

## Comparación de descomposiciones espectrales en series de locomoción

Castiglioni, Giuliana<sup>1</sup>, Kembro, Jackelyn Melissa<sup>2</sup>, and Flesia, Ana Georgina<sup>1</sup>

<sup>1</sup> CIEM, CONICET-UNC. Córdoba, Argentina.  
georgina.flesia@unc.edu.ar - orcidID 0000-0001-6936-3764  
giuliana.castiglioni@mi.unc.edu.ar

<sup>2</sup> IIByT, CONICET-UNC. Córdoba, Argentina.  
jkembro@unc.edu.ar - orcidID 0000-0003-1127-8975

**Abstract.** Este trabajo se centra en comparación de tres métodos de detección y extracción de descomposición aditiva de ritmos en señales no estacionarias, con ruido con características cercanas a la correlación de largo alcance. Dos de estos métodos se basan en descomposición de tiempo frecuencia usando la transformada wavelet continua, (CWT y SST), óptimos para el caso no estacionario, y el tercero es (SSA), un método algebraico definido para señales débilmente estacionarias que descompone en valores singulares la matriz de trayectorias trasladadas por un paso fijo. El análisis comparativo reveló un ritmo circadiano robusto detectado por los tres métodos con las tres ventanas de suavizado. Sin embargo, la detección de ciclos ultradianos fue menos consistente, mostrando algunas diferencias entre los métodos, relativo al problema de definición del modelo del ruido asociado.

**Keywords:** Ritmos ultradianos · Análisis de serie de tiempo · Análisis Synchronosqueezing · Análisis espectral singular

# Comparison of Spectral Decompositions in Locomotion Time Series

**Abstract.** This work focuses on comparing three methods for detecting and extracting rhythms through additive decomposition in non-stationary signals with noise and characteristics similar to those of long-range correlation. Two of these methods are based on time-frequency decomposition using the Continuous Wavelet Transform (CWT) and the Synchrosqueezing Transform (SST), which are optimal for non-stationary cases. The third method is Singular Spectrum Analysis (SSA), an algebraic method for analysing weakly stationary signals, which decomposes the trajectory matrix into singular values. The comparative analysis revealed a robust circadian rhythm detected by all three methods across the three tested smoothing windows. However, the detection of ultradian cycles was less consistent, showing differences between the methods, mainly related to the challenge of defining the associated noise model.

**Keywords:** Ultradian Rythms · Time series analysis · Synchrosqueezing wavelet analysis · Singular Spectrum Analysis

## 1 Introducción

La locomoción en animales es un proceso complejo que integra múltiples sistemas fisiológicos en interacción con el entorno, y se rige por ritmos circadianos y ultradianos. Dichos ritmos pueden verse afectados en situaciones de estrés, modificaciones en la dieta o en contextos sociales con hacinamiento. La correcta detección y extracción de estos ritmos es fundamental para evaluar el bienestar animal[4]. En este estudio se comparan tres métodos para analizar señales no estacionarias con ruido de largo alcance: Transformada Wavelet Continua (CWT), Análisis Espectral Singular (SSA) [2], y Synchrosqueezing Transform (SST)[1]. Los tres métodos considerados suponen para las señales de locomoción un modelo aditivo de modas más ruido, el cual es modelado como un proceso estocástico. En [4] se observó que la componente aleatoria de estas señales es no estacionaria, con correlación de largo alcance, lo cual presenta un escenario de mayor dificultad para los estimadores de modas. En este trabajo evaluamos el efecto de suavizar la señal para reducir el ruido (i.e. promediando los datos de locomoción en ventanas) sobre la exactitud (variabilidad) y precisión (sesgo) de las estimaciones del periodo de ritmos biológicos con los distintos métodos.

## 2 Metodología

### 2.1 Método CWT

El análisis wavelet es una técnica que permite estudiar cómo varían las frecuencias de una serie temporal a lo largo del tiempo. El paquete `WaveletComp` en R implementa este enfoque utilizando la wavelet de Morlet, una función compleja que permite capturar tanto la amplitud como la fase de las oscilaciones locales. A través de la transformada wavelet continua, se obtiene una representación bidimensional (tiempo-frecuencia) que facilita la identificación de patrones cíclicos no estacionarios en la serie. [1] En este análisis se utilizó la función `analyze.wavelet()`, que proporciona información sobre la potencia, la fase y la significación de los ciclos detectados. La visualización incluye el espectro de potencia, el cono de influencia y la identificación de "ridges", que marcan las frecuencias dominantes a lo largo del tiempo. Además, el paquete permite reconstruir la señal a partir de componentes específicas, facilitando la interpretación de las dinámicas presentes en los datos[6].

### 2.2 Método SSA


El SSA es un método algebraico que permite descomponer una serie temporal en componentes como tendencia, oscilaciones y ruido. Primero, se elige una ventana de longitud  $L$  y se construye una matriz con segmentos superpuestos de la serie original. Luego, se aplica una descomposición en valores singulares (SVD), que separa la estructura de la serie en componentes elementales, ordenadas según su importancia. Posteriormente, se realiza un agrupamiento de estos componentes. En este trabajo se utilizó la función `grouping.auto()` del paquete `Rssa`, que los agrupa según su similitud, facilitando la identificación de patrones relevantes en la serie. Además, se estimó la frecuencia de los componentes agrupadas con la función `parestimate()` utilizando el método ESPRIT, que luego fue convertida en periodo, expresado en horas[3].

### 2.3 Método SST

La SSR es una técnica avanzada de análisis de señales que mejora la transformada wavelet continua al reasignar la energía en el dominio tiempo-frecuencia para obtener una representación más nítida y precisa. Combina la capacidad de las wavelets para capturar características locales con un proceso de reasignación que concentra la energía en las frecuencias instantáneas, reduciendo el difuminado espectral. Es especialmente útil en señales no estacionarias, como en procesamiento de audio, imágenes o datos biomédicos, permitiendo una mejor identificación de componentes frecuenciales y sus variaciones temporales.[1]. En este trabajo se utilizó la función `findpeaks` del paquete `pracma` para identificar los picos locales más relevantes en las representaciones tiempo-frecuencia obtenidas con `SynchWave`[7].

## 2.4 Database

Las series de tiempo utilizadas son de locomoción de codornices japonesas, extraídos de video registrado durante 6.5 días a una frecuencia de muestreo de 0.5 segundos ( $10^6$  puntos por individuo), en forma de series temporales de estados mutuamente excluyentes: móvil/inmóvil. Los datos de 12 codornices fueron pre-procesados para excluir periodos de interferencia experimental y promediados en ventanas de 1, 3 y 6 minutos. Estas series son parte de la database previamente analizada en [4], usando una técnica basada en búsqueda de máximos sobre el espectrograma wavelet de la señal.



**Fig. 1.** La figura muestra un swarmplot que visualiza por cada método, SST, CWT y SSA, los cuatro períodos de mayor magnitud detectados en cada serie, sobre un conjunto de 12 series. Para cada método, las espigas muestran esta información de acuerdo a la ventana con que fueron suavizadas las series, 1 minuto (color azul), 3 minutos (color naranja) y seis minutos (color verde).

## 3 Resultados

La Figura 1 muestra, en forma de un swarmplot, los valores de los períodos obtenidos por las tres técnicas (CWT, SST y SSA) para señales de locomoción de 12 codornices, procesadas en ventanas de 1 minuto (color azul), 3 minutos

(color naranja) y seis minutos (color verde). Se computaron las cuatro modas mas importantes, por lo cual cada espiga del swarmplot tiene 48 datos. Para evaluar la precisión de los métodos, se estudió la detección del ciclo circadiano, el cluster de 12 puntos a la altura de 24 hs. El método (CWT) no logra superar la variabilidad del ruido cuando se usan las ventanas de 1 y 3 minutos y detecta el ciclo circadiano solo cuando la serie es suavizada con una ventana de 6 minutos, reproduciendo los resultados de [4]. Los métodos SST y SSA muestran una gran consistencia en la detección del ciclo circadiano, independientemente del tamaño de la ventana usada.

Ademas del ciclo circadiano se esperaba encontrar clusters de periodos en el rango ultradiano correspondiente a 6, 8 y 12 hs. Podemos observar del swarmplot que CWT (6min) muestra seis grupos, mientras que SSA y SST tienen mayor variabilidad en los ultradianos. En interesante mostrar que SST y en menor medida SSA detectan ciclos de periodos mayores a 24h (infradianos), las cuales no están sostenidos por fundamentos biológicos.

## 4 Conclusiones

Los ciclos ultradianos son muy difíciles de extraer con precisión. Estos datos fueron estudiados en [4] con una resolución de 6min, mediante exploración de picos de CWT con la rutina interna de Matlab, mostrando que no todos los animales presentaban ritmos ultradianos. El uso de otras ventanas de resolución y un método algebraico justifica este resultado, mostrando una gran variabilidad en el rango de períodos menores a 24 h. El paso siguiente es comparar con GaMoSEC, un conjunto de técnicas diseñadas para extraer y corroborar la existencia de ritmos ultradianos, especificando en grupos los valores ultradianos detectados.

## References

1. Flesia, A. G., Nieto, P. S., Aon, M. A. y Kembro, J. M. (2022). Computational Approaches and Tools as Applied to the Study of Rhythms and Chaos in Biology. *Methods Mol Biol.*,2399:277-341.
2. García-Iglesias,L. , Rivera, A. L., Fossion, R. (2023) Circadian cycles: A time-series approach, *Rev. Mex. Fís.*, vol. 69, no. 5 Sep-Oct, pp. 051101 1-15.
3. Golyandina, N. and Korobeynikov,A. (2014) Basic Singular Spectrum Analysis and Forecasting with R. *Computational Statistics and Data Analysis*, Vol. 71, 934-954
4. Guzmán, D. A., Flesia, A. G., Aon, M. A., Pellegrini, S., Marin, R. H., Kembro, J. M. (2017). The fractal organization of ultradian rhythms in avian behavior. *Scientific Reports*, 7(1), 684.
5. Kembro, J. M., Flesia, A. G., Nieto, P. S., Caliva, J. M., Lloyd, D., et al. (2023) A dynamically coherent pattern of rhythms that matches between distant species across the evolutionary scale, *Scientific Reports*, 13, 5326.
6. Rösch, A. and Schmidbauer, H. (2016) *WaveletComp 1.1: A Guided Tour through the R Package*.  
[http://www.hs-stat.com/projects/WaveletComp/WaveletComp\\_guided\\_tour.pdf](http://www.hs-stat.com/projects/WaveletComp/WaveletComp_guided_tour.pdf)
7. SynchWave: Synchronsqueezed Wavelet Transform <https://rdr.io/cran/SynchWave/>