

激光与光电子学进展

基于反向传播神经网络估算大气光学湍流廓线

毕翠翠^{1,2,3}, 青春^{1,3}, 钱仙妹^{1,3*}, 孙刚^{1,3}, 刘庆^{1,3}, 朱文越^{1,3}, 许满满^{1,2,3}, 韩亚娟^{1,2,3}, 郭一鸣^{1,2,3}

¹中国科学院合肥物质科学研究院安徽光学精密机械研究所中国科学院大气光学重点实验室, 安徽 合肥 230031;

²中国科学技术大学研究生院科学岛分院, 安徽 合肥 230026;

³先进激光技术安徽省实验室, 安徽 合肥 230037

摘要 大气光学湍流是与光电工程系统设计、应用密切相关的基本参数。通过仪器实地测量大气光学湍流廓线时会受到人力、物力、财力等多种条件的限制,因此依据常规气象参数估算大气光学湍流强度具有十分重要的意义。提出一种结合遗传算法的反向传播(GA-BP)神经网络。首先,基于 Tatarski 大气光学湍流参数化方案,利用 HMNSP99 外尺度模式估算了大气光学湍流廓线;其次,尝试基于实测数据训练 BP 神经网络,并结合遗传算法估算大气光学湍流廓线。将两种方法估算的大气光学湍流廓线与实测的廓线进行对比,结果表明:GA-BP 神经网络模式估算值与实测值的均方根误差(RMSE)比 HMNSP99 模式的 RMSE 小,表明利用 GA-BP 神经网络模式估算大气光学湍流廓线是一种可行的方法。

关键词 大气光学; 光学湍流廓线; Tatarski 模式; 反向传播神经网络; 探空测量

中图分类号 P427

文献标志码 A

doi: 10.3788/LOP202158.2101001

Estimation of Atmospheric Optical Turbulence Profile Based on Back Propagation Neural Network

Bi Cuicui^{1,2,3}, Qing Chun^{1,3}, Qian Xianmei^{1,3*}, Sun Gang^{1,3}, Liu Qing^{1,3}, Zhu Wenyue^{1,3},
Xu Manman^{1,2,3}, Han Yajuan^{1,2,3}, Guo Yiming^{1,2,3}

¹Key Laboratory of Atmospheric Optics, Anhui Institute of Optics and Fine Mechanics, Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei, Anhui 230031, China;

²Science Island Branch of Graduate School, University of Science and Technology of China, Hefei, Anhui 230026, China;

³Advanced Laser Technology Laboratory of Anhui Province, Hefei, Anhui 230037, China

Abstract Atmospheric optical turbulence is the fundamental parameter closely related to the design and application of optoelectronic systems. The field measurements of atmospheric optical turbulence profiles by instruments are limited by labor, materials, financial resources, and other conditions. Therefore, it is of great significance to estimate the intensity of atmospheric optical turbulence according to the conventional meteorological parameters. A back propagation combined with genetic algorithm (GA-BP) neural network is proposed. First, based on Tatarski atmospheric optical turbulence parameterization scheme, the HMNSP99 outer-scale model is used to estimate the optical turbulence profiles; second, attempting to construct BP artificial neural network combined with genetic algorithm, which are trained by measured data to predict atmospheric optical turbulence profiles. The atmospheric optical turbulence profiles estimated by the two methods are compared with the measured profiles. The results show

收稿日期: 2021-02-21; 修回日期: 2021-03-01; 录用日期: 2021-03-08

基金项目: 中国科学院科技创新重点实验室基金(CXJJ-19S028)

通信作者: *qianxianmei@aiofm.ac.cn

that the root mean square error (RMSE) between the estimated values of GA-BP neural network and measured values is smaller than that of HMNSP99 model, which proves that it is a feasible method to use GA-BP artificial neural network model to estimate the optical turbulence profiles.

Key words atmospheric optics; optical turbulence profile; Tatarski model; back propagation neural network; sounding measurement

OCIS codes 010.1290; 010.1330

1 引言

光波在大气中传输时,受到大气湍流的影响导致折射率随机起伏,从而产生光束漂移、光强闪烁和像点抖动等一系列湍流效应,严重影响了光学系统的正常使用^[1]。大气光学湍流强度通常用折射率结构常数(C_n^2)表征,该参数是评估大气湍流对激光大气传输影响的重要参数。目前有多种测量 C_n^2 等大气湍流参数的仪器,例如湍流气象探空仪^[2]、Scintillation Detection and Ranging (SCIDAR)^[3]、Multi-Aperture Scintillation Sensor (MASS)^[4]、闪烁仪^[5]等,但获取高空光学湍流需要耗费大量的人力、物力,并且受到测量手段的限制难以实现大范围的实时测量。因此,建立光学湍流参数化模式,基于便于实测的常规气象参数估算大气光学湍流是解决这一问题行之有效的方法。

目前国内外对高空大气光学湍流参数化模式研究开展了大量的工作。Tatarski^[6]提出可根据常规气象参数估算大气光学湍流,即 Tatarski 模式。Hufnagel 等^[7]基于探空数据归纳出高空大气湍流参数模式,但此模式只考虑了风速这个气象参数对湍流的影响,而且该模式是中纬度模型,在使用范围上有所限制。Warnock 等^[8]开发了美国国家海洋和大气管理局(NOAA)模式,该模式整合了风切变的精细结构,但此模式较为复杂,效果一般。此外,Abahamid 等^[9]基于 Tatarski 光学湍流参数化模式,使用来自不同地点的湍流探空数据研究了边界层和自由大气中的大气湍流特性。Hufnagel-Vally 5/7 (HV 5/7)模式是 Hufnagel 模式中最为著名并广泛应用的模式,吴晓庆等^[10]根据在兴隆获得的探空数据,采用 HV 5/7 模式拟合得到了兴隆夜间 C_n^2 廓线公式。翁宁泉等^[11]采用 HV 5/7 模式,拟合出了香河、昆明和合肥的 C_n^2 廓线公式。孙刚等^[12]通过 NOAA 模式在合肥、北京地区得到大气湍流高度分布廓线。青春等^[13]依据 Tatarski 大气光学湍流参数化方案,利用数值天气预报模式(WRF)模拟了高美古、茂名、乌鲁木齐等典型地区高空大气光学湍流

廓线。蔡俊等^[14]基于 Tatarski 湍流参数化方案,利用探空数据,对内陆(合肥)、海陆交界处(茂名)和远海海洋这 3 个不同环境下的大气光学湍流廓线进行了估算。尽管各种参数化模式都有一定的进步和优点,但是各自的缺点和局限也是明显的,有必要进一步开展估算大气光学湍流廓线的模式研究。

近年来,人工神经网络在图像处理 and 模式分类等方面得到了广泛应用^[15-16]。与传统的理论估算方法相比,人工神经网络具有较强的非线性映射能力,可根据数据进行自适应学习,不依赖先验公式。Wang 等^[17]使用神经网络在 Mauna Loa Observatory 对 C_n^2 进行了为期一个月的估算,利用温度、压强、位温梯度、风切变等常规气象参数进行估算,初步证实了这种估算 C_n^2 方法的可行性。随后,诸多学者通过人工神经网络方法估算了近海面、冰雪面和高原地区近地面的光学湍流强度^[18-20],进一步说明新的 C_n^2 量化方法的可行性。人工神经网络方法不仅能避开 Monin-Obukhov 相似理论中复杂的物理计算过程,还展示了在不同稳定性条件下估算近地层 C_n^2 的潜力。然而,基于人工神经网络模式估算高空大气光学湍流廓线的研究鲜有报道。本文依据 2017 年 11 月—12 月期间在三亚地区开展的高分辨率湍流探空数据,提出一种结合遗传算法的反向传播(GA-BP)神经网络算法模式估算 C_n^2 廓线。基于 Tatarski 参数化模式以及 GA-BP 模式获得 C_n^2 廓线,同时将两种模式估算的 C_n^2 廓线与实测 C_n^2 廓线进行对比,并使用统计值定量描述两种模式估算结果的准确度。

2 测量原理及实验概况

2.1 C_n^2 测量原理

对于可见光和近红外波段,折射率起伏主要是温度变化引起的。根据局部地区均匀各向同性湍流理论,温度结构常数 C_T^2 通常通过微温传感器上一对微温探头测量空间两点(距离为 r)的温差平方平均得到,温度结构函数 D_T 与温度结构常数 C_T^2 满足以下关系:

$$D_T(\mathbf{r}) = \langle [T(\mathbf{x}) - T(\mathbf{r} + \mathbf{x})]^2 \rangle = C_T^2 r^{2/3}, \\ l_0 \ll |\mathbf{r}| \ll L_0, \quad (1)$$

式中： \mathbf{x} 和 \mathbf{r} 表示位置矢量，单位是 m； $T(\mathbf{x})$ 和 $T(\mathbf{r} + \mathbf{x})$ 分别是空间距离 \mathbf{r} 的温度，单位是 K； $\langle \cdot \rangle$ 表示系综平均； L_0 和 l_0 分别表示湍流外尺度和内尺度，单位是 m。

因此可直接由温度结构常数 C_T^2 得到 C_n^2 ，表达式为

$$C_n^2 = \left(79 \times 10^{-6} \frac{P}{T^2} \right)^2 C_T^2, \quad (2)$$

式中： P 为气压，单位是 hPa；折射率结构常数 C_n^2 的单位为 $\text{m}^{-2/3}$ 。本实验中，微温传感器频率响应

范围为 0.05~30 Hz，最小温度扰动偏差小于 0.002 K^[21-24]。微温传感器测量装置如图 1 所示，一对相距 1 m、直径约为 10 μm 的铂丝探针组成惠斯通电桥的两臂。其中，铂丝作为微温探头，一对微温探头测量不同空间位置两点温差，并将其转化为电阻差，再经过惠斯通电桥将电阻差转化为电压差。传感器输出电压与两测量点温差变化成正比，经过平方平均由(1)式计算得到温度结构常数 C_T^2 ，再由(2)式计算得出 C_n^2 。




图 1 微温传感器的测量系统。(a)微温传感器;(b)铂丝探针

Fig. 1 Micro-thermometer measurement system. (a) Micro-thermometer; (b) platinum wire probe

2.2 实验概况

实验地点三亚(109.56° E, 18.23° N, 海拔高度为 364 m)地处海南岛最南端,北靠高山,南临南海。三亚属热带海洋性季风气候区,年平均气温 25.7 °C。2017 年 11 月—12 月期间,湍流探空仪在三亚地区开展了探空实验,获取了温度、风速、压强等常规气象参数和 C_n^2 廓线。其中,温度和风速测量精度分别为 0.3 K 和 0.2 $\text{m}\cdot\text{s}^{-1}$,而微温传感器测量的海拔范围是从地表到海拔 30 km。湍流气象探空

仪测量实验如图 2 所示。研究中,除了各种因素(例如天气和强风造成的损坏)导致探空仪测量异常外,取 11 月—12 月期间 38 份有效探空数据进行研究,表 1 列出了所有数据具体的探空记录。值得指出的是,GA-BP 神经网络训练时,前 32 个探空记录数据作为训练样本,其余 6 个数据作为预测样本。

3 估算模式

3.1 Tatarski 模式

大气光学湍流的参数化模式将标准的探空气象参数转化为 C_n^2 廓线。根据 Kolmogorov 的局部地区均匀各向同性理论,Tatarski 提出了 C_n^2 与常规气象参数的关系:

$$C_n^2 = \alpha L_0^{4/3} M^2, \quad (3)$$

$$M = - \frac{79 \times 10^{-6} P}{T^2} \frac{\partial \theta}{\partial z}, \quad (4)$$

$$\theta = T \left(\frac{1000}{P} \right)^{0.286}, \quad (5)$$

式中： α 为常数，一般取为 2.8； θ 为位温，单位为 K； M 是位势折射率梯度。在忽略湿度影响的情况下， C_n^2 可由外尺度 L_0 以及常规气象参数计算得到，是利用常规气象参数估算 C_n^2 廓线的理论依据。

HMNSP99 外尺度模式^[25]已被用来估算湍流廓线,该模式将高空风切变和温度梯度与估算光学湍



图 2 湍流气象探空仪测量实验

Fig. 2 Measurement experiment of turbulence meteorological radiosonde

表 1 湍流探空仪探空记录
Table 1 Sounding records of turbulence radiosonde

No.	Date	Launching time	Termination time	Termination height /m	No.	Date	Launching time	Termination time	Termination height /m
1#	2017-11-15	18:09	19:40	32510	20#	2017-12-07	07:40	09:16	32480
2#	2017-11-17	18:06	19:36	32300	21#	2017-12-07	18:26	19:49	31350
3#	2017-11-19	07:42	09:12	32300	22#	2017-12-08	18:53	20:22	32020
4#	2017-11-21	18:03	19:29	28630	23#	2017-12-09	07:42	09:00	31970
5#	2017-11-22	07:47	09:20	32560	24#	2017-12-09	18:55	20:26	32110
6#	2017-11-22	18:50	20:22	32630	25#	2017-12-10	07:47	09:18	32110
7#	2017-11-24	07:39	09:04	32480	26#	2017-12-10	19:00	20:39	31820
8#	2017-11-25	07:45	09:19	32670	27#	2017-12-11	07:43	09:21	32910
9#	2017-11-25	18:47	20:15	32080	28#	2017-12-11	19:00	20:23	29740
10#	2017-11-27	07:37	09:17	31350	29#	2017-12-12	07:40	09:00	31560
11#	2017-11-27	18:56	20:32	33270	30#	2017-12-12	18:59	20:32	32960
12#	2017-11-28	07:50	09:10	31210	31#	2017-12-13	18:59	20:21	32100
13#	2017-11-28	18:55	20:27	33060	32#	2017-12-15	19:01	20:34	32700
14#	2017-11-29	07:39	09:07	32190	33#	2017-12-18	19:00	20:32	32670
15#	2017-11-29	18:53	20:20	30600	34#	2017-12-19	07:35	08:58	28400
16#	2017-12-02	08:07	09:39	32100	35#	2017-12-19	19:01	20:26	31690
17#	2017-12-04	07:44	09:28	33090	36#	2017-12-20	19:00	20:25	33250
18#	2017-12-04	18:57	20:29	30920	37#	2017-12-24	19:00	20:36	32830
19#	2017-12-05	07:41	09:13	32260	38#	2017-12-27	07:49	09:06	30140

流联系起来,具体表达式为

$$L_0^{4/3} = \begin{cases} 0.1^{4/3} \times 10^{0.362+16.728S-192.347 \frac{dT}{dz}}, & \text{Troposphere} \\ 0.1^{4/3} \times 10^{0.757+13.819S-57.784 \frac{dT}{dz}}, & \text{Stratosphere} \end{cases} \quad (6)$$

$$S = \sqrt{\left(\frac{\partial u}{\partial z}\right)^2 + \left(\frac{\partial v}{\partial z}\right)^2} \quad (7)$$

式中:S为风切变; u 、 v 分别为纬向风速和径向风速,单位是 $\text{m}\cdot\text{s}^{-1}$ 。

3.2 GA-BP神经网络模式

人工神经网络在非线性函数的计算方面具有较高的性能表现,能够从输入与输出数据中学习并获取有用信息而不需要建立精确的数学模型,从而能处理那些难以用规律或公式描述及机理不是十分明确的问题,表现出了极大的灵活性和适应性。反向传播神经网络是人工神经网络的一种重要实现方法,是一种多层前馈神经网络,该网络的主要特点是信号正向传播,误差反向传播^[26]。正向传播中,把一系列与被预报值关系密切的气象参数通过输入层输出,经过连接权重加权后作用于隐含层,最终传递到输出层。对输出与期望输出进行比较,并将二者间的误差送回。在学习过程中,误差计算

结果的传递方向是逐层反向传播的,根据该误差计算值依次调整各连接权重和阈值进行迭代训练,如此循环直到达到预先设定的最小误差或者训练次数^[27]。但初始化权值和阈值的随机性会使得结果陷入局部极值,且BP神经网络训练收敛速度慢,容易陷入局部极小值的情况且鲁棒性差,本实验组使用遗传算法对BP网络的初始化权值和阈值进行优化,以优化后的权值和阈值作为BP网络的初始化权值和阈值,再对数据进行训练。

大气湍流是大气随机运动形成的,湍流强度由于季节、天气等因素影响具有显著差异。国内外对大气光学湍流模式也进行了大量的研究,但无论哪种模式都带有经验性质,存在局限性。本实验组利用神经网络较强的非线性拟合能力,建立了常规气象参数与 C_n^2 之间的映射关系,GA-BP神经网络的拓扑结构如图3所示。

x_1, x_2, \dots, x_n 是 GA-BP 神经网络的输入值, y_1, y_2, \dots, y_n 是 GA-BP 神经网络的预测值。从拓扑结构图可以看到,GA-BP神经网络可看成一个非线性函数,网络输入值和预测值分别为该函数的自变量和因变量。建模时,将高度、压强、温度、风速、风

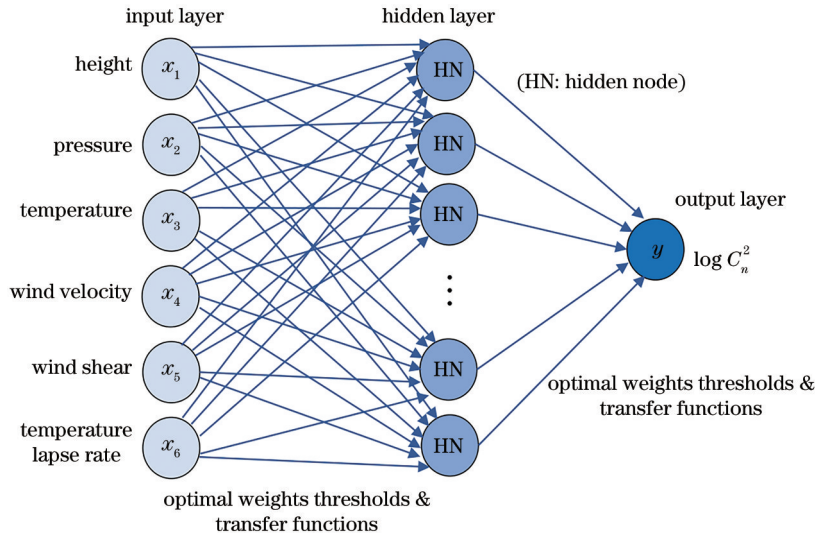


图 3 GA-BP神经网络拓扑结构图

Fig. 3 Topological structure diagram of GA-BP neural network

切变、温度梯度^[13]这 6 个与光学湍流有密切关系的物理量作为神经网络的输入层,大气光学湍流强度作为输出层,输出参量是 $\log C_n^2$ 。由(2)~(7)式可知,压强、温度、风速、风切变、温度梯度是计算 C_n^2 的直接或间接参数;高度参数的选择突出了大气光学湍流在高空变化的特征。实验证明,高度、压强、温度、风速、风切变、温度梯度参数可作为 GA-BP 神经网络的输入因子。

给定神经网络的输入因子与输出参数后,隐含层神经元个数 l 取决于输入和输出参量之间的非线性映射程度,隐含层神经元个数过少会产生欠拟合情况,神经元过多会产生过拟合问题,从而降低预测精度。目前,隐含层神经元个数还没有统一的计算方法,本实验中结合遗传算法和交叉验证方法^[28]来确定。交叉验证方法随机将数据分为 3 部分,训练集(60%),验证集(20%)和测试集(20%)。其中训练集用来训

练模型,验证集用来选择隐含层神经元个数,测试集用来评估模型的预测能力。对神经元个数不同的隐含层,采用平均绝对误差(M_{AE})和平均相对误差(M_{RE})表征 C_n^2 估算值与测量值的误差,表达式为

$$M_{AE} = \frac{1}{N} \sum_{i=1}^N |Y_i - X_i|, \quad (8)$$

$$M_{RE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - X_i}{X_i} \right| \times 100\%, \quad (9)$$

式中: X_i 和 Y_i 分别为探空实测值和估算值; i 为数据集的样本序号; N 为 (X_i, Y_i) 数据的个数。

当隐含层神经元个数不同时,交叉验证结果如图 4 所示。从图中可以看出,当神经元个数为 32 时,训练集、验证集估算结果的 M_{AE} 和 M_{RE} 差别较小,因此隐含层神经元个数选择为 32。依据遗传算法和交叉验证过程,确定 GA-BP 神经网络结构为 6-32-1,即输入层是 6 个输入因子,隐含层为一层且包含 32 个神经

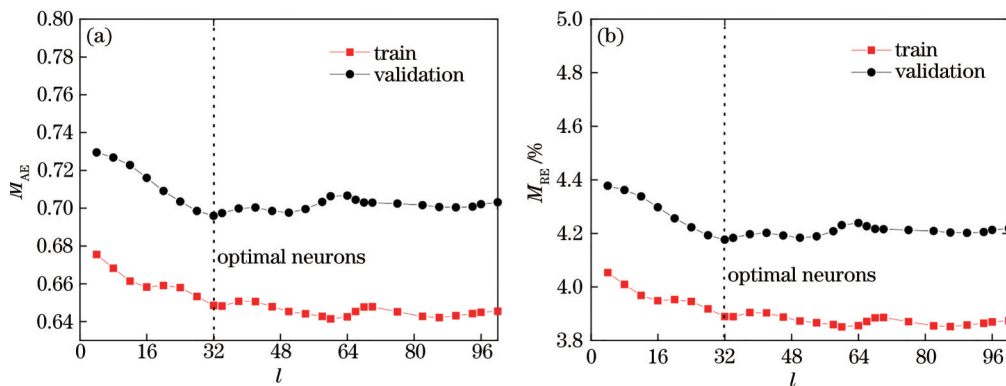


图 4 隐含层神经元个数不同时训练集和验证集误差。(a) M_{AE} ; (b) M_{RE}

Fig. 4 Errors of training set and validation set for different number of neurons in hidden layer. (a) M_{AE} ; (b) M_{RE}

元,输出一个参量。而测试集用来评估 GA-BP 神经网络模型的性能,即测试集 C_n^2 估算值与测量值的 M_{AE} 和 M_{RE} 分别为 0.712 和 4.14%。

图 5 为 GA-BP 神经网络的算法流程图。值得注意的是进行网络建模之前,要消除不同单位数据对网络训练的干扰,需要对模型中所有因子进行归

一化处理^[18],表达式为

$$x = \frac{2(X - X_{\min})}{(X_{\max} - X_{\min})} - 1, \quad (10)$$

式中 x 为归一化后的参数值, $x \in [-1, 1]$; X 为修正前的参数值, X_{\max} 和 X_{\min} 分别为对应参数因子的最大值和最小值。

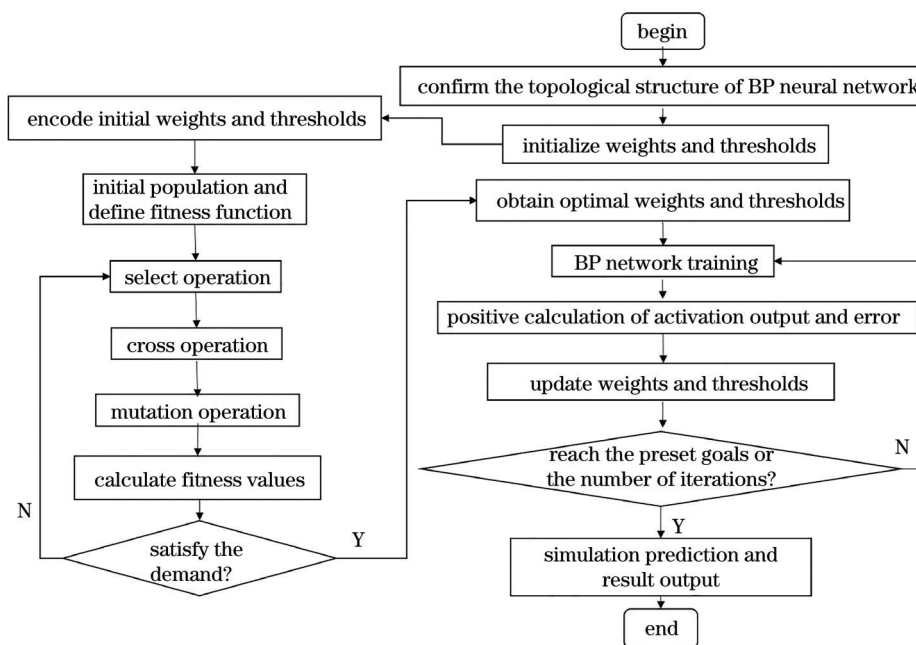


图 5 GA-BP 神经网络算法流程图

Fig. 5 Flow chart of GA-BP neural network algorithm

采用遗传算法优化 BP 神经网络,初始化权值和阈值,基本步骤^[29]如下。

1) 编码和初始种群的产生。将随机权值和阈值表示成遗传空间中染色体数据,进行编码。随机产生 M' 个染色体,其中每个数据称为一个个体,构成初始种群。

2) 适应度评估。计算个体的适应度,此处定义为估算值与实测值的平均绝对误差。

3) 选择、交叉和变异。依据适应度从当前群体中选择优良个体进入下一代;通过交叉产生新个体,组合父辈的特征;变异随机改变染色体基因的值,为新个体产生提供机会。

根据网络机理确定 GA-BP 神经网络模型等设置,其中训练网络采用 Resilient Backpropagation (RPROP) 算法^[30]。设置种群大小为 50,最大进化代数 100,交叉概率和变异概率分别为 0.6 和 0.08。

图 6 为遗传算法优化神经网络初始权值和阈值的训练过程。随着迭代次数的增加,最佳适应度值

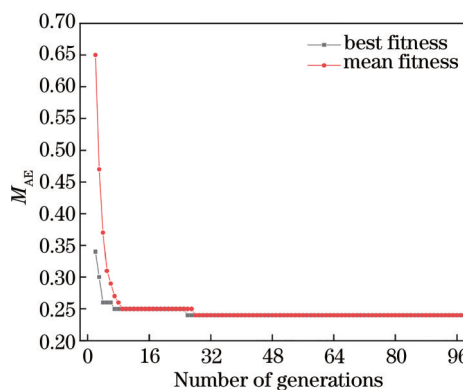


图 6 GA-BP 神经网络算法训练过程

和平均适应度值逐渐趋于稳定,即 C_n^2 估算值与测量值 M_{AE} 减小并达到稳定值,在 27 代以后基本保持不变。

4 结 果

图 7 为不同时间三亚地区湍流廓线探空测量实测值及对应的 HMNSP99 模式和 GA-BP 模式的估

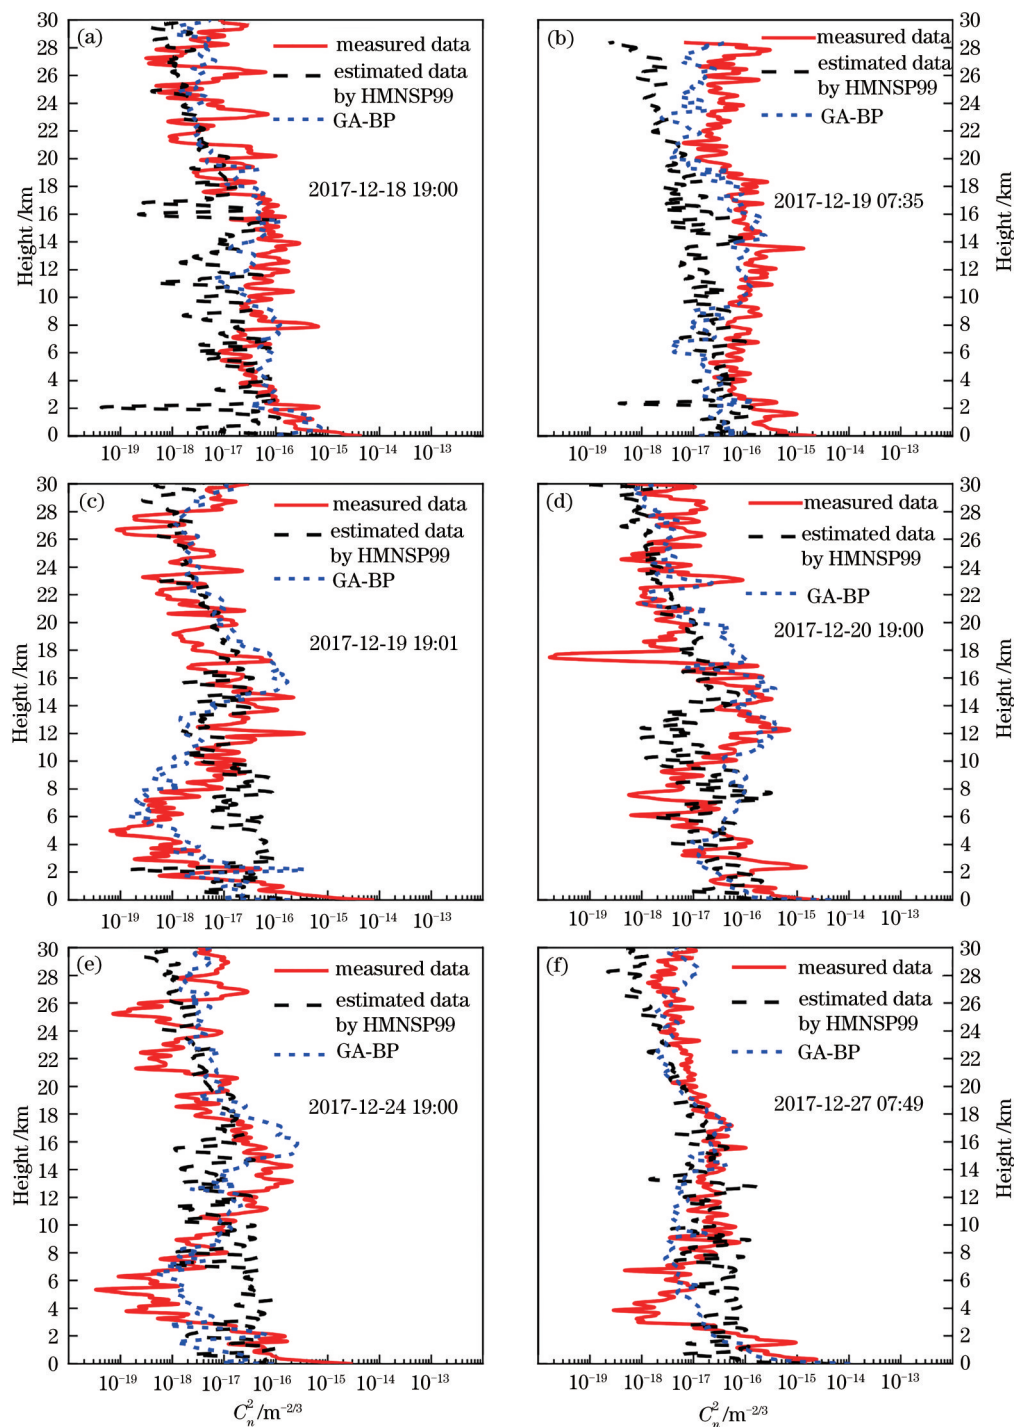


图 7 湍流廓线实测值和估算值

Fig. 7 Measured and estimated values for turbulence profile

算值。从图中可以看出：实测廓线、HMNSP99模式和GA-BP模式估算的湍流廓线具有相似分布特征：近地面层的湍流通常最强， C_n^2 随着高度增加急剧下降；然后在对流层中均出现强湍流层，尤其在对流层顶(大约17 km)附近，均出现不同强度的强湍流层；此后在平流层中，湍流强度随高度增加逐渐减小。图7中估算的 C_n^2 廓线和测量的 C_n^2 廓线在

变化趋势和湍流强度量级上较为一致。当然也存在部分时刻某些高度估算结果与实测廓线存在偏差的情况。总体而言，两种估算方法均能基本准确估算 C_n^2 廓线。

为了衡量模式估算的准确性，采用平均偏差(BIAS)、均方根误差(RMSE)统计方法^[31]定量统计分析探空仪实测值和估算值之间的相关性，并以此

来评估 GA-BP 模式和 HMNSP99 模式的估算准确度。它们的表达式分别为

$$S_{\text{BIAS}} = \sum_{i=1}^N \frac{Y_i - X_i}{N}, \quad (11)$$

$$E_{\text{RMSE}} = \sqrt{\sum_{i=1}^N \frac{(Y_i - X_i)^2}{N}}. \quad (12)$$

根据平均偏差和均方根误差可得到 σ , 表达式为

$$\sigma = \sqrt{E_{\text{RMSE}}^2 - S_{\text{BIAS}}^2}. \quad (13)$$

σ 代表的是不受平均偏差影响的固有不确定性, 并且提供有关系统和统计不确定性的基本信息。

两种方法估算的廓线与实测廓线的统计差异如图 8 所示。从图中可以看出, HMNSP99 模式和 GA-BP 模式的 BIAS 值小于 $1 \text{ m}^{-2/3}$, RMSE 值小于 $1.3 \text{ m}^{-2/3}$, σ 值小于 $1 \text{ m}^{-2/3}$ 。同时, GA-BP 模

式统计得到的 RMSE 和 σ 值都小于 HMNSP99 模式的结果。从图 8(d) 中可以发现: 在边界层区域, HMNSP99 模式估算的湍流强度较弱; 在边界层以上到对流层顶附近区域, GA-BP 模式估算的 C_n^2 廓线更接近于实测的 C_n^2 廓线; 而在对流层顶以上区域, 两种模式估算的 C_n^2 廓线与实测的 C_n^2 廓线基本一致。值得注意的是, 在对流层顶附近和低平流层出现强湍流层, 这些可能是因为强对流天气、激流、冷暖空气交汇、重力波等扰动源发生温度分层和风速剪切等不稳定现象从而发展成湍流^[32]。此外, 从图 8(d) 中可以看出, GA-BP 模式估算的 C_n^2 廓线比 HMNSP99 模式估算的 C_n^2 廓线更接近于实测廓线, 进一步表明 GA-BP 模式估算结果的准确度更好。因此, GA-BP 神经网络为估算高空大气光学湍流廓线提供了一种新的方法。

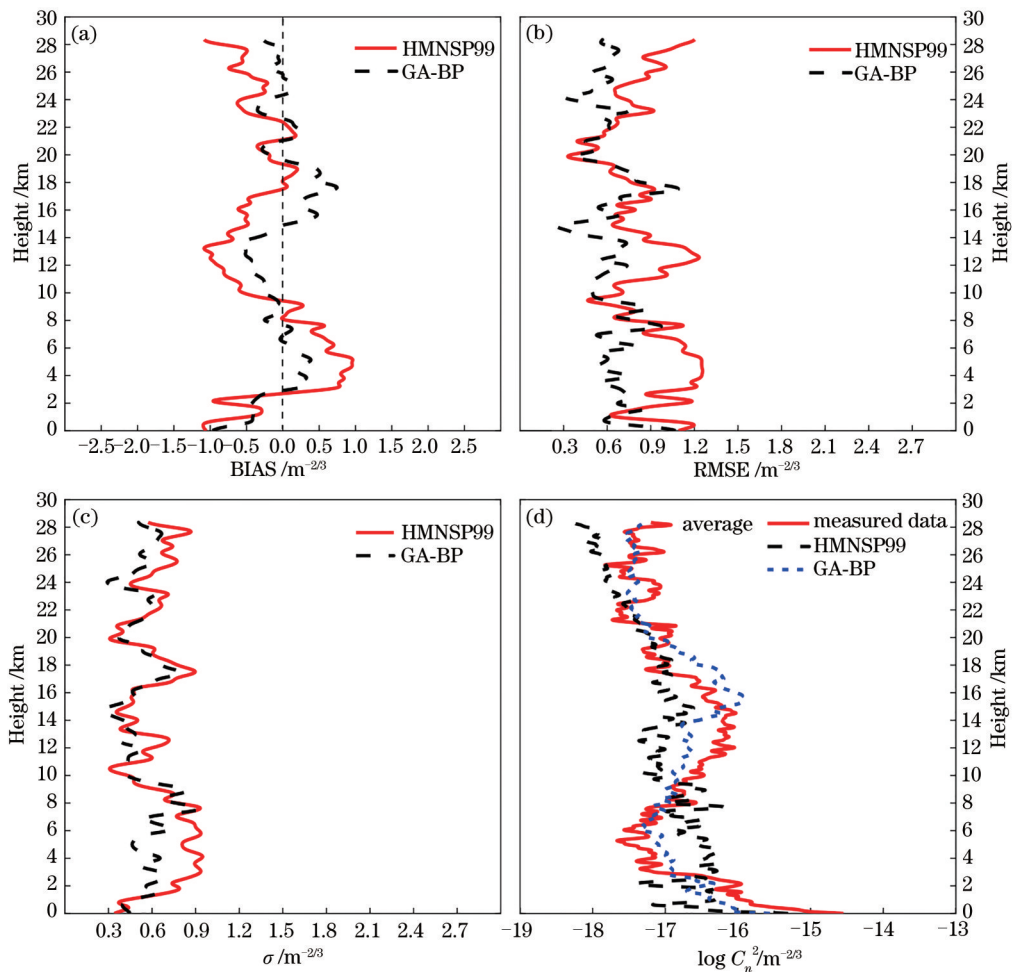


图 8 湍流探空与模式估算之间的 BIAS, RMSE, σ 和 $\log C_n^2$ 的平均廓线。(a) BIAS; (b) RMSE; (c) σ ; (d) $\log C_n^2$ 平均廓线
 Fig. 8 BIAS, RMSE, σ , and average profile of $\log C_n^2$ between turbulence sounding and model estimation. (a) BIAS; (b) RMSE; (c) σ ; (d) average profile of $\log C_n^2$

5 结 论

基于 Tatarski 高空湍流参数化方案,采用含有风切变和温度梯度的 HMNSP99 外尺度模式估算 C_n^2 廓线,同时通过 GA-BP 神经网络借助高度、压强、温度、风速、温度梯度、风切变等常规气象参数估算 C_n^2 廓线,并将这两种模式估算结果与实测 C_n^2 廓线做了对比。实验结果表明,两种模式估算的 C_n^2 廓线与实测的 C_n^2 廓线无论在量级上还是整体变化趋势上都符合得较好。与 HMNSP99 模式估算结果相比,GA-BP 模式估算的 C_n^2 平均廓线在对流层中与实测平均廓线差异较小,得到的 C_n^2 廓线 RMSE 小于 HMNSP99 模式结果,且同时小于 $1 \text{ m}^{-2/3}$ 。因此,GA-BP 神经网络模式为估算高空光学湍流提供了一种可行的方法。所提 GA-BP 模式训练所用的探空数据有限,某些高度 GA-BP 神经网络模式估算的结果与实测数据廓线仍存在差异,要提高神经网络模型的预测精度,仍需后期开展更多的探空实验进一步完善训练数据集和优化神经网络设计。

参 考 文 献

- [1] Song Z F. Applied atmospheric optics[M]. Beijing: China Meteorological Press, 1990: 67-70.
宋正方. 应用大气光学基础[M]. 北京: 气象出版社, 1990: 67-70.
- [2] Azouit M, Vernin J. Optical turbulence profiling with balloons relevant to astronomy and atmospheric physics[J]. Publications of the Astronomical Society of the Pacific, 2005, 117(831): 536-543.
- [3] Avila R, Vernin J, Masciadri E. Whole atmospheric turbulence profiling with generalized scidar[J]. Applied Optics, 1997, 36(30): 7898-7905.
- [4] Kornilov V, Tokovinin A, Shatsky N, et al. Combined MASS-DIMM instruments for atmospheric turbulence studies[J]. Monthly Notices of the Royal Astronomical Society, 2007, 382(3): 1268-1278.
- [5] Vernin J, Roddier F. Experimental determination of two-dimensional spatiotemporal power spectra of stellar light scintillation evidence for a multilayer structure of the air turbulence in the upper troposphere[J]. Journal of the Optical Society of America, 1973, 63(3): 270-273.
- [6] Tatarski V I. Wave propagation in a turbulent medium[M]. New York: McGraw-Hill, 1961.
- [7] Hufnagel R E, Stanley N R. Modulation transfer function associated with image transmission through turbulent media[J]. Journal of the Optical Society of America, 1964, 54(1): 52-61.
- [8] Warnock J M, VanZandt T E, Green J L. A statistical model to estimate mean values of parameters of turbulence in the free atmosphere [M]. 7th ed. Boulder: Symposium on Turbulence and Diffusion, 1985: 211-214.
- [9] Abahamid A, Jabiri A, Vernin J, et al. Optical turbulence modeling in the boundary layer and free atmosphere using instrumented meteorological balloons [J]. Astronomy & Astrophysics, 2004, 416(3): 1193-1200.
- [10] Wu X Q, Zeng Z Y, Ma C S, et al. Observations of atmospheric turbulence by balloon-borne instrument at Xinglong station[J]. Chinese Journal of Quantum Electronics, 1996, 13(4): 385-390.
吴晓庆, 曾宗泳, 马成胜, 等. 兴隆大气湍流气球探测[J]. 量子电子学, 1996, 13(4): 385-390.
- [11] Weng N Q, Zeng Z Y, Xiao L M, et al. Profile and characteristic of refractive index structure constant[J]. High Power Laser & Particle Beams, 1999, 11(6): 673-676.
翁宁泉, 曾宗泳, 肖黎明, 等. 大气折射率结构常数垂直分布特征[J]. 强激光与粒子束, 1999, 11(6): 673-676.
- [12] Sun G, Weng N Q, Zhang C Y, et al. Atmospheric turbulence in typical area based on NOAA model[J]. Infrared and Laser Engineering, 2014, 43(2): 388-393.
孙刚, 翁宁泉, 张彩云, 等. 基于 NOAA 模式的典型地区大气湍流高度分布[J]. 红外与激光工程, 2014, 43(2): 388-393.
- [13] Qing C, Wu X Q, Li X B, et al. Research on simulating atmospheric optical turbulence in typical area[J]. Acta Optica Sinica, 2016, 36(5): 0501001.
青春, 吴晓庆, 李学彬, 等. 典型地区高空大气光学湍流模拟研究[J]. 光学学报, 2016, 36(5): 0501001.
- [14] Cai J, Li X B, Wu P F, et al. Estimation of atmospheric optical turbulence profiles in different environments based on Tatarski parameterization scheme[J]. Infrared and Laser Engineering, 2018, 47(11): 1111002.
蔡俊, 李学彬, 武鹏飞, 等. 利用 Tatarski 方案估算不同环境下的光学湍流廓线[J]. 红外与激光工程, 2018, 47(11): 1111002.
- [15] Li Y H, Liu P, Zhou J B, et al. Center extraction of structured light stripe based on back propagation neural network[J]. Acta Optica Sinica, 2019, 39(12):

1212005.
李玥华, 刘朋, 周京博, 等. 基于 BP 神经网络的结构光光条中心提取[J]. 光学学报, 2019, 39(12): 1212005.
- [16] Zhang Q, Xiao G, Lan Y Q. Turbulence target detection based on BP neural network multi-level classification[J]. *Systems Engineering and Electronics*, 2018, 40(7): 1486-1490.
张强, 肖刚, 蓝屹群. 基于 BP 神经网络多类分类的湍流目标探测[J]. 系统工程与电子技术, 2018, 40(7): 1486-1490.
- [17] Wang Y, Basu S. Using an artificial neural network approach to estimate surface-layer optical turbulence at Mauna Loa, Hawaii[J]. *Optics Letters*, 2016, 41(10): 2334-2337.
- [18] Lü J, Zhu W Y, Cai J, et al. Comparison of two approaches for estimating atmospheric optical turbulence intensity near sea[J]. *Acta Optica Sinica*, 2017, 37(5): 0501001.
吕洁, 朱文越, 蔡俊, 等. 两种估算近海面大气光学湍流强度方法的比较[J]. 光学学报, 2017, 37(5): 0501001.
- [19] Su C D, Wu X Q, Luo T, et al. Adaptive niche-genetic algorithm based on backpropagation neural network for atmospheric turbulence forecasting[J]. *Applied Optics*, 2020, 59(12): 3699-3705.
- [20] Chen X W, Zhu W Y, Qian X M, et al. Estimation of surface layer optical turbulence using artificial neural network[J]. *Acta Optica Sinica*, 2020, 40(24): 2401002.
陈小威, 朱文越, 钱仙妹, 等. 基于人工神经网络的近地面光学湍流估算[J]. 光学学报, 2020, 40(24): 2401002.
- [21] Wu X Q, Tian Q G, Jiang P, et al. A new method of measuring optical turbulence of atmospheric surface layer at Antarctic Taishan station with ultrasonic anemometer[J]. *Advances in Polar Science*, 2015, 26(4): 305-310.
- [22] Qing C, Wu X Q, Li X B, et al. Use of weather research and forecasting model outputs to obtain near-surface refractive index structure constant over the ocean[J]. *Optics Express*, 2016, 24(12): 13303-13315.
- [23] Qing C, Wu X Q, Li X B, et al. Mesoscale optical turbulence simulations above Tibetan Plateau: first attempt[J]. *Optics Express*, 2020, 28(4): 4571-4586.
- [24] Han Y J, Wu X Q, Luo T, et al. New Cn_2 statistical model based on first radiosonde turbulence observation over Lhasa[J]. *Journal of the Optical Society of America A*, 2020, 37(6): 995-1001.
- [25] Ruggiero F H, DeBenedicts D A. Forecasting optical turbulence from mesoscale weather prediction models[C]//2002 DoD High Performance Modernization Program Users Group Conference, Austin, Texas. [S.l.: s.n.], 2002.
- [26] Han L Q. Artificial neural network tutorial [M]. Beijing: Beijing University of Posts and Telecommunications Press, 2006: 58-64.
韩力群. 神经网络教程[M]. 北京: 北京邮电大学出版社, 2006: 58-64.
- [27] Liu D, Li J, Li Y H, et al. Application experiment of BP neural network model in long-term weather forecasts[J]. *Meteorological Science and Technology*, 2006, 34(3): 250-253.
刘德, 李晶, 李永华, 等. BP 神经网络在长期天气过程预报中的应用试验[J]. 气象科技, 2006, 34(3): 250-253.
- [28] Li H. Methods of statistical learning[M]. Beijing: Tsinghua University Press, 2012: 10-17.
李航. 统计学习方法[M]. 北京: 清华大学出版社, 2012: 10-17.
- [29] Wang X P, Cao L M. Genetic algorithm: theory, application and implementation of software[M]. Xi'an: Xi'an Jiaotong University Press, 2002: 1-16.
王小平, 曹立明. 遗传算法: 理论、应用与软件实现[M]. 西安: 西安交通大学出版社, 2002: 1-16.
- [30] Riedmiller M, Braun H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm[C]//IEEE International Conference on Neural Networks, March 28-April 1, 1993, San Francisco, CA, USA. New York: IEEE Press, 1993: 586-591.
- [31] Masciadri E, Lascaux F, Fini L. MOSE: operational forecast of the optical turbulence and atmospheric parameters at European Southern Observatory ground-based sites-I. overview and vertical stratification of atmospheric parameters at 0-20 km[J]. *Monthly Notices of the Royal Astronomical Society*, 2013, 436(3): 1968-1985.
- [32] Wu X Q, Qian X M, Huang H H, et al. Measurements of seeing, isoplanatic angle, and coherence time by using balloon-borne microthermal probes at Gaomeigu[J]. *Acta Astronomica Sinica*, 2014, 55(2): 144-153.
吴晓庆, 钱仙妹, 黄宏华, 等. 丽江高美古视宁度、等晕角及相干时间的探空测量[J]. 天文学报, 2014, 55(2): 144-153.