

신경망 이론을 이용한 탄성파 주시 토모그래피의 연구

김태연¹⁾ · 윤왕중¹⁾

Seismic Traveltime Tomography using Neural Network

Tae Yeon Kim and Wang Jung Yoon

요 약 : 탄성파 토모그래피 중에서 많이 사용되는 2차원 시추공-시추공 주시 토모그래피는 파선각이 제한됨에 따라 분해능이 저하되므로, 본 논문에서는 감소된 분해능을 향상시키기 위한 방법들을 검토해 보았다. 토모그래피 역산 과정은 파선의 위치 및 주시에 대한 오차에 민감하므로 선형 주시 보간법을 사용하여 파선을 추적하였으며, 다른 파선 추적법들에 의한 역산결과와 비교하여 좋은 결과를 얻을 수 있었다. 반복적 비선형 역산 과정에 있어서, 파선경로의 추적에 소요되는 계산 시간을 줄이기 위해서 일정 계산과정 동안 선형성을 고려하였으며 그 결과 빠른 수렴을 얻을 수 있었다. 일반적으로 역산과정에서는 적절한 초기 모델의 선정이 계산 결과에 많은 영향을 미치므로, 인공 신경망을 이용하여 획득된 주시로부터 초기속도 모델을 계산하였다. 지구물리학에서 인공 신경망방법으로 많이 쓰이는 다층 전향 신경망은 내재된 단점들 때문에 좋은 결과를 얻을 수 없었으므로, 본 연구에서는 GRNN 신경망을 이용하였다. 인공 신경망으로부터 계산된 초기모델을 역산에 사용함으로써 분해능을 향상시킬 수 있었다. 그러나 파선 투과각이 넓은 경우나 탐사 대상체가 매우 복잡한 구조를 가지는 경우에는 초기모델이 역산결과에 큰 영향을 주지 않았다. 지구물리학적 토모그래피에서는 파선의 투과각이 제한을 받게되는 경우가 많으므로, 이럴 경우 인공 신경망을 이용하여 초기 모델값을 계산함으로써 역산 결과 생성되는 단면도의 분해능을 향상시킬 수 있다.

Abstract : Since the resolution of the 2-D hole-to-hole seismic traveltime tomography is affected by the limited ray transmission angle, various methods were used to improve the resolution. Linear traveltime interpolation(LTI) ray tracing method was chosen for forward-modeling method. Inversion results using the LTI method were compared with those using the other ray tracing methods. As an inversion algorithm, SIRT method was used. In the iterative non-linear inversion method, the cost of ray tracing is quite expensive. To reduce the cost, each raypath was stored and the inversion was performed from this information. Using the proposed method, fast convergence was achieved. Inversion results are likely to be affected by the initial velocity guess, especially when the ray transmission angle was limited. To provide a good initial guess for the inversion, generalized regression neural network(GRNN) method was used. When the transmitted raypath angle is not limited or the geological model is very complex, the inversion results are not affected by initial velocity model very much. Since the raypath angles, however, are limited in most geophysical tomographic problems, the enhancement of resolution in tomography can be achieved by providing a proper initial velocity model by another inversion algorithm such as GRNN.

Keywords : 탄성파 주시 토모그래피, 선형 주시 보간법, GRNN

서 론

탄성파 주시 토모그래피는 발생원에서 수신기에 이르는 P파의 초동주시만을 측정하여 매질의 탄성파 속도 분포를 구하는 방법이다. 주시 토모그래피에서는 파선의 경로와 주시계산이 정밀해야 좋은 결과를 얻을 수 있지만, 정밀한 파선추적을 위해서는 계산 시간과 비용이 많이 소요된다.

본 연구에서는 계산시간의 비용을 절감하고 동시에 분해능을 향상시키기 위한 여러 가지 방법들을 고찰해보았다. 파선추

적에 많이 사용되는 발사법과 굴곡법의 단점을 보완하기 위해 Asakawa and Kawanaka(1993)가 개발한 선형 주시 보간법(LTI, Linear traveltime interpolation) 방법을 이용하여 파선추적의 정밀성을 높였으며, 파선추적에 소요되는 계산시간을 절약하기 위하여 파선의 경로를 저장하여 선형역산을 수행한 후에 그 결과를 이용하여 다시 파선 추적하는 과정을 반복하였다.

일반적으로 시추공-시추공 토모그래피에서와 같이 파선 투과각이 제한될 경우에는 초기 모델이 분해능에 많은 영향을 준다는 사실을 확인하였으며, 적절한 초기 모델을 구하기 위하여

*1999년 5월 21일 접수
1) 전남대학교 자원공학과

인공신경망을 이용하였다. 지구물리분야에서 많이 사용되는 다층 전향 인공 신경망은 local minima에 수렴하는 경향이 있기 때문에 본 연구에 대한 적용이 불가능하였다. 그러므로 본 연구에서는 Specht(1991)의 GRNN (Generalized regression neural network) 알고리즘을 도입하여 지구 물리적 문제에 대한 적용 가능성을 알아보았다.

선형 주시 보간법에 의한 파선추적

선형 주시 보간 파선 추적법은 몇 개의 주시 계산점들을 cell 경계면 상에 위치시킨 후, 경계선상 임의의 점에서의 주시는 이웃하는 주시 계산점들의 주시를 선형 보간 함으로써 얻어질 수 있다는 가정을 이용한다. 이것은 분리된 격자점을 연결한 선들을 파선 경로로 사용했던 Moser(1991)의 이론을 보완한 Fischer and Lees(1993)의 것과 비슷한 방법으로, 최소 주시 시간이 구해지는 cell의 경계면상에 위치하는 점들을 연결하여 파선 경로로 결정한다. 이 파선 추적법이 다른 파선추적법들에 비해 가지는 장점은 선두파를 추적할 수 있다는 것이다.

선형 주시 보간 파선 추적법은 cell 상에 위치하는 주시 계산점의 개수에 의해서 파선경로의 정확성이 결정된다. 주시 계산점의 개수가 많아질수록 주시의 선형성을 가정하는 cell 경계면상의 폭이 줄어들게 되어 정확한 파선 위치와 주시를 구

할 수 있지만, 이에 따라 파선의 위치와 주시를 구하기 위해 소요되는 계산시간도 증가하게 된다. Fig. 1은 주시 계산점의 증가에 따른 파선 경로를 나타내고 있다. 이때 매질의 속도는 균질하게 설정하였다. Fig. 1(a), Fig. 1(b), Fig. 1(c)는 한 cell 당 주시 계산점이 각각 6개, 10개, 28개일 때 송신기 1번에서 반대편에 있는 24개 수신기로 이동하는 파선경로들이다. 주시 계산점이 증가할수록 실제 경로인 직선에 가까워짐을 알 수 있다. 그러나 이때 전체 24×24개의 파선을 계산하기 위해 소요되는 시간은 Pentium MMX-200을 이용할 경우 각각 10.53초, 24.17초, 167.88초가 소요되었다. Fischer and Lees(1993)에 의하면 토모그래피 분해에서는 모델에 적용하는 평활화(smoothing) 때문에 최소한의 node를 써서 실제 파선의 위치로부터 최대 3개, 평균 2개 블록을 벗어나지 않는 파선경로를 구해야 한다고 하였다. 그러므로 본 연구에서 사용한 모델 격자상의 주시 점 개수는 합성주시의 작성에서는 파선경로를 정확하게 나타내고 있는 28개로 설정하였고, 역산과정의 수행에 있어서는 파선경로의 오차는 나타나지만 계산시간이 빠른 10개로 설정하였다.

Fig. 2는 합성 주시 모델과 각 파선 추적법에 따른 역산 결과를 나타내고 있다. 합성 주시 모델의 배경 속도값은 4.0 km/sec이고 이상대 속도값은 3.2 km/sec이다. 격자는 28×23으로 설정하였으며 송수신기는 단면의 왼쪽과 오른쪽에 각각 24개씩 배열하였다. 역산 결과를 비교하기 위해 사용한 발사 파선




Fig. 1. Relationship between the number of node per cell edge and raypath accuracy in a homogeneous medium (2 km/sec). (a) 6 points in each cell, (b) 10 points in each cell, (c) 28 points in each cell




Fig. 2. Results of bore-hole tomography using various ray tracing methods in a medium having low velocity anomaly (-20%). (a) Synthetic model, (b) LTI ray tracing, (c) Shooting ray tracing, (d) Straight ray tracing.

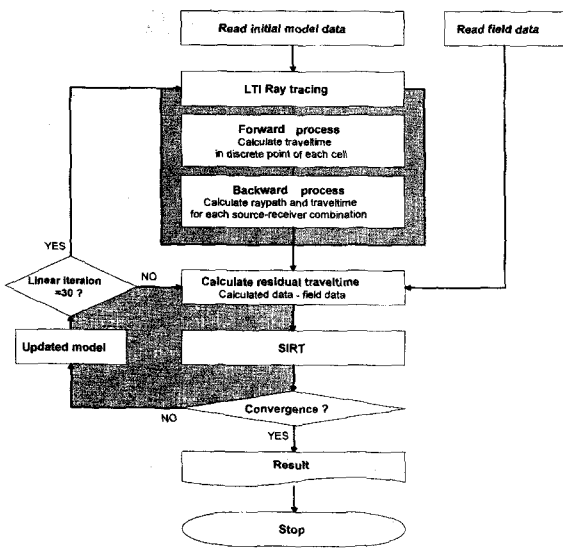


Fig. 3. Flow chart for non-linear iterative tomography. In this process, the segment length of the raypath are stored to reduce the ray-tracing time.

추적법은, 모델의 격자점에 속도를 정의함으로써 파선 및 주시를 계산하는 Tweeton *et al.*(1992)의 알고리즘을 사용하였다. LTI 파선 추적법을 이용한 역산 결과가 단층면이나 파쇄대와 같은 저속도 이상대의 탐지에 있어서 발사 파선 추적법이나 직선 파선 추적법에 비해 뛰어난 분해능을 보여준다.

역산결과와 속도 RMS오차를 계산한 결과, LTI 파선 추적법에서는 반복횟수가 90회 될 때까지 꾸준한 감소를 보였다. PC에서의 계산시간을 측정하였을 경우 Pentium MMX-200으로 10회 비선형적 반복계산을 하면 4분이 소요되었고 PentiumII 350으로는 2분 20초가 소요되었다. PentiumII 350으로 수렴성을 나타내는 90회까지 비선형적 반복 계산을 할 경우 20분이 소요된다. 주시 토모그래피의 자료처리에서 파선추적에 드는 비용은 매우 크므로, 되도록 파선추적의 횟수를 줄이기 위해 파선추적을 1회 수행한 후 계산된 파선경로를 저장하여 선형 역산을 30회 실행하였으며, 이때의 결과 모델로부터 파선추적을 다시 실시하였다. 이때 선형 역산의 계산은 매우 빠르므로 이런 방법을 사용함으로써 비교적 적은 계산시간으로도 결과

값을 반복횟수 30회만에 수렴시킬 수 있었다. Fig. 3은 본 연구에서 사용한 전체 공정을 나타내고 있다.

모델의 속도 자유도 제한 및 파선각 확장에 의한 분해능 향상

Fig. 4는 속도가 4.0 km/sec인 균질한 매질에 속도가 4.8 km/sec인 고속도 이상대와 3.2 km/sec인 저속도 이상대를 가진 합성모델과, 물리 검증등의 과정을 통해 시추공상의 속도를 알 수 있다고 가정하여 모델의 속도를 고정시켰을 때의 역산결과들을 나타내고 있다. 속도의 제한을 하지 않았을 때의 역산결과인 Fig. 4(b)의 경우에는 저속도대의 대략적인 위치만 파악할 수 있을 뿐 고속도대의 위치나 속도에 대한 정보는 거의 찾을 수 없다. Fig. 4(c)는 1열, 14열, 28열의 속도를 시추공 속도 검증에 의해 안다고 가정하여 속도 자유도를 제한한 경우의 결과를 나타낸다. 14열은 이상대의 정보를 전혀 포함하지 않는 시추공이지만 분해능이 향상되었다. Fig. 4(d)는 1열, 8열, 21열, 28열의 속도 자유도를 제한한 경우로 8열과 21열은 각각 고속도와 저속도 이상대의 중심부를 지나는 열이다. 저속도 이상대와 고속도 이상대가 분리되어 올바른 위치에 나타나고 있다.

Fig. 5는 시추공-시추공간의 주시자료 이외에 지표면에 수신기를 위치시켜 측정된 주시자료를 더했을 때의 역산결과를 나타내고 있다. Fig. 5(a)는 오른쪽 시추공과 지표면에 각각 24개와 13개의 수신기를 배열한 경우이다. 고속도 이상대에 대한 정확한 속도정보는 주시 않지만 위치는 잘 나타나고 있다. 통과하는 파선수의 증가로 인해 왼쪽 윗부분의 분해능이 향상되었고, 이에 따라 오른쪽 아래부분의 분해능도 더불어 향상되었다. Fig. 5(b)는 시추공 상의 24개 수신기 이외에, 지표면에 등간격으로 28개의 수신기를 더 배열한 경우로 이상대들의 위치 및 속도값을 잘 보이고 있다. Fig. 5(c)는 시추공의 수신기를 12개로 줄이고 지표면상에 13개를 배열했을 때의 역산결과로, 전체적인 파선의 수는 Fig. 4(b)와 비슷하지만 파선의 투과각을 넓힌 경우이다. Fig. 4(b)에 비해 해상도가 훨씬 증가하였다. 이러한 결과는 파선수의 증가보다는 투과각 확장이 해상도 증가에 많은 영향을 미친다는 사실을 확인해준다.




Fig. 4. The effect of velocity constraints to the resolution of bore-hole tomography. (a) Synthetic model, (b) No constraints are applied, (c) The velocity of the cells in 1st, 14th and 28th columns are fixed, (d) The velocity of the cells in 1st, 8th, 21th and 28th columns are fixed.




Fig. 5. The effect of raypath angle to the resolution of borehole tomography. 24 Transmitters are located in the left borehole and receivers located in right borehole and at the surface. (a) 24 borehole receivers and 13 surface receivers, (b) 24 borehole receivers and 28 surface receivers, (c) 12 borehole receivers and 13 surface receivers.

초기 속도 가정값에 따른 역산 결과의 의존성

Eppstein and Dougherty(1998)는 역투영법이나 SIRT와 같은 역산법은 평활화와 내삽을 하며 역산 결과의 수렴도가 초기 속도값에 의존한다고 하였다. 또한 감쇠 최소 자승법의 경우에도 초기 모델값이 참값으로부터 멀리 떨어진 경우에는 해가 수렴하지 않고 발산할 확률이 많다.

Fig. 6은 초기 속도값이 역산 결과에 미치는 영향을 알아보기 위한 것으로, 합성 주시 모델의 각 블록에 대한 평균 속도

값들을 초기 모델의 속도값으로 설정하였을 때의 역산 결과를 나타낸다. Fig. 6(a)와 같이 합성 모델을 7×8의 블록들로 나누어 이때의 블록 평균 속도값을 초기 속도 가정값으로 사용하였다. Fig. 6(b)는 이때 입력되는 초기 속도값으로, 고속도 이상대와 저속도 이상대에 대한 위치만을 개략적으로 나타내고 있다. 역산의 결과인 Fig. 6(c)는 송수신기가 위치한 시추공의 속도를 고정시키지 않은 경우이고 Fig. 6(d)는 송수신기가 위치한 시추공의 속도를 배경 속도값으로 고정한 경우이다. Fig. 4(b)보다 분해능이 많이 증가하였으며 속도에 대한 정보도 잘 나타




Fig. 6. Initial guess for the model has great influence on the resolution. 24 transmitters and receivers are located in the left and right borehole, respectively. (a) The block structure to obtain a average velocity model (7×8 cells). (b) The initial guess obtained by averaging within blocks, (c) Inversion result with no velocity constraints (d) Inversion result with the fixed velocity in the transmitter and receiver borehole.




Fig. 7. If the more accurate Initial guess for the model is calculated, the much better resolution of tomography can be obtainable (a) The block structure to obtain a average velocity model (4×4 cells). (b) The initial guess obtained by averaging within blocks, (c) Inversion result with no velocity constraints (d) Inversion result with the fixed velocity in the transmitter and receiver borehole.

내고 있다.

Fig. 7은 블록을 세분하였을 때의 블록 평균 속도값을 초기 속도값으로 이용한 경우에 대한 역산 결과를 나타내고 있다. Fig. 7(a)와 같이 합성 모델을 4×4의 블록들로 나누어서 계산된 블록의 평균 속도값들을 초기 모델 속도값으로 사용하였다. Fig. 7(b)는 이때 입력되는 초기 속도값으로 Fig. 6(b)에 비해 지층에 대한 정보를 많이 가지고 있다. Fig. 7(c)와 Fig. 7(d)는 이때의 역산결과들로 Fig. 6의 결과에 비해 좋은 결과를 나타낸다. 그러므로 역산에 있어서 초기 모델의 속도값을 실제 지층과 비슷하게 설정해 줄수록, 결과 단면도의 분해능이 향상된다.

인공 신경망을 이용한 역산의 초기 속도값 계산

측정된 주시자료로부터 탐사 매질의 속도값들을 계산하기 위해 인공 신경망 알고리즘을 사용하였다.

인공 신경망은 측정된 변수들 사이의 관계가 알려지지 않으면서, 입출력값들이 비선형적으로 변하는 함수 알고리즘과 관련된 문제를 푸는데 많이 사용된다. 이것은 90년대에 들어서면서 지구물리학에 본격적으로 도입이 되어, 탄성과 자료처리에서의 노동집약적인 과정인 속도분석, 주시계산, 취득 자료의 편집 등에 사용(Cary and Upham, 1992)되었으며 Bodau (1998)는 탄성과 속도로부터 절리 밀도를 결정하는데 이용하기도 하였다.

인공 신경망 알고리즘으로 가장 널리 쓰이는 방법은 역전파 알고리즘을 사용하는 다층 전향 신경망(MLFN, multiple-layer feedforward network)이다. 이때 신경망을 훈련시키는 계산 방법은 direct gradient descent를 보편적으로 이용한다. 이 계산 방법은 오차함수의 local minimum에 수렴할 수 있으며 많은 반복계산을 필요로 하는 단점을 가진다. 이러한 단점들을 보완하기 위해서 학습율을 변화시키고 수치적인 적합화를 만들게 되는데, 이를 위해 Conjugate Gradient법이나 Marquart-Levenberg법을 사용하기도 한다(Hangan et al., 1996). 이러한 보완적인 방법에도 불구하고 다층 전향 신경망은 결과값에 대한 이론적 예측이 매우 힘들고, 초기 가중치와 숨은층에 있는 neurode의 개수에 따라 신경망의 결과값이 변화한다는 점을 문제점으로 가진다. 또한 많은 수의 가중치를 구해야하는 경우에는 적절한 해를 기대하기 어렵다.

이러한 단점들을 해결하기 위해 본 논문에서는 인공 신경망 기법 중의 하나인 GRNN 방법을 사용하여 측정된 주시의 일부로부터 초기 속도 가정값을 계산하였다. GRNN이 역전파법에 비해 가지는 가장 큰 장점으로는 훈련자료가 비교적 적게 요구된다는 점이다. Specht(1991)는 역전파법과 비슷한 정확도를 얻기위해 1%의 훈련자료만이 필요하다고 하였다. 또한 GRNN은 입력되는 자료들에 대해서 표준화(예를 들면 단위벡터화)할 필요가 없다(Caudill, 1993).

GRNN은 4개의 층으로 구성된다. 첫 번째 입력층은 입력

pattern을 각각의 pattern layer의 neurode들에 배분하는 역할을 하며 두번째층(pattern layer)으로 모두 연결된다. 두번째층은 훈련 자료에 있는 각각의 pattern들에 대해 하나의 neurode를 가지고 있으며 이때의 가중치는 훈련 자료에 있는 pattern 요소들이다. j번째 pattern-layer의 입력 함수는 다음과 같이 나타낼 수 있다.

$$I_j = \sum_{i=1}^n |W_{ij} - X_{ij}| \quad \text{또는} \quad I_j = \sum_{i=1}^n (W_{ij} - X_{ij}) \quad (1)$$

여기서 x_i 는 입력신호이고 w_{ij} 는 i번째 입력 layer와 j번째 pattern layer neurode사이의 가중치이며 n은 입력층의 neurode 수를 나타낸다. 이렇게 계산된 입력값은 아래와 같은 지수함수의 형태를 가지는 비선형 활성화함수에 대입된다.

$$f(I_j) = \exp\left(\frac{-I_j}{2\sigma^2}\right) \quad (2)$$

함수에서 계산된 Pattern unit의 출력값은 Summation unit로 전달된다. Summation unit에서는 다음과 같은 적분을 실행하여 원하는 결과값을 계산해낸다.

$$\hat{Y}(\mathbf{X}) = \frac{\sum_{i=1}^n Y^i f(I_i)}{\sum_{i=1}^n f(I_i)} \quad (3)$$

여기서 Y^i 는 각 pattern layer neurode가 가지는 출력값으로써, 훈련자료에서의 결과값에 해당한다. GRNN은 그 거동식이 (2)에 있는 평활화 인자 σ 에 의해 달라지게 된다. 본 논문에서는 평활화 인자 σ 의 값을 결정하기 위해 계산 결과의 평균 체급 오차를 줄여나가는 알고리즘(Master, 1995)을 이용하여 계산했다.

인공 신경망의 입력값은 3, 7, 11, 15, 19, 23 송수신기쌍의 합성 주시값 36개를 사용하였으며, 출력값으로는 Fig. 7(a)와 같이 나타내어지는 합성모델 블록의 속도값 42개를 이용하였다. 훈련자료는 Fig. 4(a)와 같은 속도 모델에서의 속도 이상대 비가 10%, 20%, 30%, 40%, 50%인 합성 모델과, 각각의 저속도와 고속도 이상대 위치가 바뀐 합성모델들을 이용하여 총 10개로 구성하였다. Fig. 8은 이때의 계산 결과 값들을 나타내고 있다. Fig. 8(a)는 속도 이상대의 비가 25%인 경우의 주시값 36개를 입력하였을 때 계산된 블록의 평균 속도 값들로, 실제 합성주시모델과 거의 일치하는 결과를 보인다. Fig. 8(b)는 고속도대와 저속도대의 위치를 서로 뒤바꾼 경우로, 여기에서도 좋은 결과를 나타내고 있다. Fig. 8(c)는 이상대의 속도차가 0%인 균질한 매질의 주시값 36개를 입력하였을 때의 결과 속도값으로, (a)와 (b)의 경우에 비해 약간의 오차는 있지만 실제 합성모델에 많이 근접해 있음을 알 수 있다. 이때 계산 시간은 자료의 훈련시간까지 합하여 10초가 소요되었다.




Fig. 8. Results of a velocity profile using GRNN method for a initial velocity guess in a inversion processing. Input data is the traveltimes of (a) 25% anomaly case. (b) -25% anomaly case. (c) homogeneous case.

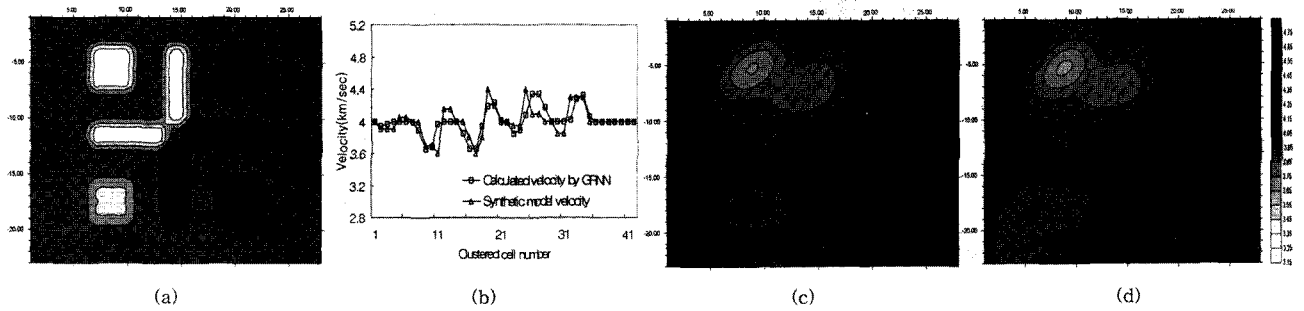


Fig. 9. Results of a bore-hole tomography for the complex synthetic model. (a) A synthetic model. (b) Calculated initial velocity guess. (c) No velocity constraints. (d) Velocities for the transmitter and receiver holes are fixed.

매우 불균질한 매질에서의 인공 신경망 적용성을 알아보기 위해 Fig. 9(a)와 같은 합성주시모형을 이용하여 알고리즘을 적용했다. 송신기는 단면도의 왼쪽에 24개를 배열하였고, 수신기는 지표면과 오른쪽에 각각 28개와 24개를 위치시켰다. Fig. 9(b)는 36개의 합성 주시값을 앞에서 훈련시킨 인공 신경망에 입력하여 구한 평균 블록 속도값과 실제 평균 블록 속도값을 나타낸다. 실제 합성 모델과 비슷한 경향을 나타내고 있다. Fig. 9(c)는 인공 신경망으로부터 계산된 블록 평균 속도값을 이용하여 얻은 역산결과이며, 역산의 초기모형을 배경값으로 주었을 때의 결과와 많은 차이를 나타내지 않았다(속도 RMS오차가 각각 0.3008와 0.3052). Fig. 9(d)는 송수신기가 위치한 시추공들의 속도를 고정한 경우이다. 이러한 결과로부터 파선투

과각이 넓은 경우나 매질이 매우 복잡한 경우에는 초기 속도 가정값이 역산 결과에 많은 영향을 미치지 않음을 알 수 있다. 실제 지질환경에서의 토모그래피 분해능을 알아보기 위해, 속도 구배를 가지는 매질에 기울어진 저속도 이상대가 존재하는 모델에서의 역산 결과를 살펴보았다. 합성모델은 지표속도가 3.8 m/sec이고 심도가 깊어짐에 따라 1 m/sec씩 속도가 증가하는 매질의 중앙에 속도가 3.4 km/sec인 단층으로 구성되어 있다. Fig. 10(a)는 합성 모델을 나타낸다. Fig. 10(b)는 36개의 주시를 인공 신경망에 입력하여 계산된 블록의 평균 속도값을 나타낸다. GRNN-1은 Fig. 8에서 훈련시킨 인공신경망의 결과이고, GRNN-2는 속도가 4 km/sec인 균질한 매질에 3.4 km/sec의 저속대층이 있는 훈련자료를 GRNN-1에 더한 인공 신경망

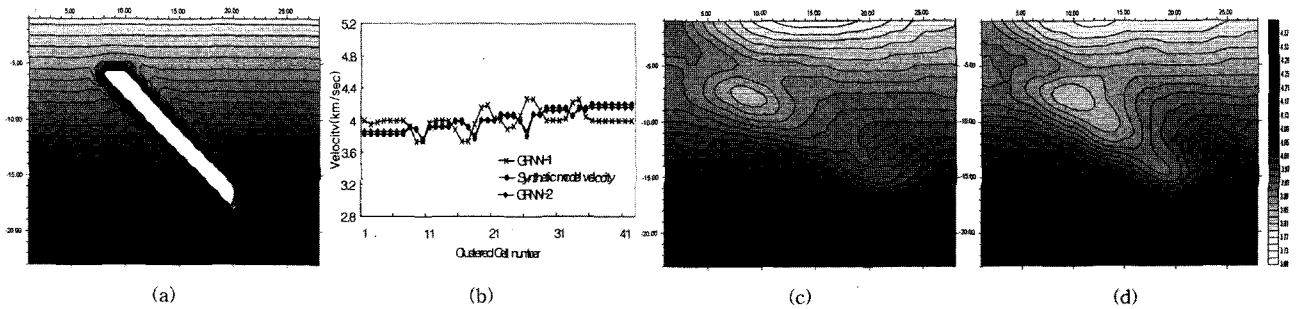


Fig. 10. Results of a bore-hole tomography for the synthetic model having velocity gradient. (a) A synthetic model. (b) Calculated initial velocity guess. If the GRNN has a similar training case with a survey area, it calculates initial velocity more exactly. (c) Using homogeneous initial velocity (3.8 km/sec). (d) Using calculated velocity from GRNN-2.

의 결과이다. 탐사되는 대상 매질과 가까운 훈련자료를 가진에 따라 인공 신경망의 속도 결과값이 실제 매질에 가까워졌다. Fig. 10(c)는 역산의 초기 속도값을 지표속도인 3.8 km/sec로 주었을 때의 결과이고, Fig. 10(d)는 GRNN-2로부터 계산된 블록의 평균 속도값을 역산의 초기 속도값으로 이용한 결과이다. 인공신경망을 이용하여 구한 초기 속도값을 사용할 경우, 단층의 위치 및 형태에 대한 분해능이 더 향상됨을 알 수 있다.

결 론

본 연구에서는 시추공-시추공 비선형 파선 토모그래피법의 계산속도 및 분해능을 향상시키기 위한 방법들을 검토하였다. 파선의 위치 저장을 통한 선형성 고려로 역산 결과의 수렴속도를 빠르게 하여 계산시간을 줄였으며, 매질의 속도 자유도 제한과 파선각 확장을 통한 토모그래피 분해능 향상을 확인하였다. 특히 역산의 안정성을 위해 인공 신경망 기법중의 하나인 GRNN법을 이용하여 측정된 주시자료로부터 초기 속도값을 구하는 방법을 제시하였다. 이러한 과정을 통하여 역산 결과 단면도의 분해능을 향상시켰다. 지구물리학적인 토모그래피에서는 파선의 투과각이 제한되는 경우가 많으므로 GRNN과 같은 역산 알고리즘을 이용하면 많은 분해능을 향상시킬 수 있을것으로 기대된다.

참고문헌

1. 윤왕중, 1991, 대수적 영상재구성법에 의한 탄성과 지오토모

그래피의 연구: 서울대학교, 박사학위논문.

2. Asakawa, E. and Kawanaka, T., 1993, Seismic ray tracing using linear travelttime interpolation: Geophysical Prospecting, **41**, 99-111.
3. Boadu, F. K., 1998, Inversion of fracture density from field seismic velocities using artificial neural networks: Geophysics, **63**, 534-545
4. Cary, P. and Upham, W., 1992, 9, An evaluation of neural networks: Geop. leading edge, **11**, 45-47.
5. Caudill, M., 1993, 5, GRNN and Bear it: AI Expert, **8**, 28-33.
6. Eppstein, M. J. and Dougherty, D. E., 1998, Optimal 3-D travelttime tomography: Geophysics, **63**, 1053-1061.
7. Fisher, R. and Lees, J. M., 1993, Shortest path ray tracing with sparse graphs: Geophysics, **58**, 987-996.
8. Hangan, M. T., Demuth, H. B. and Beale, M., 1996, Neural network design: PWS Pub, Boston, U.S.
9. Master, T., 1995, Advanced algorithms for neural networks: John Wiley & Sons, New york, U.S.
10. Moser, T. J., 1991, Shortest path calculation of seismic rays : Geophysics, **56**, 59-67.
11. Specht, D. F., 1991, A Generalized regression neural network: IEEE Trans. Neural Networks, **2**, 568-576.
12. Tweeton, D. R., Jackson, M. J., Roessler, K. S., 1992, BOM-CRATR-A Curved ray tomographic computer program for Geophysical application: Bureau of Mines, Minneapolis, MN.