

文章编号: 0253-2239(2007)03-0384-7

基于 Madaline 网络的气溶胶消光系数反演算法*

韩道文 刘文清 陆亦怀 张玉钧 杨辉

(中国科学院安徽光学精密机械研究所环境与光学技术重点实验室, 合肥 230031)

摘要: 运用激光雷达监测气溶胶是大气环境监测的一项重要内容,通过激光雷达方程可以反演得到气溶胶消光系数,并进而获得气溶胶的其他特性。然而传统方法在反演气溶胶消光系数时需要很多假设,使得反演精度受到很大限制。提出了一种利用多层自适应线性(Madaline)人工神经网络来反演气溶胶消光系数的方法,通过对网络进行训练,可由激光雷达回波信号直接反演气溶胶消光系数,从而可有效避免传统方法的诸多假设。对比实验表明该方法使反演精度大大提高,获得了很好的反演结果。

关键词: 大气光学; 消光系数; 多层自适应线性网络; 激光雷达

中图分类号: X831.03 文献标识码: A

A Retrieve Method for Aerosol Extinction Coefficient Based on Madaline Networks

Han Daowen Liu Wenqing Lu Yihuai Zhang Yujun Yang Hui

(Key Lab of Environmental Optics & Technology, Anhui Institute of Optics and Fine Mechanics, the Chinese Academy of Sciences, Hefei 230031)

Abstract: Aerosol detecting using lidar is an important part of atmosphere monitoring. Many aerosol properties are gained on the base of the aerosol extinction coefficient received through lidar equation. The traditional method restricts the precision of the aerosol extinction coefficient because of many hypotheses. A new procedure was developed, based on the Madaline artificial neural network theory to retrieve the aerosol extinction coefficient. Through the trained network, the aerosol extinction coefficient could be retrieved from the lidar echo signal directly, consequently the new method dispensed with those hypotheses in the traditional method. According to the comparison of the different test results, the new method improved the precision of retrieval greatly and good result was obtained.

Key words: atmospheric optics; extinction coefficient; Madaline networks; lidar

1 引 言

激光雷达作为一种主动遥感探测工具已经有 30 多年的历史^[1],已广泛应用于激光大气传输、全球气候预测、气溶胶辐射效应及大气环境等研究领域^[2]。气溶胶激光雷达为大气气溶胶探测研究提供了有力的工具,成为探测大气气溶胶光学-物理参量时空分布的一个有效、可靠的手段,20 世纪 60 年代以来始终是激光大气遥感的一个前沿研究课题^[3~6]。

米氏(Mie)散射气溶胶激光雷达是根据米氏散射理论,通过雷达方程反演气溶胶消光系数,进而得到气溶胶的其他特性。然而在反演消光系数时,由于雷达方程中有太多的变量,为了计算的方便,许多变量都用经验值或假设来代替,这使得消光系数的反演存在着诸多不确定的因素,因而其结果的可靠性受到置疑。

采用具有自学习功能的神经网络模型来反演气

* 国家 863 计划(2005AA64100)资助课题。

作者简介: 韩道文(1974—),男,安徽桐城人,讲师,博士研究生,主要从事激光雷达大气环境监测方面的研究。

E-mail: dwhan@aiofm. ac. cn

导师简介: 刘文清(1954—),男安徽蚌埠人,博士,研究员,博士生导师,主要从事环境监测技术、痕量技术、水体、目标散射特性等的光学与光谱学监测方法,机动车尾气在线监测技术等研究和相应的监测仪器研发工作。E-mail: wqliu@aiofm. ac. cn

收稿日期: 2006-01-10; 收到修改稿日期: 2006-06-01

溶胶消光系数,是一种全新的方法。神经网络的主要特征之一是具有自学习能力,通过对样本模式的学习可以将信息之间的内在机制分布式地存储在神经网络中。神经网络反演消光系数的实质是通过选择适当的神经网络模型,逼近雷达方程真实解的动态过程。因为避免了诸多假设的不确定性,使得反演结果的可信度大大增加。本文利用多层自适应线性(Madaline)神经网络对雷达数据进行处理,为该领域的进一步研究提供参考。

2 传统反演方法及其不足

2.1 反演方法

激光雷达垂直发射的激光光束通过大气时,其接收到高度 z 处大气后向散射回波信号的能量 p

(z)由雷达方程决定^[7]:

$$p(z) = p_0 C z^{-2} [\beta_1(z) + \beta_2(z)] T_1^2(z) T_2^2(z), \quad (1)$$

式中 p_0 是激光发射能量; C 是激光雷达系统常数; $\beta_1(z)$ 和 $\beta_2(z)$ 分别是高度 z 处的气溶胶粒子和空气

分子的后向散射系数; $T_1 = \exp\left[-\int_0^z \alpha_1(z') dz'\right]$ 是气

溶胶透射率, $T_2 = \exp\left[-\int_0^z \alpha_2(z') dz'\right]$ 是空气分子透射率。 $\alpha_1(z)$ 和 $\alpha_2(z)$ 分别是高度 z 处的气溶胶粒子和空气分子消光系数。

如果事先已知某一高度 z_c 处气溶胶粒子和空气分子后向散射系数,则 z_c 处以下各高度上的气溶胶粒子后向散射系数(后向积分)为

$$\beta_1(z) = -\beta_2(z) + \frac{X(z) \exp\left[2(s_1 - s_2) \int_z^{z_c} \beta_2(z') dz'\right]}{\frac{X(z_c)}{\beta_1(z_c) + \beta_2(z_c)} + 2s_1 \int_z^{z_c} X(z') \exp\left[2(s_1 - s_2) \int_z^{z_c} \beta_2(z'') dz''\right] dz'}, \quad (2)$$

而 z_c 处以上各高度的气溶胶粒子后向散射系数(前向积分)为

$$\beta_1(z) = -\beta_2(z) + \frac{X(z) \exp\left[-2(s_1 - s_2) \int_z^{z_c} \beta_2(z') dz'\right]}{\frac{X(z_c)}{\beta_1(z_c) + \beta_2(z_c)} - 2s_1 \int_z^{z_c} X(z') \exp\left[-2(s_1 - s_2) \int_z^{z_c} \beta_2(z'') dz''\right] dz'}, \quad (3)$$

其中 $X(z) = p(z) z^2$; $s_1 = \alpha_1(z) / \beta_1(z)$, 是气溶胶消光后向散射比; $s_2 = \alpha_2(z) / \beta_2(z)$, 是空气分子的消光后向散射比。

在激光雷达平流层气溶胶探测研究中,除用气溶胶粒子后向散射系数来表征平流层气溶胶的光学性质外,通常还使用气溶胶散射比 $R(z)$, 它定义为 $R(z) = 1 + \beta_1(z) / \beta_2(z)$ 。

在激光雷达对流层气溶胶探测研究中,一般用气溶胶粒子消光系数来表征对流层气溶胶的光学性质。因此,同样地,如果事先已知某一高度 z_c 处气溶胶粒子和空气分子消光系数,则 z_c 处以下各高度上的气溶胶粒子消光系数(后向积分)为

$$\alpha_1(z) = -\frac{s_1}{s_2} \alpha_2(z) + \frac{X(z) \exp\left[2\left(\frac{s_1}{s_2} - 1\right) \int_z^{z_c} \alpha_2(z') dz'\right]}{\frac{X(z_c)}{\alpha_1(z_c) + (s_1/s_2) \alpha_2(z_c)} + 2 \int_z^{z_c} X(z') \exp\left[2\left(\frac{s_1}{s_2} - 1\right) \int_z^{z_c} \alpha_2(z'') dz''\right] dz'}, \quad (4)$$

而 z_c 处以上各高度的气溶胶粒子后向散射系数(前向积分)为

$$\alpha_1(z) = -\frac{s_1}{s_2} \alpha_2(z) + \frac{X(z) \exp\left[-2\left(\frac{s_1}{s_2} - 1\right) \int_z^{z_c} \alpha_2(z') dz'\right]}{\frac{X(z_c)}{\alpha_1(z_c) + (s_1/s_2) \alpha_2(z_c)} - 2 \int_z^{z_c} X(z') \exp\left[-2\left(\frac{s_1}{s_2} - 1\right) \int_z^{z_c} \alpha_2(z'') dz''\right] dz'}, \quad (5)$$

2.2 传统反演方法的不足

从上述反演方程式可以看出,若要从激光雷达测量的回波信号中得到气溶胶后向散射系数 $\beta_1(z)$ 或消光系数 $\alpha_1(z)$, 必须预先知道 $s_1, s_2, \beta_2(z)$ [或 $\alpha_2(z)$] 和边界值 $\beta_1(z_c)$ [或 $\alpha_1(z_c)$] 四个参量。

$s_1 = \alpha_1(z)/\beta_1(z)$ 是气溶胶消光后向散射比,它依赖于气溶胶粒子的尺度谱分布和折射指数。实际反演消光系数时,人们大都依据不同条件来确定的 s_1 值,例如:火山爆发期的平流层气溶胶, s_1 分别取 40(6~15 km), 22(15~25 km), 40(20~25 km) 和 43(25~30 km)。对于背景期的平流层和对流层气溶胶,假设其值为 50。

$s_2 = \alpha_2(z)/\beta_2(z)$ 是对应的空气分子的消光后向散射比,其值一般固定为 $8\pi/3$, 并不随地点和时间的改变而改变。同样的,空气分子的后向散射系数 $\beta_2(z)$ [或 $\alpha_2(z)$] 使用美国标准大气模式获得空气分子密度的垂直分布廓线,再由分子瑞利散射理论计算得到。这些变量的值都不随测量地点和时间的改变而改变。

另一个影响计算误差的变量是标定高度 z_c 。 z_c 是通过选取近乎不含气溶胶粒子的清洁大气层所在的高度来确定。这个高度上的 $X(z)/\beta_2(z)$ 的值应最小,通常在 3.5~6.0 km 高度范围内自动选取,并且设 $R(z_c) = 1 + \beta_1(z_c)/\beta_2(z_c) = 1.01$ 。

上述这些假设在反演消光系数时基本不变,然而不同地方不同时间的大气状况是不同的,胡欢陵等^[8]就讨论了 s_1 对激光雷达方程解的影响,并指出用实时测量的 s_1 来处理激光雷达回波数据是必要的,表明用固定的经验值来处理激光雷达回波信号,反演消光系数存在一定的误差。因此这些不确定因素的存在,使得消光系数反演结果的可靠性令人置疑。

3 Madaline 网络

3.1 多层自适应线性网络结构^[9,10]

多层自适应线性(Madaline)神经网络结构如图 1 所示。

设网络的输入模拟向量为

$$\mathbf{X}_k = (x_1^k, x_2^k, \dots, x_n^k),$$

输出模拟向量为

$$\mathbf{Y}_k = (y_1^k, y_2^k, \dots, y_p^k), \quad k = 1, 2, \dots, m$$

连接权向量为

$$\mathbf{W}_{ij} = (\omega_{i1}, \omega_{i2}, \dots, \omega_{ip}), \quad i = 1, 2, \dots, n,$$

其中 m 为输入模式对数, n 为输入单元数, p 为输出




图 1 Madaline 网络结构图(x_i 为输入, w_{ij} 为连接权值, y_j 为输出)

Fig. 1 Structure of Madaline networks (x_i is input, w_{ij} is weight, y_j is output)

单元数, 则有 $y_i^k = \sum_{j=1}^n x_j^k w_{ji}$, 即

$$\begin{bmatrix} x_1^k & x_2^k & \dots & x_n^k \end{bmatrix} \begin{bmatrix} \omega_{11} & \omega_{12} & \dots & \omega_{1p} \\ \omega_{21} & \omega_{22} & \dots & \omega_{2p} \\ \omega_{31} & \omega_{32} & \dots & \omega_{3p} \\ \vdots & \vdots & \vdots & \vdots \\ \omega_{n1} & \omega_{n2} & \dots & \omega_{np} \end{bmatrix} = \begin{bmatrix} y_1^k & y_2^k & \dots & y_p^k \end{bmatrix}, \quad (6)$$

若令

$$\mathbf{x} = [x_1^k \quad x_2^k \quad \dots \quad x_n^k],$$

$$\mathbf{W} = \begin{bmatrix} \omega_{11} & \omega_{12} & \dots & \omega_{1p} \\ \omega_{21} & \omega_{22} & \dots & \omega_{2p} \\ \omega_{31} & \omega_{32} & \dots & \omega_{3p} \\ \vdots & \vdots & \vdots & \vdots \\ \omega_{n1} & \omega_{n2} & \dots & \omega_{np} \end{bmatrix},$$

$$\mathbf{y} = [y_1^k \quad y_2^k \quad \dots \quad y_p^k],$$

则有

$$\mathbf{x}\mathbf{W} = \mathbf{y}. \quad (7)$$

3.2 Madaline 模型学习算法——最小平方误差算法^[11]

Madaline 网络的学习过程是按使误差平方和最小化原则,即最小平方误差(Least mean square, LMS)算法,反复对连接权进行修正,使神经元的实际输出与期望输出的差为最小。

最小平方误差算法采用了误差最速下降准则,使用的误差测度函数为均方误差(Mean square error, MSE)。在用最速下降准则自适应训练神经网络时,系统的权向量可以从任意的初始值 w_0 开始,然后计算均方误差函数的梯度,权值依负梯度变化。不断重复这个过程,可使均方误差的平均误差不断减小,达到优化的目的。即有

$$W_{k+1} = W_k + \mu(-\nabla_k), \quad (8)$$

其中 W_k 为当前权值, W_{k+1} 为下一步权值, μ 为学习参量(训练参量), ∇_k 为均方误差曲面上对应于 $W = W_k$ 的梯度值。

实际上,为了便于实现,我们并不是使用样本的平均梯度,因为要计算所有样本的平均梯度是很费时的。我们采用瞬时梯度,因为它可以直接从单个样本数据求得。于是

设均方误差测度函数(误差平方和)为

$$E = \sum_k \left\{ \frac{1}{2} \left[\sum_j (d_j^k - \sum_i w_{ij} x_i^k)^2 \right] \right\}, \quad (9)$$

其中 d_j^k 为在 j 输出单元的期望输出;第 j 单元的实际输出为 $y_j = \sum_i w_{ij} x_i^k$ 。

定义瞬时梯度为

$$\nabla_k = \frac{\partial E_k}{\partial W_k} = -(d_k - W_k X_k) X_k = -\epsilon_k X_k, \quad (10)$$

代入(3)式,有

$$\begin{aligned} W_{k+1} &= W_k + \mu(d_k - W_k X_k) X_k, \\ \Delta W_k &= W_{k+1} - W_k = \mu \epsilon_k X_k. \end{aligned} \quad (11)$$

若要实现全局误差函数方向上的梯度下降,则 W_k 的变化应正比于负平均梯度,即

$$\Delta W_k = -\mu \frac{\partial E}{\partial W_k} = \sum_{k=1}^m \left(-\mu \frac{\partial E_k}{\partial W_k} \right). \quad (12)$$

当用(7)式来训练网络,为获得全局误差最小的最优权值,需要多次的迭代运算。

最小平方误差算法可描述为

$$W_{k+1} = W_k + \frac{a}{|X_k|^2} \epsilon_k X_k, \quad (13)$$

式中 ϵ_k 为当前误差, a 为学习步长, $|X_k|^2$ 为权值个数。

设理想输出为 d_k , 有

$$\epsilon_k = d_k - X_k^T W_k, \quad (14)$$

于是得到

$$\Delta W_k = W_{k+1} - W_k = \frac{a}{|X_k|^2} \epsilon_k X_k. \quad (15)$$

3.3 输出无关性

由 Madaline 网络结构可知,不管是在网络的学习过程中,还是在网络的预测过程中,某个通道的输出 y_i 与其他通道的输出是无关的。由(6)式知, $y_i = \sum_{j=1}^n w_{ij} x_j$, 即在权值矩阵中,与输出 y_i 有关的权值只是矩阵的第 i 列,而与其他列无关。这种输出无关性给我们训练网络和使用网络提供了很大的方便。

在网络的学习过程中,期望输出 y_i 只修正权值矩阵的第 i 列,不会影响矩阵的其他列。因此学习样本中期望输出的精度,也只影响权值矩阵中对应列的权值的精度。也就是说,如果在一批学习样本中,某个期望输出的精度比其他期望输出高,那么网络学习的结果,是该值对应权值的可靠性就高,用该网络处理数据,该输出值的精度也比其他输出值高。同样地,若学习样本中某个期望输出的精度相对较低,则这种较低的精度只影响该值对应的权值,而不会影响其他的权值。

同时,输出无关性为我们选择输出值的个数提供了方便。我们可以根据需要进行适当数目的输出值。当需要增加一个输出值时,只需对应在矩阵中增加一列,并且只需对新增列进行训练,其他列的训练结果仍然是有效的,因为对该列的训练不影响其他列。

输出无关性使 Madaline 网络在反演气溶胶消光系数时更具有可行性。

4 消光系数反演算法

4.1 Madaline 网络组成

利用 Madaline 网络反演气溶胶消光系数的基本思想是:首先提供足够数量的学习样本供网络训练,通过调整网络权值使得由输入计算出的网络输出尽可能的接近期望输出,通过训练,将网络的权值调整到合适的值,使得对所有的样本都能够得到期望输出,这时,网络的训练就结束了,就可以用该网络来反演气溶胶消光系数了。

Madaline 网络的学习样本由输入和期望输出两部分数据组成。网络的输入是激光雷达获得的原始数据。以我们实验使用的微脉冲激光雷达(MPL)为例,微脉冲激光雷达可以得到 30 km 的数据,数据量是 1000 组(距离分辨率是 30 m)。我们把这 1000 组数据作为网络的输入。

网络的期望输出是对应的气溶胶消光系数。为了使网络最终获得的消光系数精度较高,学习样本的精度应当满足高精度的要求,即学习样本中的期望输出应尽可能的准确,所以使用其他一些精度更高的仪器测出的消光系数作为网络的期望输出。根据能够得到的消光系数的范围和需要来确定输出数组的大小。在实验中,我们用多部激光雷达近地段的消光系数的平均值作为期望输出,由于我们所能得到的较高精度的消光系数的高度比较低,我们选择 12 km 以下的数据作为网络期望输出,共有 400

组数据。

因此 Madaline 网络的组成就是:由 1000 组原始数据作为输入,精确测定的 400 组气溶胶消光系数作为期望输出。

Madaline 网络的组成符合网络正常工作的基本要求,即输入数据和输出数据之间存在着一定的关系。事实上,雷达接收到的原始数据与消光系数之间的确存在着一定的关系,这种关系已经由雷达方程予以揭示。不过由于其中太多的假设使得两者的依赖关系变得不确定,而通过对神经网络进行有效的训练后,可得到正确表示各个通道之间关系的连接权值。训练完成后,便可利用原始信号来获得对应的消光系数。

4.2 反演算法^[12]

Madaline 网络按最小平方误差学习规则,通过提供的样本对网络进行训练。

网络输入向量

$$\mathbf{X}_k = (x_0^k, x_1^k, x_2^k, \dots, x_n^k),$$

x_n 为输入通道的模拟值,在我们的系统中为输入层上激光雷达的原始数据, $n = 1, 2, \dots, 1000$, 表示有 1000 个输入。 $k = 1, 2, \dots, m$, m 表示训练的样本总数。

期望输出

$$\mathbf{Y}_k = (y_1^k, y_2^k, y_3^k, \dots, y_p^k),$$

y_p 为输出通道的模拟值,即对应 12 km 距离上的消光系数, $p = 1, 2, \dots, 400$, 表示有 400 个输出。

连接权向量

$$\mathbf{W}_{ij} = (w_{i1}, w_{i2}, w_{i3}, \dots, w_{ip}),$$

$i = 1, 2, \dots, 1000$, $j = 1, 2, \dots, 400$ 。为输入层到输出层之间的连接权值。

按以下步骤对网络进行训练:

1) 初始化——给各连接权 W_{ij} 赋予 $[-1, 1]$ 区间内的随机值。

2) 任选一学习样本对提供给网络。

3) 计算网络输出值:

$$y_j^k = \sum_{i=1}^n w_{ij} \cdot x_i^k, j = 1, 2, \dots, p.$$

4) 计算网络各输出单元的期望输出 d_j^k 与实际输出 y_j^k 之间的误差:

$$\epsilon_j^k = d_j^k - y_j^k, j = 1, 2, \dots, p.$$

5) 进行连接权修正:

$$w_{ij}(N+1) = w_{ij}(N) + \Delta w_{ij}(N),$$

其中
$$\Delta w_{ij} = a \cdot \sum_{i=1}^n \epsilon_j^k \cdot x_i^k.$$

6) 取下一个学习样本对提供给网络,重复步骤 2) ~ 5), 直到所有学习样本都训练完毕(或误差 ϵ 变得足够小)为止。

5 实验结果与讨论

实验时,多部雷达同时测量,并且雷达之间的距离在 20 m 以内,可以认为在这个范围内所有雷达所测气溶胶的分布是一样的。把其中一部微脉冲激光雷达的原始数据作为输入,把所有雷达用传统方法反演的近地段消光系数平均值作为期望输出。某时刻的原始数据与对应时刻的消光系数作为一对学习样本,对网络进行训练。在实际应用中我们选择了不同数目的学习样本,其中包括了各种条件下的样本数据(如不同气象条件下的测量数据)对网络进行训练,最后分别得到了全连通网络的 $1000 \times 400 = 400000$ 个权值。

测试样本选择非学习样本。为了比较网络的性能,我们选择了多个测试样本对网络的推广能力进行测试。文中选择了两个测试样本的反演测试结果,这两个测试样本编号分别为 20050815000 和 20050817170。图 2 是编号为 20050815000 的测试样本分别在 8000、15000、20000 和 30000 个学习样本训练后的网络上反演的结果与期望输出的对比。图 3 是编号为 20050817170 的测试样本分别在 8000、15000、20000 和 30000 个学习样本训练后的网络上反演的结果与期望输出的对比。

我们以反演结果与期望输出之间的标准偏差度量两组数据的接近程度,则不同样本网络反演结果与期望输出之间的误差如表 1 所示。

表 1 反演结果与期望输出之间的误差

Table 1 Errors between the retrieved result and expected value

Sample No.	20050815000	20050817170
Network of 8000 samples	0.117643	0.127069
Network of 15000 samples	0.055701	0.056269
Network of 20000 samples	0.027194	0.026304
Network of 30000 samples	0.014155	0.014124

结果表明:

1) 用一批足够数量的学习样本对网络进行训练后,然后反演该雷达的不同信号时,不同信号所得结果与各自的期望输出的误差相差不大,表明数据处理精度只与训练过的网络有关,而与待处理信号无关。

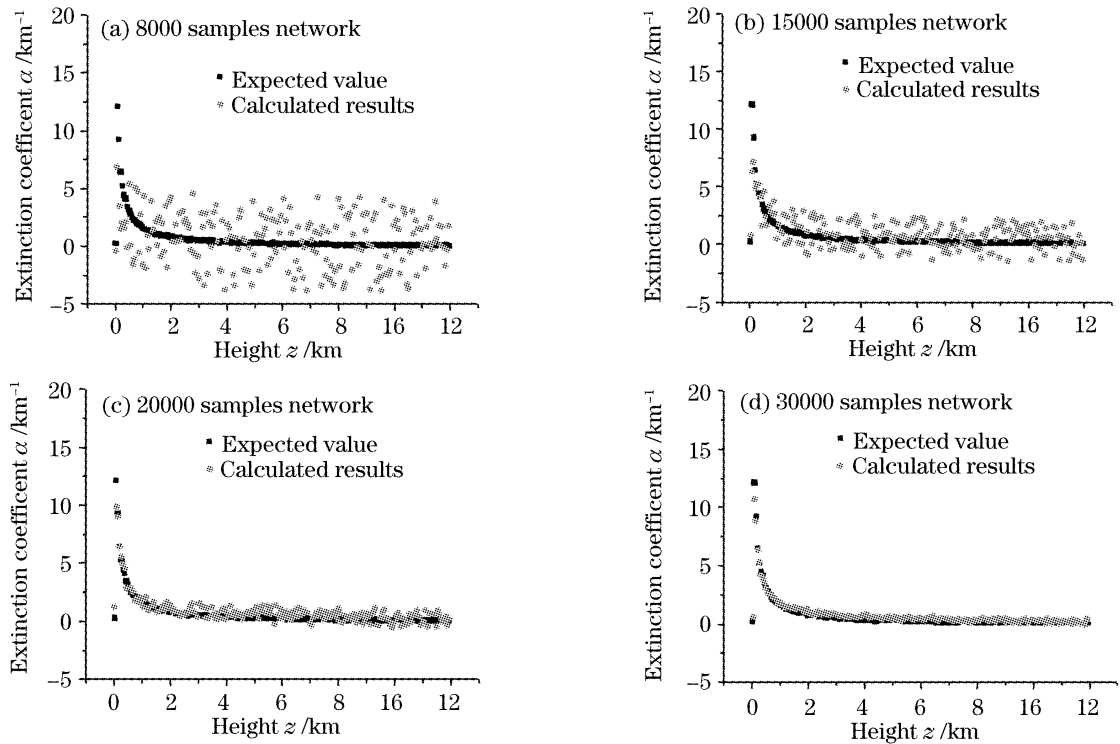


图 2 测试样本 20050815000 在不同数目学习样本网络上的反演结果对比

Fig. 2 Experiment results of No. 20050815000 test sample

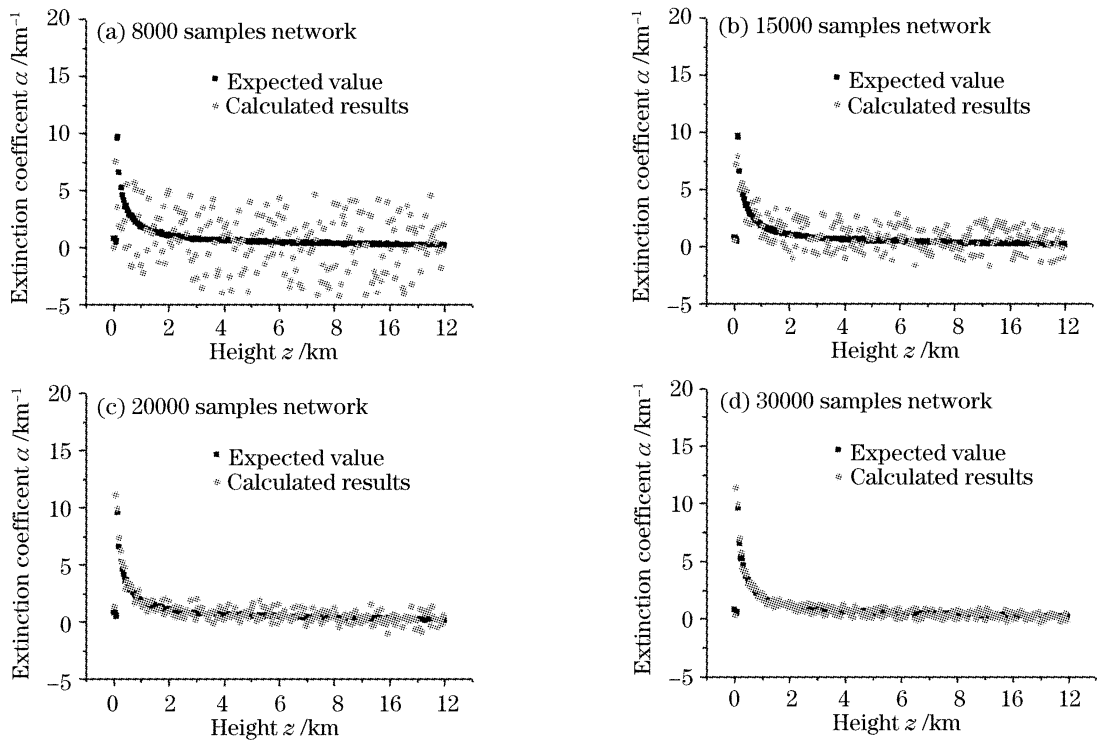


图 3 样本 20050817170 在不同数目训练样本网络上的反演结果对比

Fig. 3 Experiment results of No. 20050817170 test sample

2) 运用不同数目学习样本对网络进行训练, 所得网络对同一信号进行反演, 样本数多的网络反演结果更接近期望输出。因此, 要根据所需精度选择学习样本数目, 对网络进行训练。

图 4 是上述两测试样本信号用传统反演方法获得的消光系数值与期望输出的对比。测试样本

20050815000 用传统方法反演的结果与期望输出的误差为 0.022211, 测试样本 20050817170 的误差为 0.044564, 两者皆大于学习样本数为 30000 的神经网络反演结果的误差。实验表明, 用高精度的样本训练过的 Madaline 网络反演消光系数, 明显优于传统的反演方法。

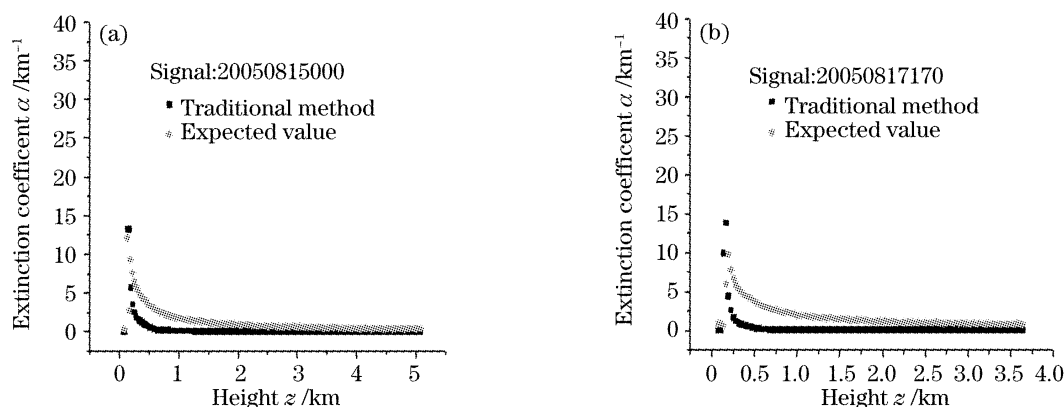


图 4 传统方法反演结果与期望输出的比较

Fig. 4 Comparison between expected value and result calculated by traditional method

6 结 论

利用 Madaline 网络反演气溶胶消光系数,避免了传统方法因为诸多假设带来的计算误差。如果训练样本的输出精度达到理想的精度,则训练过的网络就可以逼近这样的精度,其结果明显优于传统方法。

训练样本中的消光系数可以通过其他更精确的仪器测量获得,高空消光系数可以通过探空气球或机载设备获得,总之,高精度的消光系数是可以得到的。网络的训练非常灵活,网络在训练过程中,样本数目可以逐步增加,前一次训练的结果作为下一次训练的初始值,这样可以大大减少训练的时间。由于网络的输出无关性,我们不需要一次对所有的网络权值都进行训练,可以对不同高度的网络权值分开进行训练,只有在获得某个高度足够精确的消光系数时才对该高度的网络权值进行训练,保证训练样本达到所需的精度,从而使网络的精度得到保证。如果获得精度更高的消光系数,还可以对训练过的网络重新进行训练,使其达到更高的精度。上述训练方法都可以通过软件非常方便的加以实现,同时,只要改变训练样本,相同的软件不作任何修改就可以适用于其它雷达。因此,利用 Madaline 网络反演气溶胶消光系数,具有一定的实用价值。

参 考 文 献

- 1 James D. Spinhirne. Micro pulse lidar[J]. *IEEE Trans Remote Sensing*, 1993, **31**(1): 48~54
- 2 Hu Shunxing, Hu Huanling, Wu Yonghua *et al.*. L625 differential absorption lidar system for tropospheric ozone measurements[J]. *Acta Optica Sinica*, 2004, **24**(5): 597~601 (in Chinese)
胡顺星,胡欢陵,吴永华等. L625 差分吸收激光雷达探测对流层臭氧[J]. *光学学报*, 2004, **24**(5): 597~601
- 3 Qiu Jinhuan, Zhen Siping, Huang Qirong *et al.*. Lidar measurements of cloud and aerosol in the upper troposphere in Beijing[J]. *Chin. J. Atmospheric Science*, 2003, **27**(1): 1~7

(in Chinese)

邱金桓,郑斯平,黄其荣等. 北京地区对流层中上部云和气溶胶的激光雷达探测[J]. *大气科学*, 2003, **27**(1): 1~7

- 4 Wu Yonghua, Hu Huanling, Hu Shunxing *et al.*. Rayleigh-Raman scattering lidar for atmospheric temperature profiles measurements [J]. *Chin. J. Lasers*, 2004, **31**(7): 851~856 (in Chinese)
吴永华,胡欢陵,胡顺星等. 瑞利-拉曼散射激光雷达探测大气温度分布[J]. *中国激光*, 2004, **31**(7): 851~856
- 5 Tao Zongming, Zhang Yinchao, Cen Gang *et al.*. Estimating method of detecting minimum pollutant gas concentration by lidar[J]. *Acta Optica Sinica*, 2004, **24**(5): 602~604 (in Chinese)
陶宗明,张寅超,岑岗等. 激光雷达探测污染气体最小浓度的估算方法[J]. *光学学报*, 2004, **24**(5): 602~604
- 6 Yonghua Wu, Huanling Hu, Shunxing Hu *et al.*. Raman lidar measurements of tropospheric water vapor over Hefei[J]. *Chin. Opt. Lett.*, 2003, **1**(7): 373~376
- 7 Zhou Jun, Yue Guming, Qi Fudi *et al.*. Optical properties of aerosol derived from Lidar measurements[J]. *Chin. J. Quant. Electron.*, 1998, **15**(2): 140~148 (in Chinese)
周军,岳古明,戚福第等. 大气气溶胶光学特性激光雷达探测[J]. *量子电子学报*, 1998, **15**(2): 140~148
- 8 Hu Huanling, Wu Yonghua, Xie Chenbo *et al.*. Aerosol pollutant boundary layer measured by Lidar at Beijing [J]. *Research of Environmental Sciences*, 2004, **17**(1): 59~73 (in Chinese)
胡欢陵,吴永华,谢晨波等. 北京地区夏冬季颗粒物污染边界层的激光雷达观测[J]. *环境科学研究*, 2004, **17**(1): 59~73
- 9 Wang Wei. *Principle of Artificial Neural Network: Introduction and Application* [M]. Beijing: Beijing University of Aeronautics & Astronautics Publishing House, 1995. 44~50 (in Chinese)
王伟. *人工神经网络原理: 入门与应用* [M]. 北京: 北京航空航天大学出版社, 1995. 44~50
- 10 Li Hongbin, Liu Wenqing, Zhang Yujun *et al.*. A method of characteristic LIF spectral signatures separation based on radial basis function networks[J]. *Acta Physica Sinica*, 2005, **54**(9): 4451~4457 (in Chinese)
李宏斌,刘文清,张玉钧等. 基于径向基函数网络的激光诱导荧光特征光谱分离算法[J]. *物理学报*, 2005, **54**(9): 4451~4457
- 11 Yang Jianguang. *Artificial Neural Networks Tutorial* [M]. Zhejiang: Zhejiang University Publishing House, 2001. 37~40 (in Chinese)
杨建刚. *人工神经网络实用教程* [M]. 杭州: 浙江大学出版社, 2001. 37~40
- 12 Qi Feng, Liu Wenqing, Zhou Bin *et al.*. Improving DOAS system measurement precision with artificial neural network method [J]. *Acta Optica Sinica*, 2002, **22**(11): 1345~1349 (in Chinese)
齐锋,刘文清,周斌等. 利用人工神经网络方法提高差分光学吸收光谱系统测量精度研究[J]. *光学学报*, 2002, **22**(11): 1345~1349