

Neural Network Dedektör Kullanımı ile Yeraltı Sismik Yansıma Dizilerinin Modellenmesi

Underground Modeling of Seismic Reflectivity Sequences Using Neural Network Detectors

Khosrow T.SHABESTARI* , Menouchehr BAHAVAR* , Caro LUCAS** , Mehrdad DIYANETI***

ÖZET

Ters evrişim jeofizik modellemede çok yaygın olarak kullanılmaktadır. Sismik arama yönteminde yeraltı, akustik empedans katsayıları dizilimi ile modellenebilir. Eğer kaynak belli ise sismik verilerden yararlanarak ters evrişim işleci sonucu yansıma katsayılarının hesaplanması ve kestirimi mümkündür. İstatistiksel ve alışılmış yöntemler yanı sıra ki bunlar hesaplama zamanı açısından pahalıdır, Hopfield Neural algoritması sismik iz üzerine uygulanması oldukça elverişlidir.

ABSTRACT

Deconvolution is one of the most commonly used method in geophysical modeling. In general, the earth can be modeled by a reflectivity sequence. Assuming the source wavelet is given, the seismic deconvolution problem is to estimate the reflectivity sequence based on the seismic data. The information from the reflectivity coefficients characterizes the nature of the reflecting layers inside the earth. Instead of classical method and statistical detectors which are computationally expensive, a Hopfield Neural Network is applied to seismic trace. The goal is to represent the reflectivity detection problem and solve the optimization problem.

GİRİŞ

Jeofizik bilim dalında, çeşitli fiziksel özellikler ve yöntemlerden yararlanarak yeraltı yapısının ortaya çıkartılmasına çalışılır. Bu yöntemlerden biri, sismik yansıma yöntemidir. Bir enerji kaynağından, ortama yayılan elastik dalga alanı, ortamın herhangi bir hız ve akustik empedans değişimi sonucu bir kısmı yansyarak yeryüzünde alıcılar tarafından algılanır. Bir başka deyişle kaynak fonksiyonu ile yansıma katsayılar dizisi evrişir.


EVRIŞİM MODELİ

Robinson evrişim modeli (Robinson 1954), aşağıdaki biçimde (Şekil 1) verilir. Bu modele göre birçok ters problem çözüm yöntemleri, yansıma katsayılarının kestirimi için geliştirilmiştir.

HOPFIELD NEURAL NETWORK ALGORİTMASI

Neural network algoritmasının gelişimi sonucu, son yıllarda birçok mühendislik dallarında kullanılmaktadır. Hopfield neural network şebekesi

optimum problem çözümlerinde, örneğin sismik izden yansıma katsayılarının belirtilmesinde, yaygın olarak kullanılmaktadır. Bu algoritma, sismik kesitler üzerinde ilk olarak Wang ve Mendel tarafından uygulanmıştır (Wang, 1992).



Şekil 1: Robinson sismik evrişim modeli

Figure 1: Robinson convolution model.

Robinson evrişim modelinin ifadesi, ayrık veriler için aşağıdaki bağıntı gibidir.

$$Z(k) = \sum_{i=1}^N W(k-i)U(i) + n(k) \quad (1)$$

Burada i zaman indisini, $W(k)$ sismik kaynağı, $U(i)$ yansıma dizisini, $n(i)$ gürültüyü ve $Z(k)$ sismik izi ifade etmektedir. İstatistik açısından yansıma katsayıları

* International Institute of Earthquake Engineering and Seismology, IIEES, Tehran, IRAN

** Institute of Electrotechnical, Tehran University, Tehran, IRAN


*** Khajeh Nasir-e-Tousi University, Tehran, IRAN

$U(k)$, bir Gaussian ($r(i)$) ve Bernoulli ($q(i)$) dizisi olarak hesaplanabilir. (Kormylo, 1979).


Bu durumda probleme iki açıdan bakılabilir. Birincisi $q(i)$ ' nin belirtilmesi ve ikincisi genliğin, $r(i)$ ' nin kestirimidir.

HOPFIELD' IN YAPAY VERİLERE UYGULANIŞI

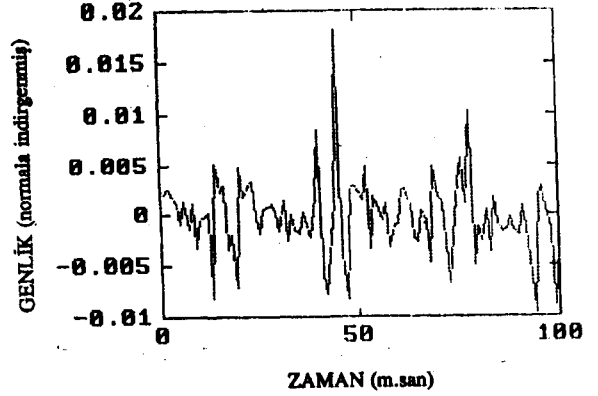
İlk olarak yapay sismogram oluşturmak için dördüncü dereceden bir yapay kaynak üretilir (Şekil 2). İki numaralı bağıntı uyarınca, yansıma dizileri üretilir (Şekil 3) ve kaynak fonksiyonu ile evriştirilir ve sonuca (sismik iz) gürültü eklenir (Şekil 4). Yansıma katsayılarının belirtilmesi için bir çok sub-optimal yöntemler kullanılmaktadır (Chi 1985, George 1965, Kormylo 1982).



Şekil 2: Kaynak dalgacığı
Figure 2: Source wavelet.



Şekil 3: Yansıma dizisi.
Figure 3: Reflectivity sequence



Şekil 4: Sismik iz
Figure 4: Seismic iz.

Bu projede **MVD** (*Minimum Variance Deconvolution*) yöntemi yanısıra Hopfield şebekesini kullanarak yansıma katsayılarının bulunmasına çalışılmıştır. Bunun için ilk olarak enerji fonksiyonu aşağıdaki gibi yazılabilir.

$$E = \frac{1}{2} \sum_{i=1}^N \left[S(k) - \sum W(k-i)q(i)r(i) \right]^2 \quad (2)$$

genliğin bir sabit değere eşit olması varsayımı durumunda:

$$\begin{aligned} E &= \frac{1}{2} \sum_{i=1}^N \left[Z(k) - \sum_{i=1}^N W(k-i)aq(i) \right]^2 \\ &= \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \left[\sum_{k=1}^N W(k-i)W(k-j) \right] q(i)q(j) \\ &\quad - \sum_{i=1}^N \left[\sum_{k=1}^N \left[W(k-i) \frac{Z(k)}{a} - \frac{1}{2} W^2(k-i) \right] \right] \end{aligned} \quad (3)$$


yukarıdaki enerji denklemi ile standart Hopfield denklemini (Hopfield 1985) kıyaslayarak aşağıdaki denklem elde edilir.

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N T_{ij} W_i W_j - \sum_{i=1}^N I_i W_i \quad (4)$$

Bu durumda şebekenin ağırlık ve girdi değerleri (6) no'lu bağıntı ile hesaplanır.


$$\begin{aligned} T_{ij} &= -\sum_{k=1}^N W(k-i)W(k-j) \\ I_i &= \sum_{k=1}^N \left[W(k-i) \frac{z(k)}{a} - \frac{1}{2} W^2(k-i) \right] \end{aligned} \quad (5)$$

Şebekenin girdi ve ağırlık değerlerini (6) no'lu bağıntıdaki gibi hesaplayarak, yansıma katsayıları için bir sub-optimal bir cevap elde edilir (Şekil 5 ve 6).



Şekil 5: MVD algoritmasının çıktısı, yuvarlak noktalar gerçek yansımaları ve çizgiler kestirimi göstermektedir.

Figure 5: MVD algorithm output.



Şekil 6: Hopfield neural network'un çıktısı, yuvarlak noktalar gerçek yansımaları ve çizgiler kestirimi gösterir.

Figure 6: Hopfield neural network output.

SONUÇ

Sonuç olarak Hopfield neural network şebekesi basit bir algoritma oluşu nedeniyle ve hesaplama hızı açısından, diğer ters evrişim yöntemlerine göre elverişlidir. Bir başka avantaj ise algoritmanın neural bilgisayarlarla kullanım olanağıdır. Bu projenin devamında ilgili şebeke gerçek arazi sismik verilerine uygulanacaktır.

KAYNAKLAR

Chi, C.Y., Mendel, J.M.1985, Viterbi algorithm detector for Bernoulli-Gaussian Processes, IEEE' Transaction on acaustic Speech and signal Processing, Vol. Assp-33, No.33.

George, D.A.1965, Matched filter for interfering signals, IEEE Transaction on infarmation theory, Vol. IT-11, Na.1,153-154.

Hopfield, J. J., Tank, D.W.1985, Neural computation of decision in optimization problem, Biological cybernatics, Vol. 52,141-132.

Kormyla, J.J. 1979, Maximum Likelihood seismic deconvolution, Ph.D. dissertation, Univ. Southern California Los angeles.

Kormylo J.J., Mandel, J.M. 1982, Maximum Likelihood detection and estimation of Bernoulli-Gaussiaa processes, IEEE Transaction on information theory, Vol. IT-28, No.3.

Robinson, E.A.1954, Predictiva decomposition of time series with application to seismic exploration, Ph.D. dissertation. Dept. of Geology and Geophysics, M.I.T., Reprinted in Geophysics, V.32, 418-484.

Wang Li-Xin 1992, A neural detector for seismic reflectivity sequenc, IEEE Transaction an Neural Networks, Val.3, No.2, 338-340.