


Algoritmo de entrenamiento. Este corresponde al de *Levenberg-Marquardt*, el cual es una modificación del método de minimización de *Gauss-Jordan*. Este algoritmo tiene menor tiempo de convergencia que la mayoría de los métodos clásicos como la *Regla Delta Generalizada*. Se utilizó el criterio de *Early Stopping* para detener el entrenamiento cuando el error de validación alcanzó el mínimo. Este método garantiza que el sistema entrenado tiene buena generalización para un conjunto predeterminado de patrones de validación. El error de entrenamiento fue del orden de 10^{-5} . EL esquema del sistema neuronal se ilustra en la figura 7:

En el caso del Detector Neuronal de Razón de Verosimilitud, la síntesis se realizó con los siguientes parámetros:

Tamaño de la ventana (N). Debe ser determinado a partir del tipo y del contenido frecuencial de la señal sísmica [12]. Se determinó el valor de N a partir del contenido frecuencial de las señales sísmicas de tipo regional y local, lo que resulta en un valor de $N=80$ muestras, que corresponde a 4s para señales muestreadas a 20 Hz.



Número de neuronas ocultas. Se determinó empezando con 2 neuronas y probando el desempeño de la red, para un resultado final de 25 neuronas en la capa oculta.

En cuanto al conjunto de entrenamiento, este fue determinado de la misma forma que el clasificador antes analizado, empezando con conjuntos pequeños y luego incrementando dependiendo del desempeño del sistema. Al final de las pruebas el conjunto de entrenamiento estuvo compuesto de 2300 patrones de ruido y 48 patrones de onda-p. El algoritmo de entrenamiento fue una modificación de la *Regla Delta Generalizada* descrito en [3].

Figura 7. Diagrama del detector basado en el clasificador

4. Resultados y conclusiones

Los sistemas fueron probados utilizando 77 señales sísmicas de tres componentes muestreadas a 20 Hz, que corresponden a sismos regionales y locales de la zona de California y Japón. Adicionalmente se agregó ruido blanco gaussiano a las señales para determinar el desempeño de los algoritmos frente a condiciones de ruido.

La relación señal a ruido se calculó hallando la varianza del ruido antes de la onda-p, y hallando la varianza de la señal+ruido después de la onda-p en una ventana estacionaria:

$$SNR = 10 \log_{10} \left(\frac{\sigma_{S+N}^2}{\sigma_N^2} - 1 \right)$$

Los resultados del tiempo de proceso se representan en la tabla 1, los cuales se midieron para los algoritmos en la estación SUN Enterprise 3500, como también en Matlab y en Fortran 95 en un PC sobre Pentium 4.

Tabla 1.

Detector	Tiempo proceso (SUN)	Tiempo proceso (PC F95)	Tiempo proceso (PC Matlab)
Clasificador	212 ms	950 ms	4 s
LRV	59 ms	400 ms	1 s

En el caso del detector neuronal de razón de verosimilitud, el desempeño dio como resultado un error promedio de 9,1% para una relación señal a ruido mínima promedio de 15dB. Mientras, para el clasificador, el desempeño del detector resultó en un error promedio de 1,3 % y la relación señal a ruido mínima promedio fue de 9,67dB. Como se observa el trabajo del clasificador es superior al detector basado en la LRV.




Figura 8. Ejemplos de detección usando el clasificador en señales con alta SNR




Figura 9. Ejemplo de detección usando el clasificador en señales con baja SNR

Se presentan ejemplos de detección con el clasificador neuronal sobre señales sísmicas de tres componentes con alta SNR (Figura 8) y baja SNR (Figura 9). El recuadro indica la ventana donde se encuentra el tiempo de arribo de la onda-p.

Bibliografía

- C. Kuang, J. Mendel. First break refraction event picking using fuzzy logic systems, IEEE Transactions on Fuzzy Systems, Vol 2, No. 4. November 1994.
- D. Whitley, The first break seismic detection problem: representation issues ,Colorado Advanced Software Institute, 1997.
- F. Luo, R. Unbehauen Applied neural networks for signal processing , University of Erlangen-Nuremberg, 1997.
- G. Castellanos, A. Meza, J. Hurtado. Detección en tiempo real de arribo de eventos sísmicos empleando Redes Neuronales, Congreso Internacional en Inteligencia Artificial, CIIC, Agosto 2001.
- H. Dai, C. Macbeth. The application of back-propagation neural network to automatic picking seismic arrivals from single-component recordings , British Geological Survey, Edinburgh, Scotland, 1997.
- H. Dai, C. Macbeth. Arrival type identification in local earthquake data using an artificial neural network , Cahiers du Centre Européen de Géodynamique et de Séismologie. Volumen 12 - 1996.
- H. Zhang. Application of multilayer perceptron (MLP) neural network in identification and picking P-wave arrival, Department of Geology and Geophysics. University of Wisconsin-Madison, 1998.
- K. S. Anant, F. U. Dowl. Wavelet transform methods for phase identification in three-component seismograms , University of California, Davis and Lawrence Livermore National Laboratory, 1995.
- M. Basseville y I.V. Nikiforov, Detection of Abrupt Changes: Theory and Application, Prentice-Hall, Inc, 1993.
- M. Enescu, Seismic data processing using nonlinear prediction and neural networks, Tampere University of Technology. Signal processing laboratory. 1997.
- M. van der Baan, C. Jutten. Neural networks in geophysical applications, Geophysics. Vol 65. No 4. Agosto 2000.
- P. J. Oonincx, Automatic Phase Detection in Seismic Data using the Discrete Wavelet Transform, Centrum voor Wiskunde en Informatica, 1998.
- Reinoud Sleeman y Torild Van Eck, Robust Automatic P-Phase Picking: An On-Line Implementation in the Analysis of Broad-Band Seismogram Recordings, Royal Netherlands Meteorological Institute (KNMI), 1999.
- S. Haykin, Neural Networks: A comprehensive foundation , Prentice Hall, 1999.
- Z. A. Der, M. W. McGarvey, y R. H. Shumway, Automatic Interpretation of Regional Short Period Seismic Signals Using the CUSUM-SA Algorithms, Defense Threat Reduction Agency, 1999.
- Z. A. Der, M. W. McGarvey, R. H. Shumway. Automatic Interpretation of regional short period seismic signals using the cusum-sa algorithms, University of California at Davis, Davis CA.
- Z. Du, G. R. Foulger, W. Mao. Noise reduction for broad-band three components seismograms using data-adaptive polarization filters., Geophys. J. Int. 2000.
- Lippmann R, Bekman P. Adaptive Neural Ney Preprocessing for signal detection in non gaussian noise., Adv. Neural Information Processing System Vol 1 1989, pp 124-132