

Sistema de telemonitorización para estimar el nivel de actividad del miembro superior mediante wearables

Rubira-Úbeda, P.^{a,*}, Martínez-Pascual, D.^b, Vales, Y.^b, Herraiz-Sala, M.^b, Lledó, Luis Daniel.^b, García-Aracil, Nicolás.^b

^aInnovative Devices for Rehabilitation and Assistance, IDRHA, Edificio Quorum I, Universidad Miguel Hernández, Avenida de la Universidad, s/n. 03202 Elche, Alicante, España

^bGrupo de Robótica e Inteligencia Artificial, Instituto de Bioingeniería de Elche, Universidad Miguel Hernández, Avenida de la Universidad, s/n. 03202 Elche, Alicante, España

Resumen

Este estudio presenta una arquitectura de telemonitorización basada en dispositivos *wearables* para la cuantificación objetiva del uso funcional del miembro superior en entornos no supervisados. El sistema emplea una arquitectura basada en tres niveles (adquisición, aplicación móvil y almacenamiento en la nube) para procesar señales inerciales. La segmentación automática mediante el algoritmo K-Means ($k = 2$) permitió identificar dos niveles de actividad funcional. Los resultados muestran que el 81 % de las métricas no siguen una distribución normal, lo que motivó el uso de pruebas no paramétricas para su validación. El test de Mann-Whitney U confirmó diferencias estadísticamente significativas en todas las variables analizadas, alcanzando niveles de significancia máximos ($p < 0,0001$) en parámetros críticos como la energía acumulada y el rango de movimiento. El estudio con voluntarios sanos valida la robustez técnica del sistema y su capacidad de interpretación clínica, estableciendo un marco de referencia para la monitorización remota de poblaciones con diversas afecciones motoras o en procesos de recuperación funcional.

Palabras clave: Tecnología de asistencia e ingeniería de rehabilitación, Ingeniería de rehabilitación y asistencia sanitaria, Toma de decisiones y procesos cognitivos, Automatización centrada en el ser humano, Interfaces inteligentes

Telemonitoring system for estimating upper limb activity level using wearables

Abstract

This study presents a telemonitoring architecture based on wearable devices for the objective quantification of upper limb functional use in unsupervised environments. The system employs a three-level architecture (acquisition, mobile application, and cloud storage) to process inertial signals. Automatic segmentation using the K-Means algorithm ($k = 2$) allowed two levels of functional activity to be identified. The results show that 81 % of the metrics do not follow a normal distribution, which led to the use of non-parametric tests for validation. The Mann-Whitney U test confirmed statistically significant differences in all the variables analysed, reaching maximum significance levels ($p < 0,0001$) in critical parameters such as accumulated energy and range of motion. The study with healthy volunteers validates the technical robustness of the system and its clinical interpretation capacity, establishing a reference framework for the remote monitoring of populations with various motor conditions or undergoing functional recovery processes.

Keywords: Assistive technology and rehabilitation engineering, Rehabilitation engineering and healthcare delivery, Decision making and cognitive processes, Human centred automation, Intelligent interfaces

1. Introducción

El declive funcional asociado al envejecimiento constituye uno de los principales retos de la sociedad contemporánea. Este proceso implica tanto el deterioro cognitivo como la

disminución progresiva de las capacidades físicas, asociadas a cambios estructurales cerebrales (Coelho et al., 2021), al aumento en la prevalencia de enfermedades (Peters, 2006) y a la cronicidad de múltiples patologías (Steinmetz et al., 2024). Como resultado, el deterioro funcional conduce frecuentemente

*Autor para correspondencia: pablo.rubira@goumh.umh.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

a una pérdida de autonomía en la realización de las actividades de la vida diaria (AVD). Al mismo tiempo, la mayoría de los mayores prefieren vivir en sus propios hogares durante el mayor tiempo posible en lugar de mudarse a una residencia (Wiles et al., 2012).

Desde una perspectiva demográfica, la población mayor de 65 años superará los 1.500 millones en 2050, representando aproximadamente el 16 % de la población mundial (Vollset et al., 2020; Chatterji et al., 2015). Este grupo presenta una elevada vulnerabilidad frente al daño cerebral adquirido; en particular, la incidencia de ictus se duplica cada década a partir de los 55 años (Boehme et al., 2017). A ello se suman las secuelas neurológicas persistentes asociadas al denominado “COVID-19 prolongado” (SeyedSaadat et al., 2021). Este escenario plantea un desafío estructural para la sostenibilidad de los sistemas sanitarios (Steinmetz et al., 2024).

En los últimos años, los dispositivos *wearables* basados en sensores inerciales han demostrado un gran potencial para la monitorización continua de la actividad física (Patel et al., 2012; Yang and Hsu, 2010). Estos sistemas permiten la adquisición objetiva de señales biomecánicas en entornos no supervisados (Piwek et al., 2016). No obstante, gran parte de la literatura se centra en métricas globales de actividad (como el conteo de pasos o el gasto energético) sin abordar específicamente la caracterización funcional del miembro superior (Preece et al., 2009; Bai et al., 2016). En rehabilitación neurológica, la cuantificación del uso real del brazo fuera del entorno clínico continúa siendo un desafío abierto (Lang et al., 2007; Bailey and Lang, 2013). Las escalas tradicionales presentan limitaciones de subjetividad y resolución temporal, mientras que numerosos estudios se desarrollan en laboratorio (Dobkin, 2005; Warner et al., 2019). Asimismo, la segmentación automática de niveles funcionales mediante aprendizaje no supervisado en contextos domiciliarios sigue siendo un área en desarrollo (Lara and Labrador, 2013; Bulling et al., 2014).

En este contexto, el presente trabajo propone una arquitectura de telemonitorización capaz de capturar y procesar datos inerciales, junto con un enfoque de aprendizaje automático no supervisado para la segmentación objetiva de niveles de actividad funcional del miembro superior en entornos no controlados. Las principales contribuciones del estudio son: (i) el diseño de una infraestructura escalable de adquisición y gestión de datos; (ii) la definición de métricas biomecánicas orientadas a la caracterización funcional; y (iii) la aplicación de técnicas de segmentación no supervisada para la identificación automática de patrones de uso funcional relevantes en contextos clínicos.

2. Materiales y Métodos

2.1. Arquitectura del Sistema de Telemonitorización

La metodología propuesta combina una arquitectura de tres niveles, el procesamiento de señales inerciales y modelos de aprendizaje automático no supervisado. El flujo de trabajo permite la transición desde la adquisición continua de señales biomecánicas hasta la generación de métricas orientadas a la interpretación clínica del uso funcional del miembro superior en entornos no supervisados. El diseño del sistema prioriza

la escalabilidad, la eficiencia energética y la integridad de los datos.

Tal y como se muestra en la Figura 1, el sistema ha sido diseñado siguiendo un paradigma de computación en tres niveles (*3-tier architecture*), desacoplando los procesos de adquisición, transmisión y almacenamiento de datos. Estos procesos se realizan en las capas de adquisición de datos, aplicación móvil y almacenamiento en la nube respectivamente, explicadas en secciones posteriores. Esta separación funcional permite garantizar modularidad, escalabilidad horizontal y tolerancia a fallos en escenarios de conectividad variable.




Figura 1: Arquitectura del sistema de telemonitorización en tres niveles: (1) Adquisición de señales inerciales mediante el wearable, (2) Gestión local y transmisión vía aplicación móvil (BLE), y (3) Almacenamiento y persistencia en la infraestructura cloud de Microsoft Azure.

2.1.1. Adquisición de datos

La adquisición de datos se realiza mediante un dispositivo *wearable* tipo *smartwatch* equipado con una unidad de medición inercial (IMU) de seis grados de libertad. El modelo seleccionado fue el *Google Pixel Watch 3*, que integra un acelerómetro y un giroscopio triaxiales configurados a una frecuencia de muestreo de 100 Hz. Esta frecuencia permite capturar adecuadamente los componentes dinámicos del movimiento humano, cuyo contenido espectral se sitúa típicamente por debajo de 20 Hz, cumpliendo el criterio de Nyquist y evitando distorsiones por submuestreo.

Las señales son preprocesadas en el propio dispositivo para reducir ruido de alta frecuencia y optimizar el consumo energético, ya que el dispositivo opera de manera continua durante periodos prolongados.

2.1.2. Aplicación móvil para gestión local

El segundo nivel de la arquitectura corresponde a una aplicación móvil basada en el sistema operativo Android (Figura 1). La comunicación entre el dispositivo *wearable* y el *smartphone* se realiza mediante el protocolo *Bluetooth Low Energy (BLE)*, seleccionado por su bajo consumo energético y su capacidad de transmisión eficiente de datos en tiempo real.

La aplicación móvil gestiona la recepción de los datos en brutos proporcionados por la IMU, su estructuración en paquetes de datos temporales y la validación básica

de integridad antes de su transmisión. Esta capa intermedia desacopla la adquisición física del procesamiento remoto, permitiendo almacenamiento temporal local ante interrupciones de conectividad y garantizando la persistencia de la información.

2.1.3. Infraestructura de almacenamiento en la nube

El tercer nivel del sistema se implementa sobre una infraestructura *cloud-native* basada en *Microsoft Azure*. Los datos son transmitidos en formato JSON a través de *Azure IoT Hub*, que actúa como punto de entrada seguro y escalable. Posteriormente, la información se almacena en una base de datos SQL.

Esta arquitectura permite la escalabilidad automática ante incrementos en el volumen de datos, facilita la gestión de múltiples usuarios simultáneos y sirve como backend para un *dashboard* clínico destinado a la visualización y al seguimiento remoto de los participantes.

2.2. Procesamiento de Señales y Extracción de Métricas

El procesamiento de los datos provenientes del dispositivo *wearable* se divide en dos fases principales: (i) el preprocesamiento de las señales inerciales brutas y (ii) la extracción de métricas cuantitativas de movilidad.

Los datos adquiridos consisten en aceleración lineal $a(t) = [a_x(t), a_y(t), a_z(t)]$ y velocidad angular $\omega(t) = [\omega_x(t), \omega_y(t), \omega_z(t)]$, ambas en tres dimensiones. Las métricas se calculan utilizando la totalidad de las muestras registradas durante cada jornada, permitiendo obtener una caracterización global del nivel de actividad diaria del miembro superior.

El primer nivel de caracterización consiste en métricas que operan directamente sobre las señales temporales:

- **Magnitud de la Señal (MAD):** Representa la intensidad instantánea del movimiento, registrada por cada sensor, independientemente de su dirección. Se define como la norma euclídea del vector de la señal $\mathbf{s}(t) = [s_x(t), s_y(t), s_z(t)]$:

$$MAD(t) = \|\mathbf{s}(t)\|_2 = \sqrt{s_x(t)^2 + s_y(t)^2 + s_z(t)^2} \quad (1)$$

Esta métrica permite capturar variaciones dinámicas tanto en la aceleración como en la velocidad angular en cada instante. Para obtener una representación agregada diaria, se calculó la media temporal del MAD a lo largo de todas las muestras registradas en la jornada d :

$$MAD_d = \frac{1}{N_d} \sum_{t=1}^{N_d} MAD(t) \quad (2)$$

- **Energía de la Señal (E):** Cuantifica la intensidad acumulada del movimiento o de la rotación. Esta métrica se calculó de forma independiente para las señales del acelerómetro y del giroscopio, proporcionando una medida de la magnitud total de la actividad en el día d :

$$E_d = \sum_{t=1}^{N_d} (s_x(t)^2 + s_y(t)^2 + s_z(t)^2) \quad (3)$$

donde N_d representa el número total de muestras del día y $s_{x,y,z}$ son las componentes de la señal correspondiente.

Esta métrica acumula la intensidad del movimiento a lo largo del tiempo, lo que suaviza los cambios bruscos y permite identificar patrones de actividad globales de manera más clara.

Este tipo de métricas basadas en la magnitud y energía de señales inerciales son fundamentales para la cuantificación objetiva del movimiento humano en entornos no supervisados (Bao and Intille, 2004; Bulling et al., 2014).

Para una caracterización más robusta del comportamiento angular del miembro superior, las señales inerciales se transforman desde el sistema de referencia del sensor hacia una estimación de orientación global. Este proceso se realiza mediante el filtro de Madgwick, un algoritmo de fusión sensorial diseñado para sistemas AHRS (*Attitude and Heading Reference Systems*) (Madgwick et al., 2010; Madgwick, 2010).

El filtro combina las medidas del acelerómetro y del giroscopio, minimizando el efecto de la deriva acumulativa (*drift*) propia de la integración del giroscopio y reduciendo el impacto del ruido en condiciones dinámicas. Como salida se obtiene un cuaternión normalizado $q(t)$, que posteriormente se transforma a ángulos de Euler (Roll, Pitch y Yaw) para facilitar su interpretación biomecánica.

A partir de los ángulos $\theta(t)$ obtenidos en cada eje se definen las siguientes métricas:

- **Rango de Movimiento:**

$$R = \max(\theta(t)) - \min(\theta(t)) \quad (4)$$

que representa la excursión angular máxima observada en el intervalo analizado.

- **Variabilidad:** calculada como la desviación estándar de la señal angular en el intervalo considerado, proporciona una medida de consistencia del movimiento:

$$\sigma_\theta = \sqrt{\frac{1}{n} \sum_{t=1}^n (\theta(t) - \bar{\theta})^2} \quad (5)$$

- **Desplazamiento Angular Acumulado:**

$$A = \sum_{t=2}^n |\theta(t) - \theta(t-1)| \quad (6)$$

estima la distancia angular total recorrida por el miembro superior durante el intervalo analizado.

La utilización de métricas basadas en rango angular, variabilidad y desplazamiento acumulado ha demostrado ser relevante para la caracterización del uso funcional del miembro superior en estudios instrumentados con sensores inerciales (Bailey and Lang, 2013; Lang et al., 2007).

2.3. Población del estudio

Se realizó un estudio piloto observacional en el que participaron 9 personas (7 varones y 2 mujeres) sin patologías neurológicas ni limitaciones funcionales conocidas, con edades

comprendidas entre 23 y 39 años. La media de edad fue de $29,56 \pm 5,34$ años con una mediana de 31 años.

Previamente al inicio del estudio, todos los participantes fueron informados sobre el procedimiento experimental, y firmaron el correspondiente consentimiento informado.

2.4. Protocolo del estudio

El objetivo principal fue validar la viabilidad técnica de la telemonitorización y analizar la estabilidad de las métricas extraídas como biomarcadores digitales (Albert et al., 2012). A los participantes se les indicó que llevaran puesto el dispositivo en la muñeca del miembro superior no dominante durante sus actividades diarias habituales durante el mayor tiempo posible. Bajo este protocolo, cada unidad de análisis corresponde a una jornada completa de registro continuo, acumulando un conjunto final de aproximadamente 70 días de datos.

A diferencia de algunos estudios realizados en laboratorio (Dobkin, 2005; Warner et al., 2019), este diseño basado en condiciones de vida real, permite evaluar la robustez del sistema frente a la variabilidad inter-usuario, patrones de movimiento no estructurados y ruido ambiental.

2.5. Segmentación de Niveles de Actividad

A partir de las métricas descritas en la Sección 2.2, se construyó un vector de características para cada día de registro, constituyendo la unidad de análisis del modelo. Cada vector $\mathbf{x}_d$ asociado al día d se define como:

$$\mathbf{x}_d = [MAD_d, E_d, R_{roll,d}, R_{pitch,d}, R_{yaw,d}, \sigma_{roll,d}, \sigma_{pitch,d}, \sigma_{yaw,d}, A_{roll,d}, A_{pitch,d}, A_{yaw,d}]$$

Cada día queda así representado como un punto en un espacio vectorial $\mathbf{x}_d \in \mathbb{R}^{11}$.

Dado que las métricas presentan diferentes escalas y magnitudes, se aplicó una normalización Min-Max a cada característica. Esta transformación garantiza que todas las variables se encuentren en el rango $[0, 1]$, evitando que aquellas con mayor escala numérica dominen el cálculo de distancias en el espacio de características.

Para la segmentación automática de los niveles de actividad se empleó el algoritmo K-Means, un método de aprendizaje no supervisado cuyo objetivo es particionar el conjunto X en k grupos, minimizando la varianza intra-cluster. Formalmente, el algoritmo busca minimizar la función objetivo:

$$J = \sum_{i=1}^k \sum_{\mathbf{x}_d \in C_i} \|\mathbf{x}_d - \mu_i\|_2^2 \quad (7)$$

donde C_i representa el conjunto de observaciones asignadas al cluster i y μ_i su centroide correspondiente. Se evaluó la configuración con $k = 2$ clusters, con el objetivo de analizar la viabilidad de una segmentación binaria (actividad baja/alta). Cada día de registro fue asignado al cluster cuyo centroide resultó más cercano en términos de distancia euclidiana.

Dado que el espacio de características es multidimensional, se empleó la técnica de reducción de dimensionalidad *t-Distributed Stochastic Neighbor Embedding (t-SNE)* (Van der Maaten and Hinton, 2008) para proyectar los vectores normalizados en un espacio bidimensional. Esta

técnica preserva las relaciones locales de proximidad entre observaciones, permitiendo una visualización intuitiva de la separación entre grupos.

La caracterización de los grupos resultantes se basó en el análisis de la distribución de las métricas biomecánicas originales. Bajo este enfoque, los segmentos con magnitudes superiores en energía, rango angular y variabilidad fueron asociados con patrones de mayor demanda funcional, permitiendo así una interpretación clínica coherente de la segmentación automática.

3. Resultados y Discusión

3.1. Segmentación con $k = 2$

La aplicación del algoritmo K-Means con $k = 2$ permitió identificar dos grupos en el espacio de características. La proyección mediante t-SNE (Figura 2) muestra una separación entre ambos clusters, evidenciando una estructura subyacente coherente en los datos.




Figura 2: Proyección t-SNE de los vectores de características con $k = 2$. Cada punto representa un día de registro, coloreado según el cluster asignado.

El análisis de la distribución de métricas normalizadas (Figura 3) revela que uno de los grupos presenta valores sistemáticamente superiores en energía acumulada, rango angular y desplazamiento total, lo que se interpreta como un patrón de mayor actividad funcional del miembro superior. El segundo grupo muestra valores inferiores en dichas métricas, siendo asociado a un nivel de actividad reducido.

Desde una perspectiva clínica, esta segmentación binaria resulta coherente con el objetivo del sistema, orientado principalmente a la detección de bajo uso funcional del miembro superior.

3.2. Análisis estadístico

Se realizó un análisis estadístico para validar la capacidad de segmentación funcional del sistema propuesto. En primer lugar, se evaluó la distribución de las 11 métricas biomecánicas mediante el test de Kolmogorov-Smirnov, dado que el tamaño

Diferencias de Métricas entre Clusters (Validación Funcional)




Figura 3: Distribución y comparación de las métricas biomecánicas entre los clusters de actividad funcional. Las cajas representan la mediana y los rangos intercuartílicos, mientras que los puntos individuales muestran la dispersión total de la muestra. Las comparaciones estadísticas indicadas con asteriscos rojos en función del nivel de significancia, se realizaron mediante el test de Mann–Whitney U.

muestral superaba los 50 registros Razali and Wah (2011). Se determinó que el 81 % de las variables (9 de 11) no seguían una distribución normal ($p < 0,05$), destacando métricas como *MAD_Acel* y *Varianza_Yaw*. Únicamente *Energia_Giros* y *Rango_Pitch* mostraron un comportamiento cercano a la normalidad.

A continuación, para validar la separación de los grupos, se aplicó el test de *Mann-Whitney U* Pratt (1959). Este análisis para datos que tienden a la no normalidad, evalúa si las distribuciones de dos grupos independientes difieren significativamente basándose en la ordenación por rangos de las observaciones, lo que permite comparar de forma robusta la posición central de las muestras sin asumir una distribución normal en los datos. Como se observa en la Figura3, los resultados confirmaron diferencias estadísticamente significativas en la mayoría de las métricas. Destacan variables como *Varianza_Yaw* y *Rango_Roll*, las cuales presentan una separación clara entre medianas y un nivel de significancia máximo (* * *), tal como se detalla numéricamente en la Tabla1. Estos resultados demuestran que los *clusters* no son agrupaciones arbitrarias, sino que representan niveles de uso funcional claramente diferenciados en términos de intensidad y rango de movimiento.

Tabla 1: Medianas de las variables del vector de características y niveles de significación estadística para cada cluster.

Métrica	Cluster 0	Cluster 1	<i>p</i> -value
MAD_Acel	0.031644	0.014727	$p < 0,01$
MAD_Giros	0.018077	0.009789	$p < 0,05$
Energia_Acel	0.854212	0.197057	$p < 0,0001$
Energia_Giros	0.332975	0.113332	$p < 0,0001$
Acumulado_Total	0.244038	0.057083	$p < 0,0001$
Varianza_Roll	0.190448	0.019234	$p < 0,0001$
Varianza_Pitch	0.315943	0.057859	$p < 0,0001$
Varianza_Yaw	0.339808	0.007466	$p < 0,0001$
Rango_Roll	0.997078	0.192455	$p < 0,0001$
Rango_Pitch	0.664131	0.288537	$p < 0,0001$
Rango_Yaw	0.947112	0.104019	$p < 0,0001$

4. Conclusiones

El presente trabajo ha demostrado la viabilidad técnica y metodológica de una arquitectura de telemonitorización basada en dispositivos *wearables* para la segmentación funcional del miembro superior en entornos no supervisados. La integración de una arquitectura de tres niveles (dispositivo *wearable*, aplicación móvil e infraestructura en la nube) permitió una adquisición continua y robusta de señales inerciales, garantizando escalabilidad, integridad de datos y potencial aplicabilidad clínica.

Desde el punto de vista analítico, la definición de un vector de características en $\mathbb{R}^{11}$, compuesto por métricas de intensidad y orientación derivadas del filtro de Madgwick, proporcionó una representación cuantitativa del comportamiento funcional diario. La aplicación de técnicas de aprendizaje no supervisado mediante el algoritmo *K-Means* ($k = 2$) permitió identificar automáticamente dos niveles diferenciados de actividad funcional.

El análisis estadístico confirmó la validez de esta segmentación. Dado que el 81 % de las métricas no seguían una distribución normal, se emplearon pruebas no paramétricas para su validación. El test de Mann–Whitney U evidenció diferencias estadísticamente significativas en todas las variables analizadas, alcanzando niveles de significancia máximos ($p < 0,0001$) en parámetros críticos como la energía acumulada, la variabilidad angular y el rango de movimiento. Estos resultados demuestran que los *clusters* obtenidos no son agrupaciones arbitrarias, sino que representan niveles funcionales claramente diferenciados en términos de intensidad y amplitud de movimiento.

El estudio piloto con voluntarios sanos valida la robustez técnica del sistema y establece un marco de referencia preliminar para su futura aplicación en poblaciones clínicas, especialmente en contextos de rehabilitación neurológica y monitorización domiciliaria. Como líneas futuras, se plantean varias mejoras a realizar. En primer lugar la ampliación del tamaño muestral, ya que el actual ($n = 9$) limita la potencia estadística y la generalización de los resultados. Este aumento en la cantidad de datos permitirá a su vez la exploración de segmentaciones multiclasa ($K > 2$). Además, para validar el sistema frente a poblaciones con patologías, se debe considerar la inclusión de pacientes con afectación motora.

Desde una perspectiva técnica, aunque la base de datos SQL ha sido suficiente para este estudio, el volumen de datos generado sugiere una evolución hacia bases de datos de series temporales. Finalmente, se deberá evaluar el consumo energético del smartwatch bajo uso intensivo y la robustez del sistema en escenarios de baja conectividad persistente.

En conjunto, la propuesta presentada constituye un avance hacia sistemas de salud digital capaces de proporcionar cuantificación objetiva, continua y válida del uso funcional del miembro superior.

Agradecimientos

Este trabajo ha sido financiado parcialmente por Agencia Estatal de Investigación, la Unión Europea-Next Generation EU y Generalitat Valenciana a través de los proyectos CIPROM/2022/12, PID2022-139957OB-I00 y CPP2023-010685.

Referencias

Albert, M. V., Kording, K., Herrmann, M., Jayaraman, A., 2012. Fall classification by machine learning using mobile phones. *PLOS ONE* 7 (5), e36556.
DOI: 10.1371/journal.pone.0036556

Bai, Y., Hibbing, P., Mantis, C., Welk, G., 2016. Upper limb activity monitoring in stroke patients using wearable sensors. *Journal of NeuroEngineering and Rehabilitation* 13 (1), 1–12.

Bailey, R. R., Lang, C. E., 2013. Quantifying real-world upper limb activity in nondisabled adults and adults with chronic stroke. *Neurorehabilitation and Neural Repair* 27 (3), 249–257.

Bao, L., Intille, S. S., 2004. Activity recognition from user-annotated acceleration data. In: *Pervasive Computing*. Springer, pp. 1–17.

Boehme, A. K., Esenwa, C., Elkind, M. S., 2017. Stroke epidemiology, midlife, and beyond. *Circulation Research* 120 (3), 472–495.
DOI: 10.1161/CIRCRESAHA.116.309144

Bulling, A., Blanke, U., Schiele, B., 2014. A tutorial on human activity recognition using body-worn inertial sensors. *ACM Computing Surveys* 46 (3), 1–33.

Chatterji, S., Byles, J., Cutler, D., Seeman, T., Verdes, E., 2015. Health, functioning, and disability in older adults—present status and future implications. *The Lancet* 385 (9967), 563–575.
DOI: 10.1016/S0140-6736(14)61462-8

Coelho, A., Fernandes, H. M., Magalhães, R., Moreira, P. S., Marques, P., Soares, J. M., Amorim, L., Portugal-Nunes, C., Castanho, T., Santos, N. C., Sousa, N., May 2021. Reorganization of brain structural networks in aging: A longitudinal study. *Journal of Neuroscience Research* 99 (5), 1354–1376.

Dobkin, B. H., 2005. Rehabilitation after stroke. *New England Journal of Medicine* 352 (16), 1677–1684.

Lang, C. E., Wagner, J. M., Edwards, D. F., Sahrman, S. A., Dromerick, A. W., 2007. Measurement of upper-limb performance in daily life after stroke. *Journal of Rehabilitation Research and Development* 44 (5), 611–630.

Lara, O. D., Labrador, M. A., 2013. A survey on human activity recognition using wearable sensors. *IEEE Communications Surveys & Tutorials* 15 (3), 1192–1209.

Madgwick, S., 2010. An efficient orientation filter for terrestrial magnetic electromagnetics and inertial measuring units. Tech. Rep. 1, University of Bristol.

Madgwick, S. O., Harrison, A. J., Vaidyanathan, R., 2010. An efficient orientation filter for terrestrial magnetic electromagnetics and inertial measuring units. In: *2010 IEEE International Conference on Robotics and Biomimetics*. IEEE, pp. 110–115.

Patel, S., Park, H., Bonato, P., Chan, L., Rodgers, M., 2012. A review of wearable sensors and systems with application in rehabilitation. *Journal of NeuroEngineering and Rehabilitation* 9 (1), 21.

Peters, R., Feb 2006. Ageing and the brain. *Postgraduate Medical Journal* 82 (964), 84–88.

Piwek, L., Ellis, D. A., Andrews, S., Joinson, A., 2016. The rise of consumer health wearables: promises and barriers. *PLOS Medicine* 13 (2), e1001953.

Pratt, J. W., 1959. Remarks on zeros and ties in the wilcoxon signed rank test. *Journal of the American Statistical Association* 54 (287), 655–667.

Preece, S. J., Goulermas, J. Y., Kenney, L. P., Howard, D., 2009. A survey of activity recognition in healthcare. *Journal of Biomedical Informatics* 42 (4), 642–654.

Razali, N., Wah, Y. B., 2011. Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. *Journal of Statistical Modeling and Analytics* 2 (1), 21–33.

SayedSaadat, S. M., Yolcu, Y. U., et al., 2021. Age-associated neurological complications of COVID-19: A systematic review. *Journal of Clinical Medicine* 10 (12), 2810.
DOI: 10.3390/jcm10122810

Steinmetz, J. D., Seher, K. M., Schiess, N., Nichols, E., Cao, B., Servili, C., Cavallera, V., Cousin, E., Hagins, H., Moberg, M. E., et al., 2024. Global, regional, and national burden of disorders affecting the nervous system, 1990–2021: a systematic analysis for the global burden of disease study 2021. *The Lancet Neurology* 23 (4), 344–381.
DOI: 10.1016/S1474-4422(24)00038-3

Van der Maaten, L., Hinton, G., 2008. Visualizing data using t-sne. *Journal of Machine Learning Research* 9 (Nov), 2579–2605.

Vollset, S. E., Goren, E., Yuan, C.-W., et al., 2020. Fertility, mortality, migration, and population scenarios for 195 countries and territories from 2017 to 2100: a forecasting analysis for the global burden of disease study. *The Lancet* 396 (10258), 1285–1306.
DOI: 10.1016/S0140-6736(20)30677-2

Warner, M. B., et al., 2019. Wearable sensors for remote monitoring of rehabilitation and recovery. *Current Physical Medicine and Rehabilitation Reports* 7, 197–204.

Wiles, J. L., Leibing, A., Guberman, N., Reeve, J., Allen, R. E. S., 2012. The meaning of “aging in place” to older people. *The Gerontologist* 52 (3), 357–366.
DOI: 10.1093/geront/gnr098

Yang, C., Hsu, Y.-L., 2010. A review of accelerometry-based wearable motion detectors for physical activity monitoring. *Sensors* 10 (8), 7772–7788.