

**MEJORAS EN EL PRE-PROCESAMIENTO DE HVSR POR MAPAS AUTO ORGANIZADOS (SOM), CON APLICACIÓN A LA MICROZONIFICACIÓN SÍSMICA DE LA CIUDAD DE SALTA, ARGENTINA.**

**Roberto Carniel**

DICA, Università di Udine, Via delle Scienze, 208 - 33100 Udine, Friuli, Italia.  
[roberto.carniel@uniud.it](mailto:roberto.carniel@uniud.it)

**Luca Barbui**

DICA, Università di Udine, Via delle Scienze, 208 - 33100 Udine, Friuli, Italia.

**Lía Orosco**

IESIING – Facultad de Ingeniería e Informática – UCASAL- Campo Castañares  
Consejo de Investigación – Universidad Nacional de Salta – Avda Bolivia 5150-Salta  
[liaorosco@gmail.com](mailto:liaorosco@gmail.com)

**Jorge Torres**

IESIING – Facultad de Ingeniería e Informática – UCASAL- Campo Castañares- Salta.  
[jgenarotorres@yahoo.com.ar](mailto:jgenarotorres@yahoo.com.ar)

**José Germán Viramonte**

Consejo de Investigación – Universidad Nacional de Salta – Avda Bolivia 5150  
Facultad de Ciencias Naturales – Universidad Nacional de Salta  
[viramont@unsa.edu.ar](mailto:viramont@unsa.edu.ar)

**Silvina Guzmán**

Universidad Nacional de Salta – CONICET- Avda. Bolivia 5150, 4.400, Salta.

**RESUMEN**

En este trabajo se presentan mejoras en el proceso de aplicación de los mapas auto organizados para la determinación de relaciones espectrales H/V, cuando las señales son demasiado ruidosas y cortas. Las mejoras se relacionan con el algoritmo de la FFT, reemplazada por una implementación de Welch, el mapa topológico, y la posibilidad de elegir triángulos de diferentes anchos, para calcular la correlación cruzada entre los distintos patrones de valores. Con respecto al mapa topológico, en un mapa plano las neuronas de los bordes no tienen la misma cantidad de vecinas que las otras. Una solución puede ser adoptar un mapa toroidal conectando los bordes superiores e inferiores obteniendo un cilindro y después unir sus bases.

Para analizar el significado de los clusters de relaciones H/V es posible aplicar un algoritmo de reconocimiento utilizando la correlación cruzada ponderada para calcular valores similares en los vectores neurales. Una vez identificado el cluster principal, es posible obtener la forma más estable de la función H/V en el sitio estudiado, que se caracteriza por la menor desviación estándar (en amplitud) como lo demandan las reglas SESAME. Este análisis permite preservar la información en el dominio temporal, lo que es útil para definir las características estables en el tiempo (propias de los efectos de sitio). Se muestra un ejemplo de aplicación para las señales cortas y ruidosas en Salta.

# MEJORAS EN EL PRE-PROCESAMIENTO DE HVSR POR MAPAS AUTO ORGANIZADOS (SOM), CON APLICACIÓN A LA MICROZONIFICACIÓN SÍSMICA DE LA CIUDAD DE SALTA, ARGENTINA.

## INTRODUCCIÓN

Este trabajo es un aporte para mejorar la aplicación de la técnica de redes neuronales artificiales no supervisadas para el posprocesamiento de resultados obtenidos por el método de Nakamura (Nakamura, 1989, 2000) (también conocida por sus siglas en inglés como HVSR), que permite la estimación de los períodos fundamentales del suelo.

La identificación del pico de la función H/V no siempre es sencilla. Por el contrario, se pueden presentar dificultades debido a la direccionalidad del ruido sísmico, lo que origina que los resultados difieran considerando direcciones distintas; este problema puede ser resuelto mediante el análisis de espectros singulares o con la aplicación de las onditas (wavelets) (Carniel et al., 2006, 2008; Barazza et al., 2009).

En general, la metodología más reciente, aplica la relación entre espectros de componentes horizontales y verticales (HVSR) a ventanas temporales, para luego realizar un promedio entre ellas. Es muy frecuente que fuentes de ruidos antropogénicos intensas se sitúen cerca de los puntos de medición, afectando grandemente las señales y por ende los resultados; identificando esas ventanas, el proceso final de determinación de los picos H/V mejora considerablemente.

Un mapa autoorganizado (SOM, en sus siglas en inglés, Kohonen, 1986) es una clase de red neuronal artificial no supervisada, compuesta de dos capas, que utiliza un algoritmo de aprendizaje competitivo permitiendo graficar el patrón de datos en una red  $n$ -dimensional de neuronas, tratando de preservar las relaciones topológicas (Figura 1). Patrones cercanos en el espacio de entrada, deben ser mapeados como nodos cercanos en el espacio de salida. Los resultados pueden ser representados como mapas bidimensionales. La habilidad de la metodología SOM de identificar clusters (o agrupamientos, en este trabajo se usan indistintamente ambos términos) permite el tratamiento de datos geofísicos, en general multidimensionales, no lineales y altamente ruidosos (Klose, 2006).

La caracterización sísmica de un sitio es convertida entonces en un análisis de clusters, donde las relaciones NS y EO son consideradas separadamente.

## ALGORITMO SOM

Las neuronas artificiales se definen en una grilla de bajas dimensiones y cada neurona es descrita por un vector ponderado  $w_i$ ,  $n$ -dimensional, donde  $n$  es la dimensión de los datos de entrada (Carniel et al., 2009).

Cada neurona es conectada a las vecinas, determinando la topología del mapa. Los nodos vecinos son equidistantes en el espacio del mapa y cada neurona de la red está completamente conectada a todos los nodos de la capa de entrada. La red representa una estructura tipo “pre-alimentada”, (los datos van de atrás hacia adelante), con una sola capa computacional formada por nodos neuronales.

Cada vector de entrada es un valor HVSR calculado en una ventana temporal. Cuando un vector de entrada se presenta a la red, se origina una región o “burbuja” de actividad. La

posición y la naturaleza de esta región cambian con el vector de entrada y durante el proceso de autoaprendizaje. Todas las neuronas de la red deberían ser expuestas a un suficiente número de vectores de entrada para asegurar que el proceso de auto organización sea adecuado.

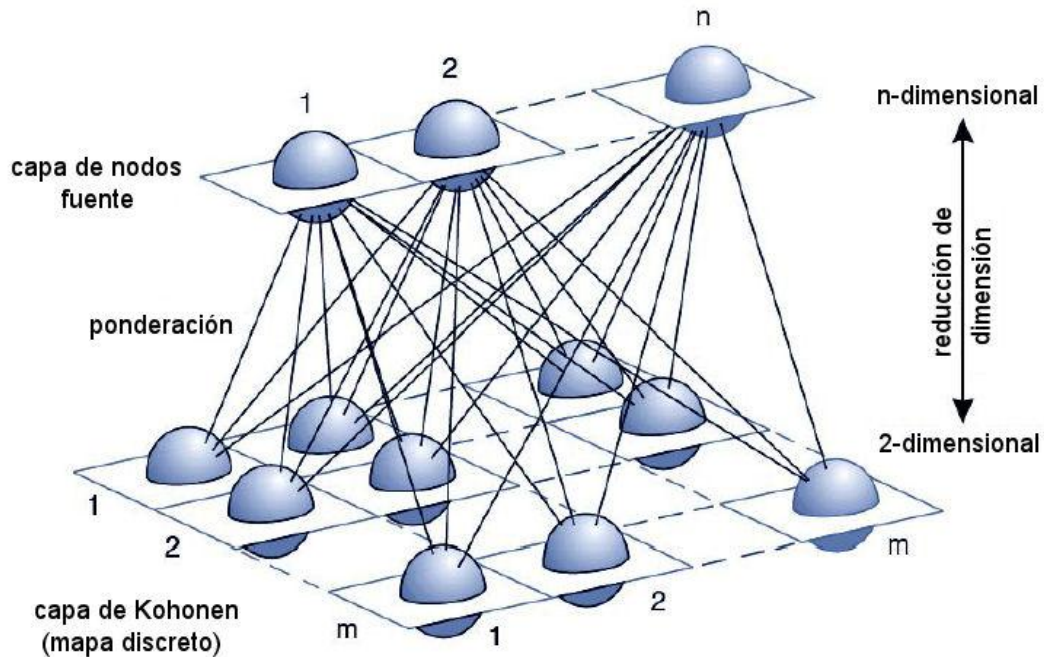


Figura 1: SOM

Hay cuatro procesos esenciales en la formación de los SOM

- 1) Inicialización de los vectores ponderados: ya que la topología y las dimensiones del mapa son fijos, es necesario inicializar los “valores” de las neuronas (nodos neuronales). Por ejemplo, puede utilizarse un proceso aleatorio.
- 2) Proceso de competencia: para cada vector de entrada, las neuronas en el mapa calculan sus respectivos valores de la función discriminante. La única neurona con el más alto valor de la función discriminante es consagrada ganadora de la competición (también conocida como la unidad del mejor match –BMU-, o neurona BMU).

Considerando que el vector de entrada sea  $x_i = [x_{i,1}, x_{i,2}, \dots, x_{i,n}]$ ; el vector ponderado en la neurona  $j$  se denota como  $w_j = [w_{j,1}, w_{j,2}, \dots, w_{j,n}]^T$ , donde  $j = 1, 2, \dots, l$ , siendo  $l$  el número total de neuronas en el mapa. Para encontrar la mejor coincidencia del vector de entrada con el vector ponderado, se utiliza el criterio de minimizar la distancia euclidiana entre los mencionados vectores.

El resultado del proceso de competición es que el espacio continuo  $X$  que activa los padrones se proyecta en el espacio discreto de salida  $M$ .

- 3) Proceso de cooperación: la neurona ganadora  $w_{c(x)}$  determina la localización espacial de neuronas excitadas cercanas, dándole las características topológicas del mapa. La función de vecindad determina cuán intensamente están conectadas las neuronas entre sí; debe ser unimodal con la distancia lateral definida como  $d_{c(x)j} = \|r_c - r_j\|$ , entre la

neurona ganadora y la neurona genérica  $w_j$ .  $r_c$  y  $r_j$  son las posiciones de las dos neuronas en el mapa. Es común elegir para definir la distancia lateral, una función gaussiana del tipo:

$$h_{c(x)j}(t) = \exp\left(-\frac{d_{c(x)j}^2}{2\sigma(t)^2}\right) \quad (1)$$

El valor de la función de vecindad también depende del tiempo discreto  $t$ ; en cada paso de tiempo, toda la base de dato es procesada por la red, examinando cada vector de entrada en orden aleatorio. El parámetro  $\sigma(t)$  define el ancho efectivo de la función de vecindad o, en otras palabras, el grado en que la neurona ganadora afecta a las vecinas. Durante el proceso de aprendizaje el radio de vecindad  $\sigma(t)$  debe disminuir monotónicamente con el paso  $t$ ; por ello, una elección común es adoptar una función exponencial del tipo  $\sigma(t) = \sigma_0 \exp\left(-\frac{t}{T}\right)$  donde  $\sigma_0$  es el valor de  $\sigma$  al comienzo del algoritmo SOM y  $T$  es una constante temporal.

- 4) Proceso de adaptación: esto permite modificar a los vectores ponderados de las neuronas excitadas para incrementar los valores de su función discriminante en relación con el vector de entrada. Este ajuste se realiza de manera que refuerza la respuesta de la neurona BUM con la aplicación de patrones de entrada similares, permitiendo el proceso de entrenamiento y la creación de los clusters de datos. Este proceso de adaptación tiene lugar generalmente de acuerdo a la siguiente formulación:

$$w_j(t+1) = w_j(t) + \alpha(t) h_{c(x)j}(t) [x_i(t) - w_j(t)] \quad (2)$$

donde  $0 \leq \alpha(t) \leq 1$  es el factor de tasa de aprendizaje, una función que decrece monotónicamente con el paso de la regresión  $t$ . Las dos funciones comúnmente utilizadas son  $\alpha(t) = \alpha_0 \exp\left(-\frac{t}{\tau}\right)$  y  $\alpha(t) = \alpha_0 \frac{\tau}{\tau+t}$  donde  $t$  es como siempre el número de iteración y  $\tau$  una nueva constante de tiempo.

## MEJORAS INTRODUCIDAS

Al aplicar SOM a los registros de ruidos ambientales, se presentan problemas tanto en el preproceso de las señales como así también en el proceso de aprendizaje y en la interpretación de resultados, ya que las señales obtenidas en la campaña de medición de vibraciones ambientales son cortas y muy ruidosas, tanto por las características del ruido cultural de la ciudad como por las limitaciones del instrumental utilizado.

Para obtener los espectros de amplitudes (espectrogramas para las direcciones Este-Oeste y Norte-Sur (Figuras 2 y 3), la clásica FFT fue reemplazada por el método de Welch (1967) que permite amortiguar los efectos del ruido, y obteniendo un balance aceptable entre la resolución en el campo de la frecuencia y del tiempo; para suavizar las señales se aplicó la función de Konno-Ohmachi (1998).

En el proceso de aprendizaje, la función discriminante se basa ahora en un índice ponderado de correlación cruzada en vez de la distancia euclidiana. Esto permite considerar mejor las formas espectrales, más que los valores puntuales de la función H/V. Más aún, durante el entrenamiento se puede elegir apropiadamente el rango de frecuencias de interés por lo que es posible comparar patrones de comportamiento de los resultados en el mismo, optimizando la organización de los mapas y dotando de mayor significancia a la organización en grupos.




Figura 2: Espectrograma de la componente EO del registro de ruido ambiental

Respecto a las propiedades topológicas, los mapas tienen la desventaja que las neuronas a lo largo de los bordes no tienen el mismo número de nodos vecinos que los interiores, resultando en un proceso de aprendizaje no homogéneo. La solución es remover los bordes, utilizando un mapa toroidal.

La última mejora ayuda a obtener una mejor interpretación. Una vez que los datos han sido proyectados en el mapa, se realiza un análisis de clusters, utilizando la correlación cruzada ponderada para calcular similitudes de los vectores de código para cada par de neuronas como se aprecia en la Figura 6. Para cada umbral del valor de similitud considerado, se detecta un número de agrupamientos en el mapa (Figura 7).

## APLICACIÓN A REGISTROS DE VIBRACIONES AMBIENTALES DE SALTA

Se presenta el análisis completo de señales de vibraciones ambientales obtenidas de una estación de tres componentes en la ciudad de Salta, con el fin de obtener la frecuencia de resonancia del suelo.

Las Figuras 4 y 5 muestran la media, mediana y desviación estándar de la relación H/V para las direcciones NS y EO.






Figura 3: Espectrograma de la componente NS del registro de ruido ambiental




Figura 4: Relaciones H/V de la componente NS

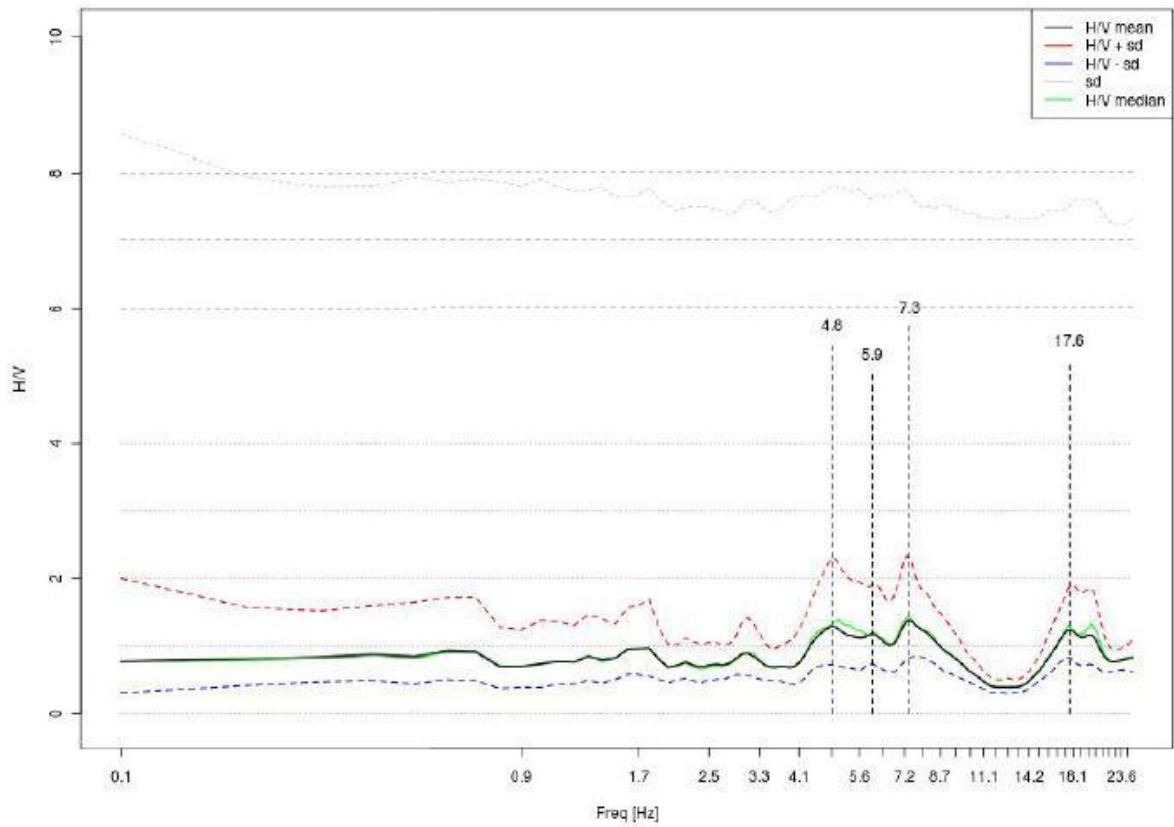


Figura 5: Relaciones H/V de la componente EO

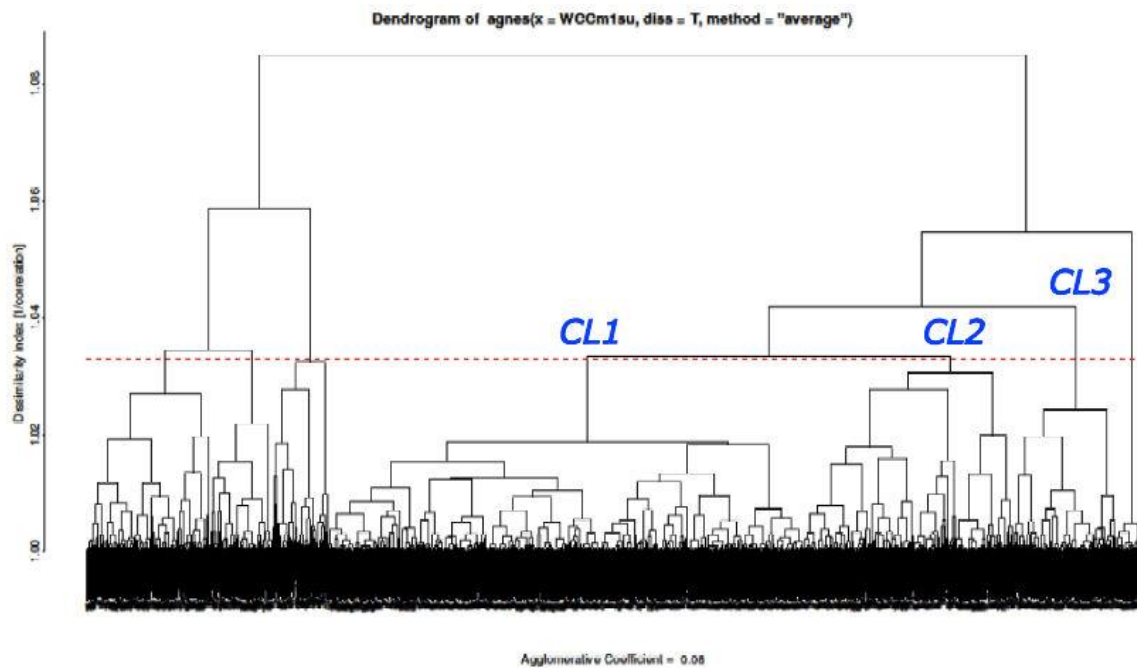


Figura 6: Dendrograma






Figura 7: Clusters (grupos) en el mapa topológico

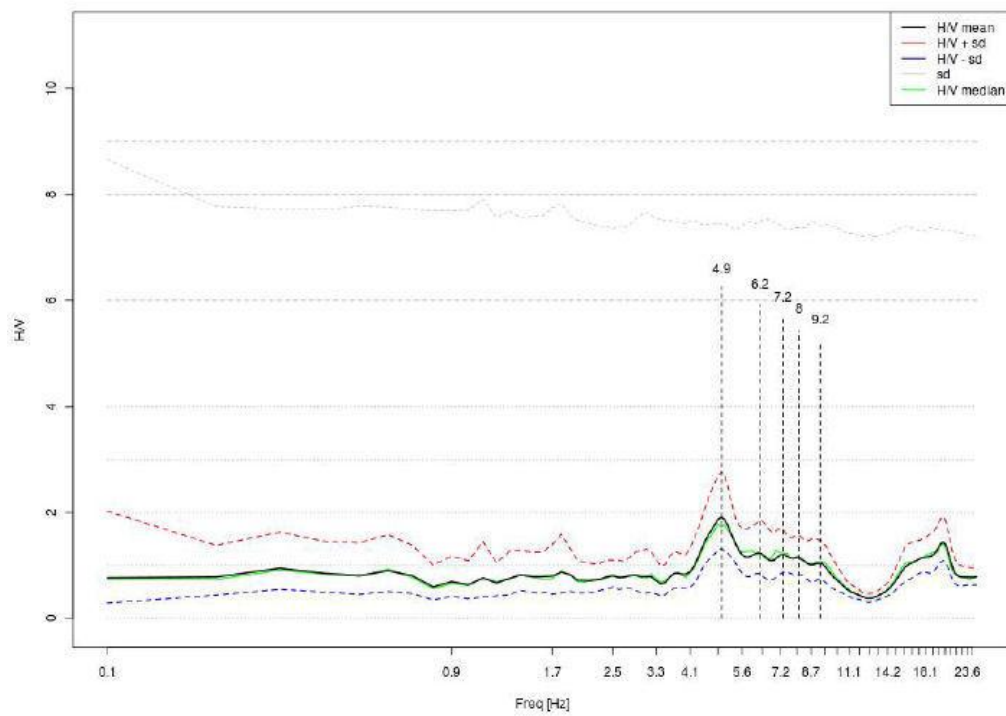


Figura 8: Cluster 1, 221 espectros en 772 códigos






Figura 9: Componentes EO y vertical de la serie temporal utilizada en el ejemplo de aplicación




Figura 10: Cluster 2, 130 espectros en 319 códigos




Figura 11: Cluster 3, 91 espectros en 1887 códigos

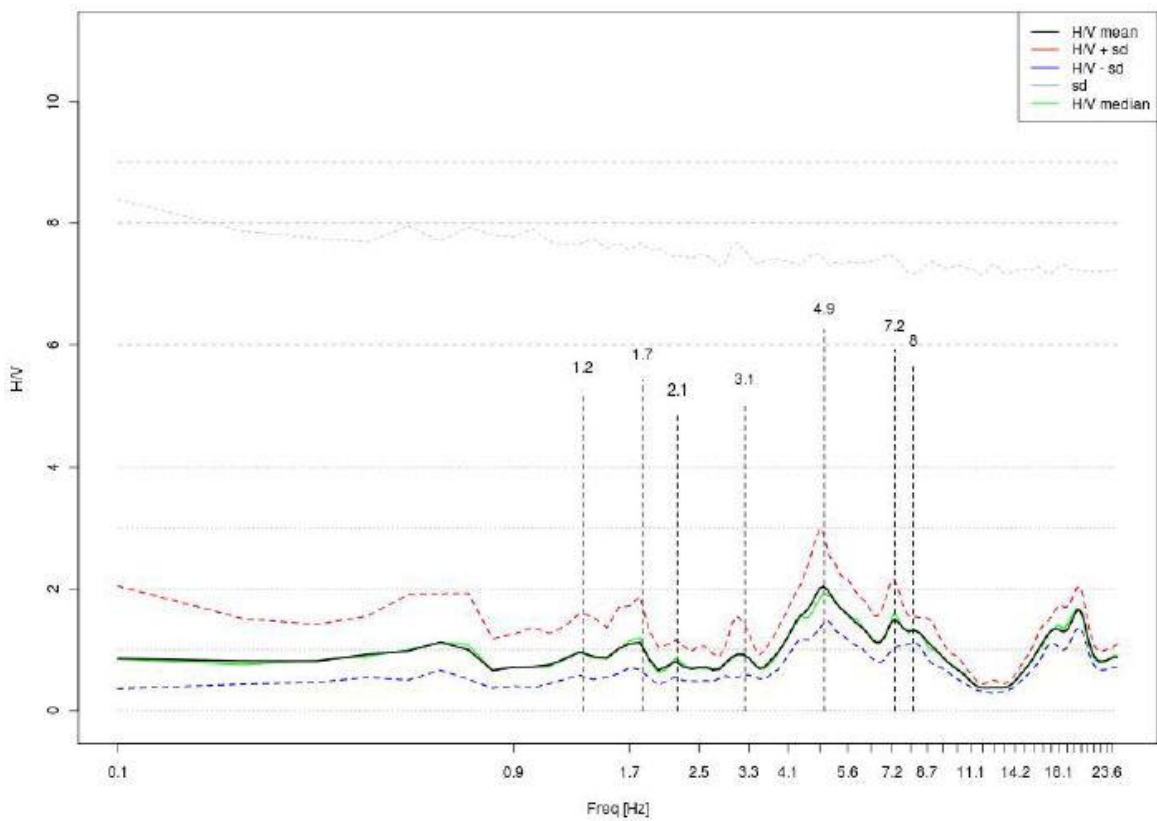


Figura 12: Cluster 1, 212 espectros en 684 códigos (Dirección NS)

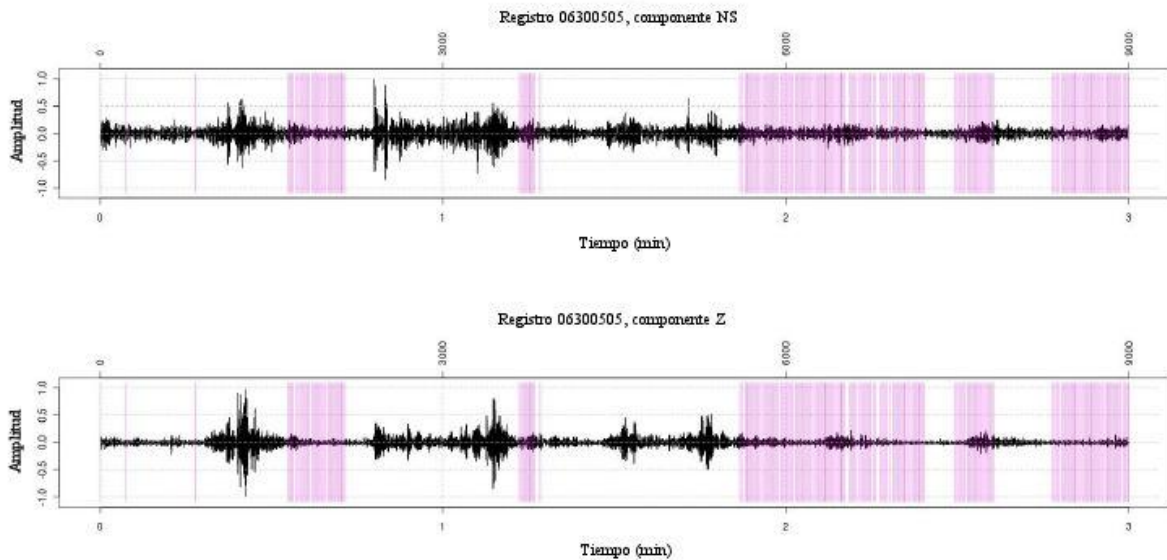


Figura 13: Serie temporal del registro aplicado en el ejemplo, en la dirección NS

El método que se propone centra el análisis en el contenido del espectrograma. Las Figuras 8, 9 y 10 muestran la media y mediana del espectro para cada uno de los tres clusters más grandes detectados en la dirección EO. La Figura 9 muestra la distribución de datos sobre los tres agrupamientos principales. Los resultados para el mismo análisis se presentan también para el cluster más importante en la dirección NS (Figuras 12 y 13).

Como se aprecia en las Figuras 8 y 12, el más grande agrupamiento en ambas direcciones se caracteriza por un pico alrededor de la frecuencia de 5 Hz. Es razonable suponer entonces que ésta es la frecuencia fundamental de ese punto medido.

## CONCLUSIONES

La aplicación de SOM para el procesamiento de los datos de mediciones de vibraciones ambientales ha probado ser una herramienta útil para ayudar en el proceso de análisis de las mismas, ya que la identificación de los picos H/V no es siempre sencilla.

En el caso de las señales obtenidas en la Ciudad de Salta, además de estar muy contaminadas por ruidos antropogénicos, son cortas, por lo que las mejoras introducidas en este trabajo permitirán reprocesar las señales obtenidas y mejorar los mapas de microzonificación de la ciudad, considerando las frecuencias fundamentales del suelo. Esto es además valioso, cuando no se cuenta con información geotécnica sobre el subsuelo de la ciudad a profundidades mayores a las de fundación de edificios.

## REFERENCIAS

Barazza, F., Malisan, P. and Carniel, R., 2009, "Improvement of H/V technique by rotation of the coordinate system". *Communications in Nonlinear Science and Numerical Simulation*, 14: 182-193.

Carniel, R., Barazza, F. and Pascolo, P., 2006, "Improvement of Nakamura technique by singular spectrum analysis". *Soil Dynamics and Earthquake Engineering*, 26:55-63.

- Carniel, R., Barbui, L. and Malisan, P., 2009, "Improvement of HVSR technique by self-organizing map (SOM) analysis", *Soil Dynamics and Earthquake Engineering*, 29, 1097-1101.
- Carniel, R., Malisan, P., Barazza, F. and Grimaz, S., 2008, "Improvement of HVSR technique by wavelet analysis". *Soil Dynamics and Earthquake Engineering*, 28:321-327.
- Klose, C.D., 2006, "Self-organizing maps for geoscientific data analysis: geological interpretation of multidimensional geophysical data". *Computational Geosciences*, 10(3): 265-277.
- Kohonen, T., 1982, "Self-organised formation of topologically correct feature map". *Biological Cybernetics*, 43:56-69
- Konno, K., and Ohmachi, T., 1998, "Ground-motion characteristics estimated from spectral ratio between horizontal and vertical components of microtremor" *BSSA*, 88:228-241.
- Nakamura, Y., 1989, "A method for dynamic characteristic estimation of subsurface using microtremor on the ground surface". *Quarterly Report of Railway Technical Research Center*, Vol 30(1): 25-33.
- Nakamura, Y., 2000, "Clear identification of fundamental idea of Nakamura's Technique and its applications", *Proceedings of the 12th World Conference on Earthquake Engineering*.
- Welch, P.D., 1967, "The use of fast fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms". *IEEE*, 15:70-73.