

Sistema desarrollado en LabVIEW de segmentación y análisis automatizado de señales provenientes de sensores iniciales inalámbricos.

LabVIEW-Based System for Automated Segmentation and Analysis of Signals from Wireless Inertial Sensors

Josué Alejandro Andino Guerrero¹

¹*Universidad Modelo, campus Mérida, carretera Cholul a 200 metros del periférico, CP 97305 Mérida, Yucatán, México.*

*Corresponding author:
andino.josue02@gmail.com

Resumen.

Se presenta el desarrollo de un software en LabVIEW enfocado al análisis automatizado de señales iniciales obtenidas mediante sensores IMU para su aplicación en investigación, rehabilitación y cultura física. El sistema combina las funcionalidades de los siguientes paquetes de cómputo: Uno para la detección y filtrado de valores atípicos mediante una técnica basada en la desviación estándar local; Uno que implementa el método de detección de picos multiescala (AMPD) para la detección de extremos locales; Y otro utilizado para la segmentación por flancos de la señal. Se combina el uso de dichos paquetes en conjunto con una interfaz intuitiva de forma que se le permite al usuario la selección de la sección de la señal a realizar el análisis y segmentación. La validación de los algoritmos se realizó comparando detecciones con datos anotados manualmente, mostrando altos valores de sensibilidad y precisión.

Palabras Clave: señales iniciales, IMU, AMPD, LabVIEW, detección de picos

Abstract. This work presents the development of a LabVIEW-based software system focused on the automated analysis of inertial signals acquired through IMU sensors, with applications in research, rehabilitation, and physical training. The system integrates the functionality of several computational modules: one for the detection and filtering of outliers using a local standard deviation technique; another

that implements the multiscale peak detection method (AMPD) for identifying local extrema; and a third used for signal segmentation based on slope transitions. These modules are combined within an intuitive graphical interface, allowing the user to select specific sections of the signal for analysis and segmentation. The algorithms were validated by comparing detected events against manually annotated data, showing high sensitivity and precision levels

Keywords: inertial signals, IMU, AMPD, LabVIEW, peak detection

I. INTRODUCCIÓN

El análisis del movimiento humano ha cobrado creciente relevancia en campos como la investigación clínica, la rehabilitación física, y la cultura física. En [Pinzón, 2018], se desarrollaron bandas contenedoras de Unidades de Medición Inercial (IMUs) las cuales tuvieron la finalidad de reconstruir y clasificar movimientos normales y de tipo epilépticos a través de los registros de movimientos obtenidos de los sensores iniciales

Estas bandas IMUs emergieron como una solución accesible y versátil para el registro de señales iniciales en entornos reales y sin restricciones físicas para el usuario; y aunque el enfoque inicial de estas fue hacia la epilepsia, gracias a su desarrollo se han ramificado nuevas líneas de investigación dentro del laboratorio,

como lo fueron su uso en estudios de polisomnografía, o en estudios de medición del equilibrio de los miembros inferiores. El trabajo, con el que se está trabajando en conjunto, y el cual dio pie a la elaboración del proyecto presente fue el del uso de dichas bandas para la detección de inicio de fatiga muscular durante el ejercicio de flexión de bíceps.



Figura 1. Bandas contenedoras de IMUs. Fuente: [Pinzon, 2018]

Las IMUs permiten al investigador obtener información detallada sobre actividades repetitivas como flexiones, extensiones o marcha. No obstante, el análisis manual de estas señales representa una tarea tediosa y propensa a errores, especialmente cuando se trabaja con grandes volúmenes de datos y no se posee un sistema apto para el manejo de estos. Por esta razón, se presentó la necesidad de desarrollar herramientas que permitan un análisis automatizado de las señales iniciales. En este caso en específico, se requirió de un software capaz de detectar eventos clave en la señal, siendo estos los máximos y mínimos locales, para así poder segmentar por flancos posteriormente la señal de interés.

El presente trabajo describe el desarrollo de un sistema gráfico en LabVIEW que unifica tres módulos o paquetes de cómputo, siendo estos uno capaz del filtrado de valores atípicos, otro para la detección de máximos mediante el método AMPD y uno final que se encarga de la segmentación por flancos. Estos pueden ser utilizados dentro de una interfaz que permiten al usuario seleccionar y analizar secciones específicas de las señales iniciales. La implementación se diseñó para que pueda reutilizable en otras ramas de investigación relacionadas con el uso de las IMUs, y también que sea adaptable a distintas aplicaciones clínicas y deportivas.

II. METODOLOGÍA

A. Paquete de detección y filtrado de valores atípicos

El primer paquete desarrollado tiene como objetivo mejorar la calidad de la señal inercial antes de la detección de eventos, mediante la identificación y corrección de valores atípicos que pudieran distorsionar

el análisis. Para ello, se implementó un algoritmo basado en una ventana móvil bidireccional y en la desviación estándar local, el cual analiza cada punto de la señal en función de sus vecinos; se siguió la metodología propuesta en [Palshikar, 2009] y [Yu, 2014].

Dado un punto x_i , se define una ventana $2k$ muestras centradas en i . Si la diferencia entre el punto y el promedio local excede un umbral basado en h veces la desviación estándar local, es considerado un outlier y reemplazado por dicho promedio:

$$|x_i - \mu_{local}| \geq h \cdot \sigma_{local}$$

Ecuación 1. Precisión o valor predictivo positivo

Este enfoque asume que los valores cercanos a un outlier conservan la distribución local de la señal, y permite corregir valores extremos sin afectar la morfología general. En este trabajo se utilizaron valores típicos de $k = 35$ y $h = 2.35$, seleccionados tras pruebas empíricas.

La implementación en LabVIEW se muestra en la figura 2.

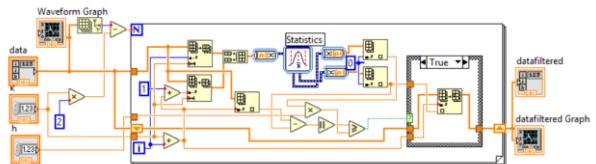


Figura 2. Algoritmo de detección de valores atípicos en LabVIEW. Fuente: Autoría propia.

B. Paquete de detección de máximos locales por método AMPD

Entre los algoritmos propuestos en la literatura para la detección de picos en señales no lineales y ruidosas, destacan métodos como la búsqueda de máximos por vecindad, el uso de filtros de derivadas, transformadas de wavelet, umbrales adaptativos y algoritmos basados en características estadísticas. Sin embargo, muchos de estos métodos están enfocados en la detección de máximos de una señal en específico, o presentan limitaciones al enfrentarse a señal con alto contenido de ruido, como ocurre frecuentemente en registros iniciales. En este contexto, el algoritmo Automático de Detección de Picos basado en Múltiples Escalas (AMPD) propuesto en [Scholkmann, 2012] fue el considerado el más adecuado, ya que este permite detectar picos en señales ruidosas

periodicas o quasiperiodicas sin necesidad de preajustar parámetros de entrada.

El funcionamiento del AMPD consta de cuatro etapas, mostradas en la figura 3:

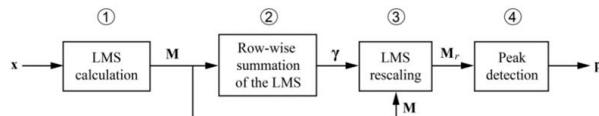


Figura 3. Etapas del algoritmo AMPD. Fuente: [Scholkmann, 2012].

Los pasos que lleva a cabo el algoritmo para cumplir con todas las etapas son los siguientes:

- Eliminación de la tendencia lineal, o detrending, para evitar que la pendiente de la señal interfiera con la detección de picos, se ajusta y elimina una tendencia lineal mediante regresión.
- Construcción del escalograma multiescala (LMS), refiriéndose a que se genera una matriz binaria M de tamaño $N \times L$, donde N es la longitud de la señal y L el número de escalas. En cada fila k , se marca con un 0 si el punto es un máximo local respecto a una ventana de tamaño $\pm k$
- Estimación de la escala óptima, donde se calcula la suma por filas de la matriz M , y se elimina la tendencia lineal para estabilizar la curva. La escala óptima L^* se define como el punto donde esta suma alcanza su mínimo
- Reescalado del LMS, donde se seleccionan solo las primeras L^* filas de la matriz, eliminando las escalas con bajo valor informativo.
- Finalmente, se calcula la desviación estándar por columnas del LMS reescalado. Los índices con desviación estándar igual a cero en todas las escalas son considerados máximos locales verdaderos

Las etapas del metodo AMPD se ejemplifican en la figura 4.

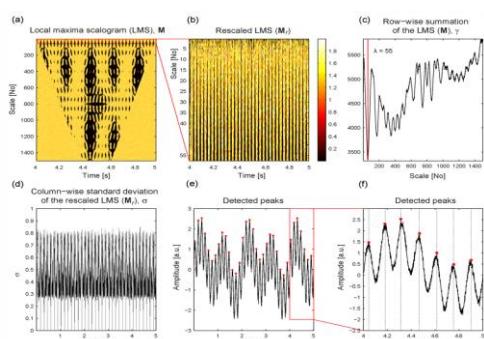


Figura 4. Ejemplo de aplicación del algoritmo AMPD. Fuente: [Scholkmann, 2012].

El algoritmo fue traducido a partir de [Scholkmann, 2016], e implementado completamente en el entorno gráfico de LabVIEW, véase figura 5. Se utilizó la versión extendida del algoritmo, que permite la detección de picos incluso en los extremos de la señal.

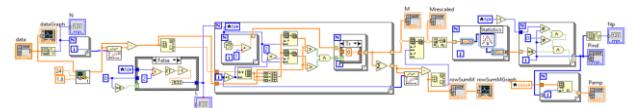


Figura 5. Algoritmo AMPD en LabVIEW. Fuente: Autoría propia

C. Paquete de segmentación por flacos

Finalmente, se integró un tercer módulo que permite la segmentación automática de ciclos de movimiento a partir de la detección de flancos descendentes entre máximos y mínimos. Este se realizó considerando los casos en que se podrían colocar los cursores durante la selección de la sección de interés. Véase figura 6.

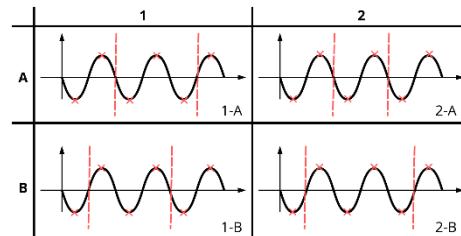


Figura 6. Casos de selección de secciones de señal. Fuente: Autoría propia

D. Validación de algoritmo AMPD y algoritmo de filtrado de valores atípicos

El sistema fue validado utilizando señales inerciales previamente registradas durante ejercicios físicos repetitivos. Se emplearon anotaciones manuales como referencia para comparar los resultados del algoritmo de detección de picos.

Se consideró una ventana de tolerancia de ± 5 muestras (50 ms) para establecer correspondencia entre detecciones y eventos reales. A partir de esto, se calcularon las métricas de sensibilidad (Se) y precisión (PPV):

$$Se = \frac{TP}{TP + FN} \times 100$$

Ecuación 2. Sensibilidad

$$PPV = \frac{TP}{TP + FP} \times 100$$

Ecuación 3. Precisión o valor predictivo positivo.

Asimismo, se cuantificaron los errores de detección como False Positive Detection Errors (FPDEs) y False Negative Detection Errors (FNDEs). La validación se realizó tanto con cómo sin el filtro de valores atípicos, Esto para observar mejoras o en su caso diferencias en la precisión y reducción de errores al aplicar el preprocesamiento.

III. RESULTADOS

A. Validación de algoritmo AMPD y algoritmo de filtrado de valores atípicos

En la **Tabla 1** se presentan los resultados obtenidos tras aplicar el algoritmo AMPD sin preprocesamiento, utilizando una ventana de tolerancia de ± 5 muestras. Se observa un desempeño general satisfactorio, con valores de sensibilidad (Se) y precisión (PPV) superiores al 96 % en el total de eventos, y un comportamiento ligeramente inferior en la detección de valles (93.75 %) respecto a los picos (98.95 %).

Tabla 1. Validación AMPD. Fuente: Autoría Propia.

	TP	FPDE	FNDE	Se (%)	PPV (%)
Picos	190	2	2	98.95	98.95
Valles	180	12	12	93.75	93.75
Total	370	14	14	96.35	96.35

La **Tabla 2** muestra los resultados al aplicar el algoritmo AMPD posterior al filtrado de outliers. Se evidencian mejoras claras en la detección de picos, alcanzando una sensibilidad del 99.47 % y una precisión del 99.47 %, así como una reducción de los errores de detección (FPDE y FNDE). Sin embargo, se observa una disminución en el desempeño para la detección de valles. El rendimiento global del sistema con preprocesamiento se mantiene en niveles aceptables (Se = 93.75 %, PPV = 93.75 %).

Tabla 2. Validación AMPD + Filtro de outliers. Fuente: Autoría Propia.

	TP	FPDE	FNDE	Se (%)	PPV (%)
Picos	191	1	1	99.47	99.47
Valles	169	23	23	88.02	88.02
Total	360	24	24	93.75	93.75

B. Segmentación por flancos

La Figura 7 presenta el resultado final del sistema, donde se visualiza la señal inercial junto con los segmentos identificados automáticamente mediante el análisis de flancos entre picos y valles detectados. Cada segmento

representa en este caso el flanco de bajada del movimiento repetitivo, delimitado por eventos extremos.

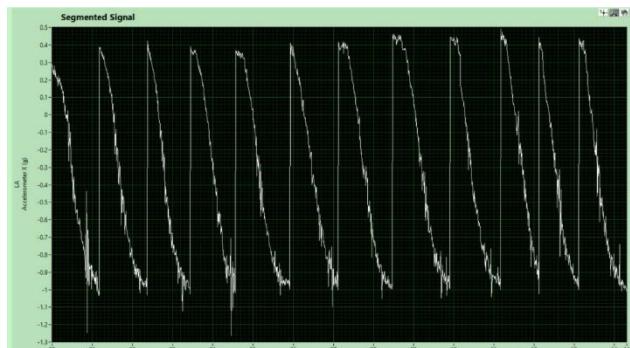


Figura 7. Señal inercial segmentada por flancos de bajada. Fuente: Autoría propia

IV. DISCUSIÓN

Los resultados obtenidos evidencian un desempeño adecuado del sistema propuesto para la detección de extrema y segmentación automática en señales inerciales. Es interesante destacar que se observó una disminución en las métricas de sensibilidad y precisión durante la detección de valles, tanto con cómo sin filtrado de outliers. Esta caída en el rendimiento puede atribuirse al ruido natural generado durante la ejecución del movimiento, particularmente en la fase de flexión del brazo, donde el sujeto realiza un mayor esfuerzo muscular. Dicha condición genera vibraciones de mayor amplitud, las cuales tienden a alterar la morfología del valle y dificultan su identificación precisa.

Asimismo, se identificó que el filtro de outliers, si bien mejora la detección de picos al eliminar valores atípicos espurios, puede en ciertos casos eliminar también picos o valles que representan eventos reales del movimiento, especialmente en señales ruidosas. Esto sugiere la necesidad de un ajuste más dinámico de los parámetros del filtro, o implementar otro método de filtrado que tenga mejor desempeño.

Como líneas de mejora, se propone:

- Automatizar la selección de los parámetros del algoritmo de filtrado de valores atípicos, permitiendo adaptar el preprocesamiento a diferentes condiciones de señal.
- Incrementar la robustez del algoritmo de segmentación, mejorando la detección de flancos en presencia de artefactos o movimientos no deseados.

- Incorporar nuevas funcionalidades al sistema, tales como el cálculo de métricas biomecánicas, visualización avanzada o análisis en frecuencia.
- Optimizar la interfaz gráfica para mejorar la experiencia del usuario y facilitar la exploración de datos iniciales por parte de investigadores o terapeutas.

En conjunto, estos hallazgos reafirman la utilidad del sistema como herramienta de análisis, a la vez que señalan oportunidades concretas para su evolución y refinamiento en futuros desarrollos.

V. CONCLUSIONES

Se desarrolló un sistema en LabVIEW capaz de realizar la segmentación y análisis automatizado de señales iniciales, integrando algoritmos de detección de valores atípicos, detección de picos basada en AMPD y segmentación por flancos. El sistema demostró un desempeño sólido en condiciones controladas, logrando altos niveles de sensibilidad y precisión en la detección de eventos relevantes del movimiento. Aunque cabe destacar que se identificaron limitaciones en la detección de extremos en presencia de ruido elevado.

En conclusión, el proyecto sienta las bases para futuras ampliaciones y refinamientos para el funcionamiento del software, incluyendo la incorporación de nuevos módulos de análisis, la mejora de la robustez del sistema frente a artefactos, y el fortalecimiento de su capacidad de adaptación a distintas poblaciones o tipos de ejercicios.

REFERENCIAS

- Beato, M., De Keijzer, K. L., Carty, B., & Connor, M. (2019). Monitoring Fatigue During Intermittent Exercise With Accelerometer-Derived Metrics. *Frontiers in Physiology*, 10, 780. <https://doi.org/10.3389/fphys.2019.00780>
- Marcard, T. V., Pons-Moll, G., & Rosenhahn, B. (2016). Multimodal motion capture dataset TNT15. Leibniz Univ. Hannover, Hanover, Germany, and Max Planck for Intelligent Systems, Tübingen, Germany, Tech. Rep.
- Moyen-Sylvestre, B., Goubault, É., Begon, M., Côté, J. N., Bouffard, J., & Dal Maso, F. (2022). Power Spectrum of Acceleration and Angular Velocity Signals as Indicators of Muscle Fatigue during Upper Limb Low-Load Repetitive Tasks. *Sensors*, 22(20), 8008.
- Palshikar, G. (2009, June). Simple algorithms for peak detection in time-series. In *Proc. 1st Int. Conf. advanced data analysis, business analytics and intelligence* (Vol. 122).
- Pinzón Vivas, J. D. (2018, noviembre). Reconstrucción y clasificación de movimientos normales y epilépticos simulados, de tipo tónico, clónico y tónico-clónico, mediante parámetros extraídos de sensores iniciales. Mérida, Yucatán.
- Scholkmann, F., Boss, J., & Wolf, M. (2012). An efficient algorithm for automatic peak detection in noisy periodic and quasi-periodic signals. *Algorithms*, 5(4), 588-603.
- Scholkmann, F. (2016). AMPD: An Algorithm for Automatic Peak Detection in Noisy Periodic and Quasi-Periodic Signals. [Online]. Disponible en: <https://CRAN.R-project.org/package=ampd>