

Clasificación de Estados de Actividad Física Mediante la Dinámica Temporal del Tiempo de Llegada del Pulso

Classification of Physical Activity States Using the Temporal Dynamics of Pulse Arrival Time

Doctorando:

Norberto SANABRIA

<https://orcid.org/0009-0005-3494-8216>

Universidad Tecnológica Nacional, Facultad Regional Buenos Aires, Argentina
nosanabria@frba.utn.edu.ar

Director/a:

Leandro CYMBERKNOP

Codirector/a: (si corresponde)

Jorge MONZON

Resumen

El reconocimiento de la actividad humana (HAR, por sus siglas en inglés) basado en señales fisiológicas ofrece una visión directa de la respuesta metabólica y autonómica del cuerpo. Este trabajo propone una red neuronal recurrente de memoria a corto y largo plazo (LSTM, por sus siglas en inglés) para clasificar los estados de actividad (reposo, caminar, correr) basándose exclusivamente en la dinámica temporal del tiempo de llegada del pulso (PAT, por sus siglas en inglés). Un aspecto central de este estudio es el análisis fisiológico de la variabilidad media del PAT (PAT Var Mean, por sus siglas en inglés), una métrica que refleja la modulación autonómica latido a latido. Utilizando un conjunto de datos PhysioNet de 22 individuos, analizamos cómo el género y la intensidad de la actividad afectan la estabilidad del PAT. Los resultados demuestran que las mujeres presentan una mayor variabilidad media en reposo en comparación con los hombres, pero esta variabilidad disminuye drásticamente en ambos géneros durante el ejercicio intenso debido al predominio simpático. El modelo LSTM, entrenado para capturar estas transiciones dinámicas, alcanzó una precisión del 92 %. Este enfoque demuestra que la firma temporal de PAT, cuantificada a través de su variabilidad media, es un indicador robusto del nivel de esfuerzo físico que trasciende las diferencias demográficas basales, lo que permite el desarrollo de sistemas HAR más eficientes y personalizados.

Palabras clave: Reconocimiento de la Actividad Humana (HAR); Variabilidad Media del Tiempo de Llegada del Pulso (PAT Var Mean); Memoria a Largo y Corto Plazo (LSTM); Fisiología Cardiovascular; Actividad Física.

Abstract

Human Activity Recognition (HAR) based on physiological signals offers a direct view into the body's metabolic and autonomic response. This work proposes a Long Short-Term Memory (LSTM) recurrent neural network to classify activity states (resting, walking, running) based exclusively on the temporal dynamics of Pulse Arrival Time (PAT). A central aspect of this study is the physiological analysis of the mean PAT variability (PAT Var Mean), a metric reflecting beat-to-beat autonomic modulation. Using a PhysioNet dataset of 22 individuals, we analyzed how gender and activity intensity affect PAT stability. Results demonstrate that females exhibit higher mean variability at rest compared to males, but this variability decreases drastically in both genders during intense exercise due to sympathetic dominance. The LSTM model, trained to capture these dynamic transitions, achieved 92% accuracy. This approach demonstrates that the temporal signature of PAT,

quantified through its mean variability, is a robust indicator of physical exertion level that transcends baseline demographic differences, enabling the development of more efficient and personalized HAR systems.

Keywords: Human Activity Recognition (HAR); Pulse Arrival Time Mean Variability (PAT Var Mean); Long-Term and Short-Term Memory (LSTM); Cardiovascular Physiology; Physical Activity.

Introducción

La monitorización automática de la actividad física es un componente esencial de la salud digital moderna. Los sistemas tradicionales de reconocimiento de la actividad humana (HAR, por sus siglas en inglés) se basan principalmente en acelerómetros inerciales, que detectan el movimiento mecánico pero ignoran la respuesta fisiológica subyacente (Lara & Labrador, 2013). En cambio, el uso de bioseñales como la electrocardiografía (ECG) y la fotopletomografía (PPG) permite capturar el nivel de esfuerzo real y el estado del sistema cardiovascular durante el ejercicio (Wang et. al, 2019). El tiempo de llegada del pulso (PAT, por sus siglas en inglés) es un biomarcador que integra información de la fase de preeyección cardíaca y el tránsito arterial del pulso (Ajtay, et al., 2023). Se ha demostrado que el PAT disminuye de forma predecible con el aumento de la intensidad del ejercicio debido al incremento de la presión arterial y la rigidez arterial (Obata et al., 2017). Sin embargo, el uso del PAT para clasificar actividades se enfrenta al desafío de la variabilidad interindividual. Factores como la altura (que alarga el PAT), el sexo (que influye en el tono autonómico) y la edad (que reduce la variabilidad latido a latido) pueden confundir los modelos de clasificación si no se abordan adecuadamente (Koenig & Thayer, 2016). Este trabajo propone una arquitectura de red neuronal de memoria a largo y corto plazo (LSTM) para la clasificación de la actividad basada en la secuencia temporal de la actividad física. Las LSTM son ideales para este propósito, ya que pueden aprender dependencias a largo plazo y patrones dinámicos complejos en series temporales fisiológicas (Hochreiter & Schmidhuber, 1997). Para garantizar la robustez demográfica, se implementó una estrategia de normalización personalizada, lo que permite que el modelo se centre en la dinámica del cambio en lugar de en los valores absolutos de la actividad física. El rendimiento del modelo se analizó en una población diversa de 22 sujetos, explorando cómo el género, la edad y el peso afectan la precisión de la clasificación. Este estudio contribuye a la creación de sistemas de monitorización más robustos y menos dependientes de sensores inerciales adicionales.

A. Reconocimiento de actividad con aprendizaje profundo: Este se ha transformado el campo del reconocimiento de actividad humana (HAR, por sus siglas en inglés), superando a los métodos tradicionales basados en características manuales. Las redes neuronales convolucionales (CNN, por sus siglas en inglés) son excelentes para extraer características espaciales de las señales de acelerometría, mientras que las redes neuronales recurrentes (RNN, por sus siglas en inglés), específicamente las LSTM, han demostrado ser superiores para modelar la naturaleza secuencial y temporal de señales fisiológicas como el ECG y el PPG (Bi et al., 2018).

B. PAT como biomarcador de esfuerzo: La relación entre el PAT y la presión arterial es bien conocida y se utiliza para la estimación continua de la presión arterial sin manguito (Mukkamala, 2015). Durante el ejercicio, el aumento de la actividad simpática reduce significativamente el PAT. Sin embargo, la variabilidad latido a latido del PAT (su "firma temporal") se ha explorado menos como característica discriminatoria para la clasificación de la actividad. La mayoría de los sistemas HAR que utilizan bioseñales se centran en la frecuencia cardíaca (FC) o la variabilidad de la frecuencia cardíaca (VFC), ignorando la información vascular contenida en el PAT (Shaffer & Ginsberg, 2017).

C. Desafíos demográficos en HAR: Uno de los mayores obstáculos para la implementación masiva de los sistemas HAR es la falta de robustez frente a la diversidad demográfica. Las mujeres suelen tener una respuesta autonómica al ejercicio diferente a la de los hombres (Al-Makhadmeh & Tolba, 2019). Del mismo modo, el envejecimiento cardiovascular altera la dinámica de la presión arterial y la elasticidad vascular, modificando la señal basal del PAT y su respuesta al esfuerzo (Koenig & Thayer, 2016). Un modelo de aprendizaje automático exitoso debe ser capaz de normalizar estas diferencias para extraer patrones de actividad universales.

Desarrollo

A. Conjunto de datos y población: Se utilizó el conjunto de datos PhysioNet de Mehrgardt (2022) que incluye 22 sujetos sanos. La población es heterogénea en cuanto a género, rango de edad (20-55 años) y características morfológicas (estatura 155-190 cm, peso 45-100 kg). Se registraron tres actividades: estar sentado (reposo), caminar (3-6 km/h) y correr (8-12 km/h). También se compararon los índices de masa corporal (IMC). La Tabla 1 muestra las estadísticas descriptivas de las mujeres monitorizadas. La Tabla 2 muestra las estadísticas descriptivas de los hombres incluidos en el conjunto de datos.

<i>Variable</i>	<i>Mediana</i>	<i>Q1</i>	<i>Q3</i>	<i>IQR</i>
Edad (años)	25	20	25	5
Peso (kg)	60	50	60	10
Altura (cm)	160	160	170	10

Tabla 1: Estadísticas descriptivas para las Mujeres (N=7)

<i>Variable</i>	<i>Mediana</i>	<i>Q1</i>	<i>Q3</i>	<i>IQR</i>
Edad (años)	25	25	32.5	7.5
Peso (kg)	80	70	82.5	12.5
Altura (cm)	175	175	180	5

Tabla 2: Estadísticas descriptivas para los hombres (N=15)

B. Extracción de series temporales PAT: Se aplicó un procesamiento digital de señales robusto (DSP).

- Detección del pico R: El algoritmo de Pan-Tompkins aplicado a la señal de ECG demostró ser un método de procesamiento que detecta de forma fiable el pico R mediante una arquitectura de operaciones matemáticas sencillas.
- Selección de canal PPG: Selector basado en el Índice de Calidad Espectral (SQI) para mitigar los artefactos de movimiento. Los algoritmos SQI evaluaron la fiabilidad de las señales fisiológicas PPG mediante la detección de ruido, artefactos de movimiento y contactos deficientes del sensor, provenientes de canales ruidosos.
- Cálculo de PAT: Dado que el PAT se puede calcular como el tiempo de retardo entre el pico de la onda R del ECG y un punto de referencia específico en la forma de onda PPG, se eligió el punto de máxima derivada, ya que el pie de onda o los puntos del pico sistólico se ven afectados por distorsiones. Se aplicaron filtros de mediana para minimizar valores atípicos.

C. Análisis de PAT Var Mean: Se definió como la desviación estándar media de los intervalos PAT en ventanas de tiempo de 10 segundos. Es análoga a la RMSSD, registrando fluctuaciones rápidas en la rigidez arterial y el tono vasomotor inducidos por el sistema nervioso autónomo.

D. Arquitectura y entrenamiento de la LSTM: Se utilizaron redes neuronales dinámicas como la LSTM para procesar datos de secuencias y series temporales en tareas de clasificación, gracias a su capa de entrada secuencial, que permitió predecir las etiquetas de clase. Su diseño posibilitó el manejo a largo plazo. El modelo propuesto consistió en una arquitectura secuencial:

- Entrada: Ventanas de 50 latidos (PAT normalizado).
- Capas LSTM: Dos capas LSTM (64 y 32 unidades) con capas Dropout intercaladas (0,3) para regularización.
- Salida: Capa densa con activación softmax para tres clases (reposo, caminar, correr).
- Etiquetas de actividad totales: 45146 (45146, 100). Codificación one-hot para 'sentarse', 'caminar' y 'correr'.

Resultados

A. Análisis fisiológico de la variabilidad media de la PAT por género: La Fig. 1 muestra la variabilidad media de la PAT (variabilidad media de la PAT) diferenciada por género y nivel de actividad. Se observaron diferencias fisiológicas interesantes: en reposo, las mujeres presentan mayor variabilidad que los hombres. Este hallazgo concuerda con la

literatura que sugiere una mayor modulación parasimpática (vagal) basal en mujeres jóvenes sanas (Al-Makhadmeh & Tolba, 2019). A medida que aumenta la intensidad del ejercicio (caminar y correr), la variabilidad media de la PAT disminuye drásticamente en ambos sexos, convergiendo a valores mínimos durante la carrera. Esta convergencia refleja una masiva disminución del vago y el predominio absoluto del sistema nervioso simpático, lo que reduce la variabilidad latido a latido al estabilizar la PAT en valores mínimos.




Figura 1: Comparación de la variabilidad media de PAT entre hombres y mujeres bajo diferentes intensidades de ejercicio. Tendencia fisiológica en función de la intensidad de la actividad, con mayor variabilidad basal en mujeres.

B. Tendencia de la variabilidad y respuesta al esfuerzo: La tendencia descendente de la variabilidad (Fig. 1) es un indicador fiable del nivel de esfuerzo. Mientras que en reposo la PAT fluctúa considerablemente debido a la arritmia sinusal respiratoria y los ajustes barorreflejos, durante la carrera estas fluctuaciones se suprimen por la alta demanda cardiovascular y el elevado tono simpático. Esta característica de la variabilidad permite al modelo LSTM clasificar con precisión los estados de actividad.

C. Rendimiento global y matriz de confusión: El modelo LSTM alcanzó una precisión global del 92 % en el conjunto de prueba. Como se observa en la Fig. 2, el modelo es excepcionalmente sensible (Recall) para identificar el estado de reposo (sentado), con una precisión cercana al 100 %. Las confusiones se producen principalmente entre caminar y correr (84,44 % y 87,23 %, respectivamente). Desglosando los resultados por género, la precisión fue del 93 % para los hombres y del 91 % para las mujeres. Esta mínima diferencia sugiere que la estrategia de normalización de la puntuación Z fue efectiva para eliminar los sesgos de género iniciales. Las mujeres, a pesar de tener un PAT basal más corto y una mayor variabilidad autonómica en reposo, mostraron patrones de cambio en PAT Var Mean durante el ejercicio que la red LSTM pudo generalizar correctamente a partir del entrenamiento conjunto.




Figura 2: Matriz de confusión que muestra el rendimiento del clasificador en las tres actividades.

D. Robustez demográfica y análisis de errores: El análisis de los casos de error reveló una tendencia interesante relacionada con la edad y el peso. Los sujetos mayores (45-55 años) y aquellos con un índice de masa corporal (IMC) más alto tendieron a mostrar dinámicas del PAT durante la marcha rápida que el modelo clasificó erróneamente como carrera. Esto se debe a que su respuesta cardiovascular al esfuerzo es más intensa (mayor aumento de la presión arterial y rigidez arterial relativa) en comparación con los sujetos jóvenes y delgados. Sin embargo, la normalización de la puntuación Z específica para cada sujeto mitigó gran parte de estos sesgos iniciales.

E. Impacto de la edad y la condición física: El análisis de errores (confusiones entre caminar y correr) reveló que la respuesta cardiovascular al esfuerzo de los sujetos mayores y con mayor peso es más intensa, lo que lleva a una clasificación

errónea. La Fig. 3 muestra que, si bien la correlación entre la edad y la PAT Var Mean en reposo es significativa, el modelo LSTM supera este sesgo al centrarse en la secuencia de cambios temporales.




Figura 3: Dispersión de la variabilidad media de PAT en función de la edad en reposo.

F. Discusión y generalización: 1) Actividad en reposo: Alto rendimiento. El modelo clasifica la actividad con una precisión muy alta (puntuación F1 del 89 %, exhaustividad del 91 %). El estado de "sentado" tiende a generar señales fisiológicas estables con baja variabilidad (Fig. 4-a), lo que facilita el aprendizaje de un patrón distintivo. 2) Actividad intensa: Rendimiento moderado a alto. La actividad de "correr" se clasifica correctamente. El ejercicio intenso produce cambios fisiológicos pronunciados (aumento de la frecuencia cardíaca, PAT significativamente más corto, predominio simpático), lo que resulta en patrones de señal distintivos con "mayor amplitud de PAT Var Mean" (Fig. 4-c), aunque los artefactos de movimiento podrían introducir ruido. 3) Actividad moderada: El modelo mostró cierta dificultad para clasificar la actividad de "caminar" debido a su naturaleza transitoria entre el reposo y el esfuerzo intenso (Fig. 4-b). Los patrones fisiológicos durante la marcha pueden superponerse con ambos extremos, creando una "zona gris" probablemente debido a lo siguiente:

a) Naturaleza transitoria: Caminar se sitúa fisiológicamente entre el descanso y el esfuerzo intenso, lo que da lugar a características de señal superpuestas. b) Alta variabilidad fisiológica interna: Los patrones pueden cambiar entre individuos o dentro del mismo individuo en función del ritmo, el nivel de condición física o el estrés. c) Confusión de clases: Caminar suavemente puede confundirse con descansar; caminar vigorosamente puede mezclarse con correr.




Figura 4: Rango de variabilidad de la PAT para hombres y mujeres en reposo (a), caminando (b) y corriendo (c).

El éxito de la arquitectura LSTM radica en su capacidad para identificar la "característica temporal" del ejercicio intenso. Mientras que caminar produce variabilidades PAT rítmicas y moderadas, correr genera una señal mucho más comprimida con fluctuaciones de alta frecuencia reducidas debido al predominio simpático extremo. Estos patrones son consistentes en diferentes alturas y pesos, lo que valida la variabilidad PAT como un biomarcador de actividad generalizable.

Conclusiones

Este estudio demuestra que es posible clasificar los estados de actividad física con alta precisión utilizando exclusivamente la dinámica temporal del PAT. Para ello, la base de datos PhysioNet desarrollada por Mehrgardt (2022) proporcionó abundante información útil para el análisis dinámico de la mecánica cardiovascular, a pesar de que el estudio original se centró en la monitorización de la frecuencia cardíaca. La métrica PAT Var Mean ha demostrado ser un indicador

fisiológico fiable, revelando diferencias de género en la modulación autonómica basal y la convergencia simpática durante el ejercicio intenso. Si bien la variabilidad de la frecuencia cardíaca es un indicador indirecto tradicional del riesgo cardiovascular, esta puede verse afectada por diversos factores, como el estrés psicológico o mental, ya sea momentáneo o transitorio. La variabilidad del PAT parece ser un marcador biomecánico fiable en diferentes estados de actividad física, incluyendo la actividad intensa durante el ejercicio. Una red neuronal, combinada con una estrategia de normalización robusta y específica para cada sujeto, demostró resistencia a las variaciones de género, edad y altura. La secuencia temporal del PAT contiene información suficiente para distinguir los niveles de esfuerzo físico. La normalización personalizada es clave para mitigar las diferencias cardiovasculares basales entre los sujetos. Las mujeres mostraron una mayor variabilidad basal de PAT en reposo, lo que sugiere una mayor influencia parasimpática. Además, la variabilidad de PAT disminuyó predeciblemente con el ejercicio, sirviendo como una marca robusta para la clasificación de la actividad. La red neuronal LSTM fue capaz de capturar estas transiciones dinámicas con alta precisión y sensibilidad, especialmente entre el reposo y la actividad intensa, demostrando resistencia a las variaciones demográficas basales. Este enfoque abre el camino a dispositivos portátiles de próxima generación que pueden reconocer actividades y evaluar la salud cardiovascular de forma simultánea y personalizada, adaptándose automáticamente al perfil fisiológico del usuario.

Referencias

- Ajtay, B. E., Béres, S., & Hejjel, L. (2023). The oscillating pulse arrival time as a physiological explanation regarding the difference between ECG- and Photoplethysmogram-derived heart rate variability parameters. *Biomedical Signal Processing and Control*, 79, 104033.
- Al-Makhadmeh, Z., & Tolba, A. (2019). Use of IoT wearable medical devices for heart disease prediction using the higher-order Boltzmann model: A classification approach. *Measurement*, 147, Article 106815.
- Bi, J., Wang, J., Zhang, X., Li, X., & Zhang, Y. (2018). A CNN-LSTM based approach for human activity recognition. *IEEE Access*, 6, 76358–76367.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
- Koenig, H. G., & Thayer, J. F. (2016). Sex differences in healthy human heart rate variability: A meta-analysis. *Journal of Cardiovascular Nursing*, 30(3), 242–249.
- Lara, O. D., & Labrador, M. A. (2013). A Survey on Human Activity Recognition. *IEEE Communications Surveys & Tutorials*, 15(3), 1192–1209.
- Mehrgardt, P., Khushi, M., Poon, S., & Withana, A. (2022). *Pulse Transit Time PPG Dataset (v1.1.0)* [Dataset]. PhysioNet. <https://doi.org/10.13026/jpan-6n92>.
- Mukkamala, R., Hahn, J. O., Inan, O. T., Mestha, L. K., Kim, C. S., Töreyn, H., & Kyal, S. (2015). Toward ubiquitous blood pressure monitoring via pulse transit time. *IEEE Transactions on Biomedical Engineering*, 62(8), 1879–1901.
- Obata, Y., Ong, Q. J., Magruder, J. T., Grichkevitch, Berkowitz, D. E., Nyhan, D., Steppan, J., & Barodka, V. (2017). Noninvasive assessment of the effect of position and exercise on pulse arrival to peripheral vascular beds in healthy volunteers. *Frontiers in Physiology*, 8, 47.
- Shaffer, F., & Ginsberg, J. P. (2017). An overview of heart rate variability metrics and norms. *Frontiers in Public Health*, 5, 258.
- Wang, J., Chen, Y., Hao, S., Peng, X., & Hu, L. (2019). Deep learning for sensor-based activity recognition: a review. *Pattern Recognition Letters*, 119, 3–11.