predictoras se comportan de manera más estable, valorar la calidad metodológica de los estudios y, por último, delimitar las brechas que habrán de orientar la investigación futura.

METODOS

La revisión se llevó de acuerdo con la declaración PRISMA 2020 para revisiones sistemáticas(Page et al., 2021). Es conveniente precisar que el protocolo no se inscribió en PROSPERO antes del inicio de la búsqueda; esta omisión se reconoce de forma expresa entre las limitaciones del trabajo.

Pregunta de revisión (PICOS)

La formulación de la pregunta se realizó bajo la estrategia PICOS. La población quedó definida por trabajadores adultos, sin restricción de sector económico. La exposición de modelado correspondió al empleo de algoritmos de aprendizaje automático destinados a predecir la fuerza de prensión, la de pinza o ambas, a partir de variables antropométricas de la mano. En calidad de comparadores se admitieron tanto los modelos de regresión lineal como la medición directa. Los desenlaces de interés fueron dos: el desempeño predictivo, expresado mediante R^2 , RMSE, MAE o exactitud, y el conjunto de variables predictoras retenidas.

Respecto del diseño, resultaron admisibles los estudios observacionales, incluidos los análisis secundarios efectuados sobre cohortes.

Estrategia de búsqueda

Se examinaron cinco bases bibliográficas a lo largo del intervalo comprendido entre el 1 de enero de 2000 y el 31 de diciembre de 2025: PubMed/MEDLINE, Scopus, Web of Science, IEEE Xplore y Google Scholar. La cadena de recuperación articuló términos MeSH con términos libres, según la sintaxis adaptada que sigue: ("hand grip strength" OR "handgrip strength" OR "pinch strength" OR "grip force") AND ("hand anthropometry" OR "hand dimensions" OR "anthropometric measurements") AND ("machine learning" OR "artificial neural network" OR "deep learning" OR "random forest" OR "support vector machine" OR "XGBoost" OR "prediction model") AND (worker OR occupational OR industrial OR "manual labor" OR ergonomic). A fin de capturar trabajos que la vía electrónica no hubiese rescatado, se rastrearon, complementariamente, las referencias de los estudios incluidos.

Criterios de elegibilidad

La inclusión quedó sujeta al cumplimiento simultáneo de cuatro condiciones. El estudio debía haber reclutado poblaciones de trabajadores adultos o muestras concebidas para aplicaciones ergonómicas de orden ocupacional. Debía, asimismo, haber aplicado al menos un algoritmo de aprendizaje automático o un modelo predictivo no lineal en la estimación de la fuerza de prensión o de pinza. Una tercera exigencia consistía en la incorporación de variables antropométricas de la mano entre los predictores. La última exigía el reporte de, cuando menos, una métrica cuantitativa de desempeño. Por el contrario, se desestimaron los estudios ajenos a la población trabajadora, los circunscritos a la regresión lineal tradicional, los orientados a señales electromiográficas con prescindencia de la antropometría y, por último, las cartas al editor y los resúmenes de congreso desprovistos de texto completo. La elegibilidad se restringió a las publicaciones redactadas en inglés y en español.

Selección de estudios y extracción de datos

El proceso de selección se realizó en dos fases sucesivas: un cribado preliminar por título y resumen y un examen ulterior a texto completo. De cada estudio elegible se recabó un conjunto homogéneo de variables: autoría, año, país, sector ocupacional, tamaño muestral, rango etario, distribución por sexo, dimensiones antropométricas medidas, algoritmo o algoritmos implementados, esquema de partición de los datos, variables retenidas en el modelo definitivo y métricas de desempeño. Cuando un mismo estudio ponía a prueba varios modelos, prevaleció aquel que exhibía el mejor desempeño sobre el conjunto de prueba.

Evaluación de la calidad metodológica

La valoración de la calidad se apoyó en una adaptación de la herramienta PROBAST (Prediction model Risk Of Bias ASsessment Tool), que discrimina cuatro dominios: participantes, predictores, desenlace y análisis. A cada dominio se le asignó una categoría de riesgo de sesgo (bajo, alto o incierto). La índole narrativa de la síntesis sugirió prescindir del metaanálisis cuantitativo.

Síntesis

La síntesis adoptó una modalidad narrativa, reforzada con tablas comparativas. Se muestran los rangos de R^2 y de RMSE discriminando por tipo de algoritmo y por desenlace (prensión frente a pinza). En la misma línea, se consideraron robustos aquellos predictores que persistían en más de la mitad de los modelos examinados.

RESULTADOS


Selección de estudios

La pesquisa arrojó 387 registros, a los que la búsqueda manual incorporó otros 14. Depurados los duplicados, el total se redujo a 312 registros; de estos, 234 se eliminaron en el cribado por título y resumen. El examen a texto completo se realizó en 78 artículos, de los cuales se descartaron 66 por los motivos que muestra la Figura 1. Doce estudios, en última instancia, cumplieron los criterios de inclusión.

Características de los estudios incluidos

Los 12 estudios seleccionados fueron publicados entre 2005 y 2024 y procedían de seis países: Malasia (n=2), Taiwán (n=4), Turquía (n=2), Corea del Sur (n=1) e Irán (n=3) (ver figura 2). El tamaño muestral osciló entre 33 y 7.119 participantes, de modo que el agregado rebasó los 9.500 trabajadores adultos. En cuanto a los sectores representados se encuentra la industria manufacturera, la agricultura, los servicios sanitarios, el trabajo de oficina y diversos entornos académicos de orientación ocupacional. La Tabla 1 condensa las características principales.

Figura 1. Diagrama de flujo PRISMA 2020 del proceso de selección de estudios



Algoritmos utilizados y desempeño predictivo

De los doce estudios revisados, siete recurrieron a redes neuronales artificiales multicapa, el cual fue el algoritmo dominante. La investigación más reciente y metodológicamente más variada probó doce clasificadores distintos y obtuvo la mejor exactitud con k-nearest neighbors, un 96,75%, seguido por adaptive boosting (86,49%) y random forest (84,66%) al predecir tres tipos de pinza (Rostamzadeh et al., 2024). Frente a la regresión tradicional los algoritmos de aprendizaje automático arrojaron errores cuadráticos medios sistemáticamente más bajos y R^2 superiores, con ganancias que fueron de 0,02 a 0,17 (tabla 1).

Figura 2. Países donde se publicaron estudios




Tabla 1. Características de los estudios incluidos en la revisión sistemática (n = 12)

Estudio	País	Ocupación	N	Algoritmo principal	Desenlace y desempeño
Taha y Nazaruddin (2005)	Malasia	Trabajadores industriales	146	ANN con algoritmo genético	HGS; R ² ≈0,95 vs regresión 0,78
Ali et al. (2015)	Malasia	Operadores de desbrozadora	204	Red neuronal feedforward	HGS; MSE 0,017 (der.), 0,066 (izq.)
Sung et al. (2015)	Taiwán	Adultos con riesgo TME	33	ANN vs regresión por pasos	HGS R ² =0,92; key pinch R ² =0,86
Çakıt et al. (2015)	Turquía	Estudiantes de odontología	100	ANN multicapa	HGS; R ² =0,87 vs regresión 0,81
Lo et al. (2019)	Taiwán	Industria manufacturera	198	Regresión múltiple por pasos	5 tipos de fuerza; R ² =0,57–0,93
Chao et al. (2020)	Taiwán	Industria manufacturera	198	Regresión predictiva	HGS y pinzas lateral/palmar
Lo et al. (2020)	Taiwán	Sector sanitario	329	Regresión predictiva	HGS, pinch, press; modelos por sexo
Hwang et al. (2021)	Corea del Sur	Adultos con orientación ergonómica	164	MLP profundo vs regresión polinomial	HGS; R ² =0,77 RMSE 69 N (ICC 0,92)
Lo et al. (2021)	Taiwán	Industria manufacturera	198	Regresión múltiple por pasos	R ² ajustado 0,28–0,93 según par de fuerzas
Rostamzadeh et al. (2024)	Irán	Población con enfoque ocupacional	7,119	12 clasificadores ML (k-NN, RF, AdaBoost)	3 pinzas; exactitud hasta 96,75% (k-NN)
Sayadizadeh et al. (2024)	Irán	Cohorte organizacional PERSIAN	542	ANN con escaneo 3D de mano	HGS R ² =0,67; HPS R ² =0,52
Yetiş et al. (2024)	Turquía	Pacientes con sospecha de STC	112	4 algoritmos ML (RF, SVM, XGB, k-NN)	Predicción de STC; exactitud 0,86

Legenda: HGS = hand grip strength (fuerza de prensión); HPS = hand pinch strength; ANN = artificial neural network; MLP = multilayer perceptron; k-NN = k-nearest neighbors; RF = random forest; SVM = support vector machine; XGB = extreme gradient boosting; STC = síndrome del túnel carpiano; TME = trastornos musculoesqueléticos.

Variables predictorias retenidas

La Tabla 2 resume qué variables permanecieron en el modelo óptimo de cada estudio. El sexo se mantuvo en todos los modelos, sin excepción. Luego, las dos dimensiones antropométricas más estables fueron la longitud de la mano y la longitud de la palma, presentes en el 83% de los modelos. La circunferencia de muñeca, el ancho máximo de la mano y el índice de forma de la mano figuran al menos en el 50% de las investigaciones. La edad y el peso corporal fueron frecuentes, sin embargo su peso relativo fue menor en los modelos de pinza que en los de prensión manual.

Tabla 2 Frecuencia de variables predictorias retenidas en los modelos óptimos

Variable predictorias	Estudios (n/12)	Frecuencia (%)	Tipo de fuerza
Sexo	12	100%	Prensión y pinza
Longitud total de la mano	10	83%	Prensión y pinza
Longitud de palma	10	83%	Prensión y pinza
Ancho máximo de la mano	8	67%	Prensión y pinza
Circunferencia de muñeca	7	58%	Prensión
Edad	7	58%	Prensión y pinza
Masa corporal	6	50%	Prensión (principalmente)
Índice de forma de la mano	6	50%	Prensión y pinza
Longitud del pulgar	5	42%	Pinza
Talla	5	42%	Prensión
Span de agarre	4	33%	Prensión
Longitud del dedo índice	4	33%	Pinza

Calidad metodológica

La evaluación con PROBAST adaptada dejó ver un patrón persistente. En el dominio de predictores, riesgo de sesgo bajo: las mediciones antropométricas se hicieron con instrumental calibrado y protocolos La Sociedad Americana de Terapeutas de la Mano (ASHT, por sus siglas en inglés). En el dominio de análisis, en cambio, el riesgo fue alto, ya que diez de los doce estudios no realizaron validación externa, al menos cinco usaron muestras pequeñas en relación con el número de predictores, ocho omitieron por completo los intervalos de confianza en sus métricas de desempeño y sólo dos trabajos, el de Rostamzadeh et al. (2024) y Sayadizadeh et al. (2024) describieron una validación cruzada estructurada, con separación limpia entre datos de entrenamiento y prueba.

DISCUSION

Hallazgos principales

Esta es la primera revisión sistemática de modelos de aprendizaje automático aplicados a predecir fuerza de prensión y pinza a partir de la antropometría de mano en poblaciones trabajadoras. Se identificaron tres hallazgos relevantes: el primero: el aprendizaje automático sí mejora a la regresión lineal, pero menos de lo que promete la literatura entusiasta sobre estos métodos, ya que en la mayoría de los estudios el aumento absoluto del R^2 ronda entre 0,05 y 0,10. El segundo tiene que ver con las variables, debido a que son menos de las esperadas considerando todo lo que se puede medir en una mano humana: sexo, longitud de la mano, longitud de la palma y ancho máximo bastan para capturar casi todo el desempeño de los modelos óptimos; y el tercero tiene que ver con que la mayoría de los estudios son realizados en países asiáticos con muestras de uno o dos centenares de trabajadores y la generalización a poblaciones latinoamericanas o africanas sigue pendiente.

Algoritmos: lo que funciona y lo que aún no se sabe

Durante dos décadas, las redes neuronales artificiales fueron el algoritmo de referencia en este nicho de investigación, ya que los estudios que las contrastan directamente con la regresión lineal (Taha y Nazaruddin, 2005; Sung et al., 2015; Ali et al., 2015; Hwang et al., 2021) repiten el mismo resultado: superioridad en error cuadrático medio.

Pero en los últimos años los modelos basados en árboles como random forest y extreme gradient boosting empezaron a competir, y en algunos casos fueron superiores. Estudios como el de Rostamzadeh et al. (2024), con más de siete mil participantes, encontró que k-nearest neighbors logró la mejor exactitud para predecir fuerza de pinza. Un hallazgo curioso porque contradice la idea tan extendida de que el modelo más complejo siempre rinde más. Lo que falta en el campo de investigación es una comparación multi-algoritmo sobre la misma cohorte de trabajadores, con métricas armonizadas y validación externa.

Variables predictoras: la convergencia parcial

Que el sexo aparezca en todos los modelos no sorprende a nadie, ya que las diferencias musculares y antropométricas entre hombres y mujeres son lo bastante marcadas como para esperarlo. Pero el dato tiene una lectura práctica: probablemente conviene construir modelos estratificados por sexo en lugar de modelos generales con una corrección añadida. La estabilidad de la longitud y el ancho de la mano apunta en una dirección parecida ya que son medibles en pocos minutos con un calibrador digital y recoge casi toda la información antropométrica útil. Las pinzas piden algo más, necesitan la longitud del pulgar y del dedo índice, lo cual encaja con la biomecánica de la prehensión fina (Lo et al., 2021). En la práctica, esto significa que los protocolos de campo pueden reducirse a cuatro o seis dimensiones sin perder poder predictivo.

Implicaciones para la ergonomía ocupacional

Hay al menos tres usos directos, diseñar herramientas y empuñaduras es el primero: si conoces la distribución de fuerza esperable en una población concreta de trabajadores puedes dimensionar diámetros, longitudes y resistencias al percentil de interés. El segundo es el tamizaje de aptitud al puesto; predecir la fuerza de un trabajador a partir de mediciones rápidas abarata y acelera las evaluaciones masivas. El tercero es el que más parece relevante: la vigilancia longitudinal; comparar la fuerza medida con la predicha permite detectar desviaciones que pueden anteceder a un trastorno musculoesquelético. Yetiş et al. (2024) ya muestra que combinar antropometría y fuerza discrimina el síndrome del túnel carpiano con exactitud superior al 85%. Una puerta abierta a algoritmos de vigilancia dentro de los programas de salud laboral.

Limitaciones de la evidencia y de esta revisión

Se evidencia ausencia de validación externa en muchos estudios, además las muestras son pequeñas para los modelos más complejos y la heterogeneidad geográfica y ocupacional vuelve difícil trasladar un modelo de una población a otra. De igual forma la propia definición de “trabajador” varía entre estudios, y algunos incluyen estudiantes o muestras mixtas bajo un concepto ergonómico. Además de esto pocos estudios siguen las recomendaciones TRIPOD para modelos predictivos, y dar cuenta de la incertidumbre (intervalos de confianza, calibración) es presentada en pocas investigaciones y definitivamente es parte de la norma que se debe seguir en estos casos.

En esta investigación también se presentan limitaciones, en primer lugar la síntesis terminó siendo narrativa, ya que la heterogeneidad de desenlaces y métricas no permitía una estimación cuantitativa agregada del efecto del aprendizaje automático sobre la regresión. Además de esto vale la pena mencionar la diferencia entre “población trabajadora” y “población general con interés ergonómico” pues en ciertos estudios respondió al juicio de los autores más que a una distinción precisa.

CONCLUSIONES

El aprendizaje automático mejora a la regresión lineal tradicional para predecir fuerza de prensión y pinza desde la antropometría de mano en trabajadores. La mejora es consistente, sí, pero discreta. La ganancia típica en R^2 va de 0,05 a 0,10 (suficiente para justificar su uso cuando hace falta precisión individualizada) pero no tanto como para desechar las ecuaciones de regresión bien ajustadas en el trabajo de campo. Además, existe un detalle que ordena el panorama: un subconjunto reducido de dimensiones (sexo, longitud y ancho de la mano, circunferencia de muñeca, índice de forma) explica el grueso del desempeño. De ahí que tenga sentido pensar en protocolos de medición simplificados para entornos ocupacionales.

Asimismo, es importante dirigir las investigaciones de este tipo en muestras representativas en las regiones que casi nadie ha estudiado, como América latina, y validar los modelos entre cohortes ocupacionales distintas, estratificar por sexo y por sector, integrar antropometría tridimensional con sensores inerciales y adoptar estándares de reporte como TRIPOD-AI. Mientras tanto, llevar estos modelos a un programa de salud laboral exige mucho cuidado ya que la transferencia entre poblaciones no es automática, y nada debería usarse de forma operativa sin validarlo antes a nivel local.

REFERENCIAS

1. Ali, M., Azmir, N., Ghazali, M., Yahya, M., & Song, J. (2015). Predicting hand grip strength of hand held grass cutter workers: Neural network vs regression. *Procedia Manufacturing*, 2, 445–449. <https://doi.org/10.1016/j.promfg.2015.07.077>
2. Çakıt, E., Durgun, B., & Cetik, O. (2015). A neural network approach for assessing the relationship between grip strength and hand anthropometry. *Neural Network World*, 25(6), 603–617. <https://doi.org/10.14311/NNW.2015.25.030>
3. Chao, S.-M., Chiu, Y.-C., & Lo, V. E.-W. (2020). The prediction models of the maximum power grip strength and pinch strength in Taiwan manufacturing workers. En R. Goossens & A. Murata (Eds.), *Advances in Social and Occupational Ergonomics. AHFE 2019. Advances in Intelligent Systems and Computing* (Vol. 970, pp. 473–479). Springer. https://doi.org/10.1007/978-3-030-20145-6_46
4. Hajaghadzadeh, M., Taghizadeh, M., Mohebbi, I., & Khalkhali, H. (2022). Hand anthropometric dimensions and strengths in workers: A comparison of three occupations. *Human Factors and Ergonomics in Manufacturing & Service Industries*, 32(5), 373–388. <https://doi.org/10.1002/hfm.20959>
5. Hwang, J., Lee, J., & Lee, K.-S. (2021). A deep learning-based method for grip strength prediction: Comparison of multilayer perceptron and polynomial regression approaches. *PLOS ONE*, 16(2), e0246870. <https://doi.org/10.1371/journal.pone.0246870>
6. Klum, M., Wolf, M. B., Hahn, P., Leclère, F. M., Bruckner, T., & Unglaub, F. (2012). Predicting grip strength and key pinch using anthropometric data, DASH questionnaire and wrist range of motion. *Archives of Orthopaedic and Trauma Surgery*, 132(12), 1807–1811. <https://doi.org/10.1007/s00402-012-1602-8>
7. Lo, V. E.-W., Chao, S.-M., & Tu, H.-H. (2020). Normative hand strength of healthcare industry workers in central Taiwan. *International Journal of Environmental Research and Public Health*, 18(1), 187. <https://doi.org/10.3390/ijerph18010187>
8. Lo, V. E.-W., Chiu, Y.-C., & Tu, H.-H. (2021). Can we use grip strength to predict other types of hand exertions? An example of manufacturing industry workers. *International Journal of Environmental Research and Public Health*, 18(3), 856. <https://doi.org/10.3390/ijerph18030856>
9. Lo, V. E.-W., Chiu, Y.-C., Tu, H.-H., Liu, C.-W., & Yu, C.-Y. (2019). A pilot study of five types of maximum hand strength among manufacturing industry workers in Taiwan. *International Journal of Environmental Research and Public Health*, 16(23), 4742. <https://doi.org/10.3390/ijerph16234742>
10. Mathiowetz, V., Kashman, N., Volland, G., Weber, K., Dowe, M., & Rogers, S. (1985). Grip and pinch strength: Normative data for adults. *Archives of Physical Medicine and Rehabilitation*, 66(2), 69–74.
11. Myles, L., Barnett, F., & Massy-Westropp, N. (2025). Do functional and biological factors influence the handgrip strength: A systematic review. *British Journal of Occupational Therapy*, 88(4), 198–216. <https://doi.org/10.1177/03080226241293617>
12. Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, n71. <https://doi.org/10.1136/bmj.n71>
13. Rostamzadeh, S., Abouhossein, A., Alam, K., Vosoughi, S., & Sattari, S. S. (2024). Exploratory analysis using machine learning algorithms to predict pinch strength by anthropometric and socio-demographic features. *International Journal of Occupational Safety and Ergonomics*, 30(2), 471–481. <https://doi.org/10.1080/10803548.2024.2322888>
14. Sayadizadeh, M., Daliri, M., Rahimi, M., Salehipour, P., Sadeghi, M., Khaje Mozafari, J., & Moradi, A. (2024). Grip and pinch strength prediction models based on hand anthropometric parameters: An analytic cross-sectional study. *BMC Musculoskeletal Disorders*, 25(1), 809. <https://doi.org/10.1186/s12891-024-07914-z>
15. Sung, P.-C., Hsu, C.-C., Lee, C.-L., Chiu, Y.-S. P., & Chen, H.-L. (2015). Formulating grip strength and key pinch strength prediction models for Taiwanese: A comparison between stepwise regression and artificial neural networks. *Journal of Ambient Intelligence and Humanized Computing*, 6(1), 37–46. <https://doi.org/10.1007/s12652-014-0245-8>
16. Taha, Z., & Nazaruddin. (2005). Grip strength prediction for Malaysian industrial workers using artificial neural networks. *International Journal of Industrial Ergonomics*, 35(9), 807–816. <https://doi.org/10.1016/j.ergon.2005.01.012>
17. Tomkinson, G. R., Lang, J. J., Rubín, L., McGrath, R., Gower, B., Boyle, T., Klassen, T. D., Bohannon, R. W., Cruz-Jentoft, A. J., Dodds, R., Granic, A., Léger, L. A., Liu, Y., Magnussen, C. G., Marfell-Jones, M., Mayhew, A. J., Morrow, J. R., Nevill, A., Norman, K., ... Ortega, F. B. (2025). International norms for adult handgrip strength: A systematic review of data on 2.4 million adults aged 20 to 100+ years from 69 countries and regions. *Journal of Sport and Health Science*, 14, 101014. <https://doi.org/10.1016/j.jshs.2024.101014>
18. Yetiş, M., Kocaman, H., Canlı, M., Yıldırım, H., Yetiş, A., & Ceylan, İ. (2024). Carpal tunnel syndrome prediction with machine learning algorithms using anthropometric and strength-based measurement. *PLOS ONE*, 19(4), e0300044. <https://doi.org/10.1371/journal.pone.0300044>

FINANCIACIÓN

Ninguna.

CONFLICTOS DE INTERÉS

No existen.

CONTRIBUCIÓN DE AUTORÍA

Redacción - borrador original: Misael Ron, Evelin escalona.

Redacción - revisión y edición: Misael Ron, Evelin escalona.