

利用人工神经网络理论对地震信号及地震震相进行识别

张范民 李清河 张元生 盛国英 范兵

(中国地震局兰州地震研究所, 兰州 730000)

摘要 根据人工神经网络理论,初步研究了人工神经网络对地震信号及震相进行识别的能力.为了进行识别,将三分向地震资料的矢量模作为神经网络的输入.结果表明:用此方法确定地震震相和到时是十分有效的,特别是对于信噪比较高的地震记录,效果更好.

主题词 地震信号识别法 震相 到时 人工神经网络

中国图书分类号 P315;P315.63

0 前言

在地震定位、地震事件识别、震源机制分析和谱分析等实时地震学问题中,一个基本任务就是如何快速自动地识别并确定P波和S波震相.为了实现此目的,地震学家们提出了各种各样的算法:Allen提出了短长期平均比法以确定P波到时^[1],Bear等对此作了改进,首先将单道记录的包络线函数用非线性放大器放大,然后进行统计分析以确定P波到时并计算可信度^[2];Pisarenko等利用似然函数渐近近似法提出了一种最佳P波检测器^[3];Roberts等利用三分向资料的自互关和互相关来估计资料是否与P波或线性偏振的S波到时相符^[4];Takanami等通过弥合局部静态自回归模型来确定P波和S波到时^[5,6];Kracke根据地震波记录在球坐标系中的位移矢量提出了一种P波检测法^[7];Cichowicz提出了一种滤波法,将偏振与能量比结合起来以确定S波到时^[8];Joswig等利用主震相关法检测弱地方震记录中P波到时^[9];在国内,张范民用最大似然法确定P波和S波到时^[10].上述这些方法均为传统的方法,所用算法也不是自适应的,在某些情况下结果可能很好,在另外一些情况下结果可能很差,且结果在很大程度上受人的主观因素影响.

随着数字化地震台网的普遍建立,迫切需要一种更有效和更可靠的方法对地震资料进行实时处理并能得出较为客观的结果.人工智能技术的应用与发展为解决地震学中的这类问题展示了光明的前景.

目前,作为人工智能技术分枝之一的人工神经网络(ANNS)已被地震学家用来对地震资料进行分类和分析处理,结果说明此技术对诸如模式识别、信号辨识和分类这类问题是非常有用的.

收稿日期:1997-10-31

第一作者简介:张范民,男,1963年9月生,助研,从事地震波理论与应用研究.

人工神经网络可以根据给定的样本进行学习, 所学知识可以被用来对新资料进行分类. 与其它统计模式识别方法相比, 神经网络法不需要概率模型分布的先验知识, 但能得到更好的结果. Dowla 等利用多层感知器(MLP)神经网络识别天然地震与核爆炸, 该研究利用检测震相的谱幅值作为训练资料^[11]. Dystart 等利用多层感知器神经网络对爆破和天然地震进行分类^[12]. Wang 等利用 Hopfield 网络实现自适应最小预报误差反褶积^[13]. Jin Wang 等利用人工神经网络进行地震事件检测^[14], 在他们的研究中, 分别将短长期平均比(STA/LTA)和滑动窗谱作为输入. Hengchang 等利用三分向资料的瞬时模作为神经网络的训练样本, 并将此网络用于确定震相到时^[15].

在本研究中, 我们利用兰州台的少数几个地震记录对人工神经网络进行训练, 当训练完成后, 再用此网络确定新的地震图中的震相到时.

1 人工神经网络

人工神经网络(Artificial Neural Networks)是指由大量与自然神经系统的神经细胞类似的人工神经元互联而成的网络.

1.1 网络结构

从网络连接结构来看, 神经网络可分成反馈网络与前向网络. 在反馈网络中, 中间隐层或输出层处理元件的全部或部分状态要返回到直接或间接引起它兴奋的上一层处理元件, 而在前向网络中, 输入信息流从输入层经过隐层向输出层单向流动. 本研究利用三层式前向网络. 三层式前向网络由输入层、中间隐层和输出层组成, 其结构如图 1 所示. 相邻的处理层之间有连接, 不相邻的处理层之间没有连接, 同层各处理元件之间也没有连接.

1.2 工作原理

首先将输入模式送到输入层, 将相应目标模式即期望输出送到训练层. 如果网络处于学习模式, 网络输出层的实际输出要与训练层的期望输出进行比较, 即计算出两者之差, 这一差值被用来修正输出层及隐层的权值.

学习的目的是使网络的实际输出与期望输出以一定的方式接近, 重复这一过程, 直到网络的输入输出映射能力达到一定的精度.

所谓网络学习, 就是要提供一个算法使之能对给定的输入确定一组权值来使网络输出层的输出很好地逼近所希望的目标输出. 网络中各神经元输入输出的激励函数取为逻辑活动函数, 各神经元结构如图 2 所示.




图 1 多层感知器神经网络结构

Fig. 1 Structure of a multi-layer perceptron neural network (from Jin Wang, 1995).

$$X_i = F(d_i) = \frac{1}{1 + e^{-\beta d_i}} \quad (1)$$

其中

$$d_i = \sum_{j=1}^N W_{ij} X_j - \theta_i \quad (2)$$

式中 X_i 为第 i 个神经元的输出, β 为常数, d_i 为第 i 个神经元的加权输入, X_j 为上一层第 j 个神经元(共有 N 个)的输出, 也就是下一层神经元的输入, W_{ij} 为两层神经元之间的权值, θ_i 为阈




图 2 具有 N 个输入的单个人工神经元的结构

Fig.2 Architecture of a single artificial neural consisting of N input units (from Dowla F U, 1990).

值.

通过网络训练可确定神经网络的权值和阈值,对于本研究中的三层式前向网络,采用目前广泛应用的误差后向传播(BP)算法.对于输出层,定义目标函数

$$J_p = \frac{1}{2M} \sum_{k=1}^M [T_k(p) - O_k(p)]^2 \quad (3)$$

$$J = \frac{1}{p} \sum_{p=1}^p J_p \quad (4)$$

式中 M 为神经网络输出层的神经元个数, $O_k(p)$ 为第 p 个训练模式的实际输出, $T_k(p)$ 为所期望的输出,误差后向传播算法利用最小二乘法极小化(4)式,可通过调整权值和阈值来实现,按照误差负梯度方向进行.对于每一个输入模式,权值和阈值都要从输出层到输入层进行修改,即网络学习是在给定的输入输出模式的监督下进行的.此算法可表示为

$$W_{ij}(p) = W_{ij}(p-1) + \Delta W_{ij}(p) \quad (5)$$

$$\Delta W_{ij}(p) = \eta \delta_i(p) O_j(p) + \alpha W_{ij}(p-1) \quad (6)$$

式中 η 称为学习率, α 称为惯性参数.

$$\delta_i(p) = F'(d_i) (\partial J_p / \partial X_j) \quad (7)$$

式中 $\delta_i(p)$ 为第 i 个神经元的误差, $F'(d_i)$ 为(1)式的导数.

对于隐层,可得其误差为

$$\delta_i(p) = O_i(p) [1 - O_i(p)] \sum_k \delta_k(p) W_{ik} \quad (8)$$

对于输出层,可得其误差为

$$\delta_i(p) = O_i(p) [1 - O_i(p)] [T_i(p) - O_i(p)] \quad (9)$$

当误差小于某一给定值时,网络学习结束.

2 地震震相检测

2.1 输入资料的特征

我们利用三分向地震资料的瞬时矢量模 $M(t)$ 作为网络的输入.因为地震信号的初动特征与震源位置和射线传播方向有关,而瞬时矢量模则与台站和地震的相对位置无关,选择 $M(t)$ 作为网络输入便可突出震相初动特征.当新震相到来时, $M(t)$ 幅度显著变大.在每个时间窗内,我们将 $M(t)$ 规一化,这样就可以使 $M(t)$ 的幅度不依赖于震级和震中距.本研究所用计算流程见图 3.

本研究中所用资料为中国 CDSN 兰州台记录到的 1990 年景泰地震和 1995 年永登地震的一些前震和余震资料,除了少部分地震资料被用于网络训练外,其它地震资料均被用来检验此方法.

2.2 网络训练

在本研究中,滑动窗长取为 1 s(41 个采样点),可包含几个完整周期的地震波,因此神经网络的输入层神经元数目为 41,输出层的神经元数目为 2,若输入信号包含地震初动,则期望

输出的矢量为[1,0],反之则为[0,1].隐层神经元数目的选择是一个非常复杂的问题,一般说来,减少隐层神经元数目,可增加网络的一般性且可减少计算内存,但是隐层神经元数目太少会使网络学习时间很长或不收敛,经过大量的试验我们最终将其取为10.

将规一化的训练样本 $M(t)$ 分为两组,一组包含P波或S波初动,另一组为背景噪音信号(图4).图4(a)为包含初动的地震信号,初动在第11个采样点(箭头所示),下边的7条记录为P波的 $M(t)$,上边的5条为S波的 $M(t)$;图4(b)为相应的背景噪音的 $M(t)$.

因为网络是自适应的,初始权值可以随机地赋予很小的值,经训练后,最终的权值将被确定下来.为了能使网络较快地收敛,可先选几个样本进行训练,当网络收敛后,以此权值为初值,增加样本数并提高精度,然后重新训练,这样就可大大缩短训练时间.

2.3 到时检测

将滑动时间窗逐点向前滑动,计算每一个窗内的瞬时矢量模 $M(t)$,将其规一化后输入到训练后的神经网络中,计算网络的输出 $O_1(t)$ 和 $O_2(t)$,定义函数

$$F(t) = \frac{1}{2} [O_1(t)^2 + (1 - O_2(t))^2] \quad (10)$$

并将 $F(t)$ 作为衡量地震初动的一个函数.在本研究中将 $F(t)$ 的下限值定为0.6,峰值宽度定为滑动时窗的一半.某些处理结果如图5~图10所示,表1为其相应的地震参数.

从图5可以看出,三分向记录的信噪比很高,我们可以简单地将信噪比定义为初动前后最大振幅之比.对于P波初动而言, $F(t)$ 的峰值宽度很宽,顶部很平,而所画竖线为神经网络根据局部最大值所确定的P波初动时刻,对于S波而言,由于其信噪比较P波低,因而 $F(t)$ 的宽度较窄,但仍然给出了准确的S波初动到时.对于图6来说,其P波和S波的信噪比均比图5中的要低,但是仍然给出了准确的初动到时.需要注意的是,标志P波初动的 $F(t)$ 不象图5中的那样宽而平坦.图7中地震记录的信噪比更低,因而其 $F(t)$ 峰值更窄且凹凸不齐,我们认为所确定的初动到时还是准确的.经过大量的研究发现,记录的信噪比高低直接影响着结果的好坏,对于信噪比大于3的记录,网络能够比较准确地定出初动到时,误差不会超过一个采样点.但对于信噪比小于3的记录,所确定的到时很不精确,有时甚

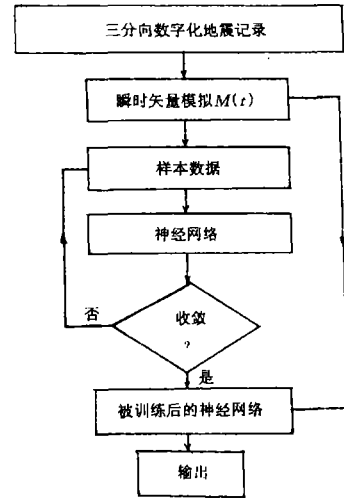


图3 计算流程

Fig.3 Calculation flow chart.




图4 训练样本 $M(t)$

Fig.4 Training Patterns.

(a) 地震初动;(b) 背景噪音




图5 地震1的三分向记录、矢量模 $M(t)$ 和函数 $F(t)$

Fig.5 The three-component records, vector modulus $M(t)$ and function $F(t)$ of earthquake 1.




图6 地震2的三分向记录、矢量模 $M(t)$ 和函数 $F(t)$

Fig.6 The three-component records, vector modulus $M(t)$ and function $F(t)$ of earthquake 2.




图7 地震3的三分向记录、矢量模 $M(t)$ 和函数 $F(t)$

Fig.7 The three-component records, vector modulus $M(t)$ and function $F(t)$ of earthquake 3.




图8 地震4的三分向记录、矢量模 $M(t)$ 和函数 $F(t)$

Fig.8 The three-component records, vector modulus $M(t)$ and function $F(t)$ of earthquake 4.




图9 地震5的三分向记录、矢量模 $M(t)$ 和函数 $F(t)$

Fig.9 The three-component records, vector modulus $M(t)$ and function $F(t)$ of earthquake 5.




图10 地震6的三分向记录、矢量模 $M(t)$ 和函数 $F(t)$

Fig.10 The three-component records, vector modulus $M(t)$ and function $F(t)$ of earthquake 6.

至不能给出初动到时. 由图8我们可以看到, 网络不仅给出了P波和S波初动, 而且给出了P波初动之后的另一个震相. 图10与图8情况相似. 这就说明, 此网络不但能够确定初动明显的P波和S波初动, 而且也能给出其它振幅明显变化的震相到时. 图9中的地震记录是一个近震记录, 波形与前面几个地震的波形有些不同, 但所确定的到时也是很准确的.

表1 本研究所给实例的地震参数

编号	发震时间	北纬	东经	深度(km)	震级(M_L)	Δ/km
1	1990-04-15-15:08:46	37°07′	103°40′	11	3.6	115.21
2	1990-11-03-04:06:18	37°08′	103°34′	15	2.6	118.56
3	1991-01-03-12:59:23	36°55′	103°12′		2.6	109.23
4	1991-10-12-08:21:01	36°23′	103°18′		3.2	59.14
5	1994-08-26-05:01:51	36°01′	103°41′		2.5	14.82
6	1995-08-26-15:52:53	36°21′	103°11′		3.0	64.82

除了信噪比以外, 滑动窗长度(即输入层神经元数目)也对结果有影响. 一般来说, 该窗长度应该包含几个周期的波, 然而, 很长的滑动窗并不一定就能给出一个好的结果, 实际上地震信号的特征直接影响着滑动窗的长度, 这种影响是很复杂的. 在本研究中, 我们经过大量试验发现, 对兰州台的资料, 输出层的神经元数目取为41最佳.

初动的确定是通过寻找函数 $F(t)$ 的局部最大值来实现的, 当最大值超过给定的阈值时, 就认为是一个新的初动. 在本研究中, 我们将其阈值取为0.6, 在这种情况下, P波的检测率为96.8%, S波检测率为86%, 当然, 也存在着一些非地震初动的虚报, 若加上其它限制条件, 如 $F(t)$ 的峰值宽度限制, 就可大大降低这种虚报率.

3 讨论与结论

随着数字化地震台网的普遍建立, 迫切需要一种有效、可靠的方法对地震资料进行实时处理. 在许多实时地震学问题中, 一个基本任务就是如何快速自动地识别并确定P波和S波震相. 地震学家们虽然提出了许多算法, 但这些传统的方法本身不是自适应的, 所得结果在很大程度上受人为因素的干扰. 人工智能技术的应用与发展为解决地震学中的这类问题提供了一种行之有效的途径, 在本文中我们利用作为人工智能技术分枝之一的人工神经网络来识别地震震相并确定其到时, 效果很好.

通过前面的应用实例, 我们可以得出如下结论:

- (1) 利用人工神经网络进行震相识别是一种行之有效的方法.
- (2) 地震记录的信噪比对于处理结果的好坏有直接的影响, 要获得比较可靠的结果, 资料的信噪比必须要好.
- (3) 神经网络的输入层神经元数目和隐层神经元数目也对结果有影响, 通过试验可将其最佳数目确定下来.
- (4) 对 $F(t)$ 加上某些限制, 可以提高准确率, 从而降低虚报率.

参考文献

- 1 Allen R V. Automatic earthquake recognition and timing from single trace. *B. S. S. A.*, 1978, 68:1521~1532.
- 2 Bear M, Kradolfer U. An automatic phase picker for local and teleseismic event. *B. S. S. A.*, 1987, 77:1437~1445.
- 3 Pisarenko V F, Kushnir A F, Savin I V. Statistical adaptive algorithms for estimation of onset movements of seismic phases. *Phys. Earth Planet. Int.*, 1987, 47:4~10.
- 4 Roberts R G, Christofferson A, Cassidy F. Real-time event detection, phase identification and source location estimation using single station three-component seismic data. *Geophys. J.*, 1989, 97:471~480.
- 5 Takanami T, Kitagawa G. A new efficient procedure for the estimation of onset times of seismic waves. *J. Phys. Earth*, 1988, 36:267~290.
- 6 Takanami T, Kitagawa G. Multivariate time-series model to estimate the arrival times of seismic waves. *Comput. Geosci.*, 1993, 19:295~301.
- 7 Kracke D. A three-component event detector: based on wave form analysis. *Comput. Geosci.*, 1993, 19:117~122.
- 8 Cichowicz A. An automatic S-phase picker. *B. S. S. A.*, 1993, 83:180~189.
- 9 Joswig M, Schulte-Theis H. Masterevent correlations of weak local earthquake by dynamic waveform match. *Geophys. J. Int.*, 1993, 113:562~574.
- 10 张范民. 利用最大似然法进行波场分解和震相识别. *西北地震学报*, 1993, 15(3):1~10.
- 11 Dowla F U, Taylor S R, Anderson R W. Seismic discrimination with artificial neural networks: preliminary results with regional spectral data. *B. S. S. A.*, 1990, 80:1346~1373.
- 12 Dystart P S, Pulli J J. Regional seismic event classification at the NORESS array: Seismological measurements and the use of trained neural networks. *B. S. S. A.*, 1990, 80:1910~1933.
- 13 Wang L X, Mendel J M. Adaptive minimum prediction - error deconvolution and source wavelet estimation using neural networks. *Geophysics*, 1992, 57:670~679.
- 14 Wang Jin, Teng Taliang. Artificial neural networks - based seismic detector. *B. S. S. A.*, 1995, 85:308~319.
- 15 Dai Hengchang, Colin MacBeth. Automatic picking of seismic arrivals in local earthquake data using an artificial neural network. *Geophys. J. Int.*, 1995, 120:758~774.

THE SEISMIC SIGNAL AND PHASE RECOGNITION BY USING ARTIFICIAL NEURAL NETWORK THEORY

Zhang Fanmin Li Qinghe Zhang Yuansheng Shen Guoying Fan Bing
(*Lanzhou. Institute of Seismology, CSB, Lanzhou 730000*)

Abstract

According to the theory of artificial neural networks, a preliminary study has been performed to test the ability of recognising seismic signals and phases by using artificial neural networks, and the phase recognition has been achieved for three-component recordings by using vector modulus of these seismic records as the network input. Results show that the method is very valid in the determination of seismic phases and arrivals, especially for high signalnoise ratio records.

Key words Earthquake signal recognition method, Seismic phase, Arrival time, Artificial neural network