

利用激光风廓线雷达对海洋大气边界层高分辨率光学湍流估算模型的研究

朱黎明^{1,2*}, 孙刚^{1**}, 张汉九^{1,3}, 许满满¹, 陈多龙^{1,3}, 邵士勇¹, 武鹏飞¹, 李学彬¹

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大气光学重点实验室, 安徽 合肥 230031;

²安徽大学物质科学与信息技术研究院, 安徽 合肥 230601;

³中国科学技术大学环境科学与光电技术学院, 安徽 合肥 230031

摘要 在海洋地区利用相干多普勒激光风廓线雷达反演可以得到边界层内全天候大气光学湍流廓线。采用机器学习方法-后向传播神经网络进行训练得到边界层光学湍流估算模型,以探空实测常规气象参数作为模型输入参数估算不同日期不同时刻的边界层内大气光学湍流廓线,并与实测值进行比较。通过误差分析可知,白天和夜晚的估算光学湍流廓线均方根误差分别为 0.4332 和 0.5626,相关系数分别为 0.8899 和 0.7673。该研究表明,相干多普勒激光风廓线雷达反演的光学湍流廓线可以通过神经网络模型实现全天候对海洋大气边界层光学湍流廓线估算的功能,且效果较好,在光电工程及天文选址方面具有重要工程参考意义。

关键词 大气光学; 激光雷达; 湍流廓线; 大气边界层; 机器学习; 神经网络

中图分类号 P183.4

文献标志码 A

DOI: 10.3788/AOS202242.1201004

Study on High Resolution Optical Turbulence Estimation Model of Marine Atmospheric Boundary Layer Using Lidar

Zhu Liming^{1,2*}, Sun Gang^{1**}, Zhang Hanjiu^{1,3}, Xu Manman¹, Chen Duolong^{1,3},
Shao Shiyong¹, Wu Pengfei¹, Li Xuebin¹

¹Key Laboratory of Atmospheric Optics, Anhui Institute of Optics and Fine Mechanics,

Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230031, Anhui, China;

²Institutes of Physical Science and Information Technology, Anhui University, Hefei 230601, Anhui, China;

³School of Environmental Science and Optoelectronic Technology, University of Science and Technology of China, Hefei 230031, Anhui, China

Abstract In the marine area, the all-weather atmospheric optical turbulence profile within the boundary layer is obtained by inversion by coherent Doppler laser wind profile radar. The machine learning approach and back propagation neural network is used to train the optical turbulence estimation model of the boundary layer. The conventional meteorological parameters measured by sounding are used as model input parameters to estimate the atmospheric optical turbulence profile in the boundary layer on different days and different times, and compared with the measured values. The error analysis shows that the root mean square errors of the estimated optical turbulence profiles at day and night are 0.4332 and 0.5626, respectively, and the correlation coefficients are 0.8899 and 0.7673, respectively. The research proves that the optical turbulence profile inversion of coherent Doppler laser wind profile radar can realize the function of all-weather estimation of optical turbulence profile of the oceanic atmospheric boundary layer through the neural network model, and the effect is good. It has great engineering reference significance in photoelectric engineering and astronomical site selection.

Key words atmospheric optics; Lidar; turbulence profile; boundary layer; machine learning; neural network

收稿日期: 2021-08-27; 修回日期: 2021-10-26; 录用日期: 2021-11-17

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: *zlm1998@mail.ustc.edu.cn; **gsun@aiofm.ac.cn

1 引言

大气湍流会造成大气折射率的起伏,当电磁波经过湍流层时会造成振幅和相位的扰动,导致图像退化,出现光学图像的闪烁、模糊和漂移等现象,限制了大型天文望远镜的角分辨率,显著影响地基天文观测效果。自适应光学(AO)系统通过对波前相位校正可以在一定程度上减少大气湍流对天文观测的影响,使光学系统达到较大的斯特列尔比^[1]。AO系统的设计和优化需要已知相干长度、等晕角、视宁度等光学湍流参数,这些参数均可由大气折射率结构常数 C_n^2 获得,大气折射率随高度的分布被称为大气折射率结构常数廓线 $C_n^2(h)$,其中, h 为高度。大气折射率结构常数廓线在不同大气层结中具有不同的分层特性,边界层是受下垫面直接影响的层结,高度在 2 km 以下,受天气条件的日变化影响强烈,是大气活动最剧烈的部分,因此估算全天候边界层内 C_n^2 具有重要意义。国外方面: Gur'yanov 等^[2]发现边界层湍流对整层大气湍流的贡献占有主导地位; Abahamid 等^[3]利用 168 次探空实验对边界层湍流进行统计分析,验证了 C_n^2 符合幂律为 $-4/3$ 的随高度指数递减统计关系。国内方面: 孙刚等^[4]通过研究合肥地区整层大气温度观测资料,得到了大气温度的垂直分布廓线并统计了温度分布特性对 C_n^2 的影响; 青春等^[5]利用数值天气预报和外尺度模式预报了高美古、茂名等地区的 C_n^2 廓线; 韩亚娟等^[6]利用青藏高原地区探空数据拟合出 HV5/7 模式。以上工作均由探空数据得到,时间分辨率低,不能反映 C_n^2 全天变化情况,尤其是大气活动最活跃的边界层。本文利用相干多普勒激光风廓线雷达测量风速的高分辨率特性反演边界层内 C_n^2 廓线并构建神经网络模型估算全天候大气边界层 C_n^2 廓线,国内还没有这方面研究。

神经网络是 20 世纪 80 年代兴起的人工智能研究热点。它是基于生物神经网络的结构和功能的数学模型或计算模型,通过大量神经元以不同的连接方式组成不同的网络,可以用于对非线性连续函数的估计和近似,在图像识别、自然语言处理、数据挖掘等领域具有巨大的应用价值^[7-9]。

本次实验首先采用 S4000 型相干多普勒激光风廓线雷达的风速实测数据,结合海洋地区 Dewan 外尺度模型,反演得到海洋大气边界层内高时空分辨率 C_n^2 廓线。其时间分辨率为 10 min,空间分辨率为 23 m,激光雷达反演风速达到的最大高度受天

气状态、气溶胶浓度等因素影响。然后利用机器学习方法-反向传播(BP)神经网络,对激光雷达反演得到的 6 天数据,共 864 条廓线进行训练,得到边界层内高时空分辨率 C_n^2 神经网络估算模型。最后结合探空实测数据进行验证,证明了利用相干多普勒激光风廓线雷达反演海洋大气边界层内高时空分辨率 C_n^2 廓线的可行性。该研究对边界层内 C_n^2 廓线预报,乃至整层 C_n^2 廓线的实时预报具有重要参考价值。

2 实验概述和理论分析

2.1 实验概述

2020 年, S4000 型相干多普勒激光风廓线雷达系统安装在海洋岛基观测场地,开展大气风场观测。仪器装置如图 1 所示。S4000 型激光雷达体积小,观测采用多普勒五波束法来获取风廓线,为避免地形影响、保证数据质量,剔除 60 m 以下和信噪比 ≤ 8 dB 的观测高度数据。



图 1 S4000 型相干多普勒测风激光雷达系统

Fig. 1 S4000 coherent Doppler wind Lidar

2020 年 10 月 17 日至 2020 年 11 月 12 日,在海洋地区随船实验中利用探空气球搭载新型全球定位系统(GPS)温度脉动仪开展探空实验。新型温度脉动仪统计时间平均为 5 s,频率响应范围为 0.1 ~ 30.0 Hz,温度标准差不大于 0.002 °C,等效 C_n^2 噪声为 $3 \times 10^{-18} \text{ m}^{-2/3}$ 。探空气球的上升速度约为 5 m/s,垂直分辨率约为 30 m^[6,10]。本次研究选取随船实验的 15 份探空数据,包括 11 份白天数据和 4 份夜晚数据,探空实验可获得边界层内大气折射率结构常数 C_n^2 、温度、压强、湿度、风速等参数的廓线分布情况。

2.2 C_n^2 的测量和估算理论

对于充分发展的大气湍流,假设满足 Kolmogorov^[11]局地均匀各向同性,在惯性子区范围内具有 2/3 的幂律关系,温度结构函数定义为

$$D_T(r) = \overline{[T(r_1 + r) - T(r_1)]^2} = C_T^2 r^{2/3}, \quad (1)$$

式中: $l_0 < r < L_0$, l_0 为内尺度, L_0 为外尺度; $T(r_1)$ 和 $T(r_1+r)$ 分别为在 r_1 点和与 r_1 点相距为 r 的两点温度; C_T^2 为温度结构常数。温差变化由相距 1 m 的铂丝微温探头获得, 电阻约为 10 Ω , 直径约为 10 μm 。通过两点微温探头获得空间两点温差, 利用式(1)求得温度结构常数 C_T^2 。在可见光和近红外波段, 忽略湿度影响, 近似地认为折射率结构常数^[12]可以直接由某一高度的气压 P 、气温 T 和 C_T^2 计算得到, 即

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

以上为探空搭载温度脉动仪测量 C_n^2 的理论方法。文献[12]提出了常规气象参数和湍流外尺度模型估算大气折射率结构常数的关系式, 表示为

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

式中: α 为常数, 取值为 2.8; M 为折射率梯度, 可由温度 T 、气压 P 以及位温 θ 求得。其表达式为

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

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

目前广泛应用的外尺度模式有: 与高度相关的 Coulman 经验外尺度模式^[13], 与风切变相关的 Dewan 外尺度模式^[14], 以及同时考虑风切变和温度切变的 HMNSP99 外尺度模式。本文旨在用激光雷达获得边界层风场条件反演 C_n^2 廓线, 故本文采用只与风切变量相关的 Dewan 外尺度模式的对流层部分, S 表示不同风速分量 u 和 v 的风切变量, 其表达式为

$$L_0^{4/3} = 0.1^{4/3} \times 10^Y, \quad (6)$$

$$Y = 1.64 + 42S, \quad (7)$$

$$S = \sqrt{\left(\frac{\partial u}{\partial h} \right)^2 + \left(\frac{\partial v}{\partial h} \right)^2}。 \quad (8)$$

2.3 BP 神经网络理论

BP 神经网络是人工神经网络的重要实现方式, 该算法基于前馈型神经网络学习, 采用误差逆传播训练算法, 在学习过程中, 误差结果逐层反向传播, 根据代价函数大小利用梯度下降依次调节每层权重和阈值, 直到达到目标误差或者最小为止^[7-9]。

假设训练集有 d 个样本, 即 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_d, y_d)\}$ 。输入由 m 个特征向量组成, 即 $x = [x_1, x_2, \dots, x_l, \dots, x_m]$, 期望输出为 t 维向量, 即 $y = [y_1, y_2, \dots, y_k, \dots, y_t]$ 。第 l 层隐含层各神经元的输出为 $h^{(l)} = [h_1^{(l)}, h_2^{(l)}, \dots, h_j^{(l)}, \dots, h_{s_l}^{(l)}]$, s_l 为第 l 层隐含层神经元的个数, $w_{ij}^{(l)}$ 为 $l-1$

层第 j 个神经元与 l 层第 i 个神经元之间的权重, $b_i^{(l)}$ 为第 l 层第 i 个神经元的偏置; 对于训练样本 y , 假设网络的预测输出为 \hat{y} , E 为代价函数, 表征模型训练结果的好坏程度。BP 算法将按照梯度下降算法进行权重和偏置的更新,

$$E = \frac{1}{d} \sum \frac{1}{2} (\hat{y} - y)^2, \quad (9)$$

$$w_{i,j}^{(l)} = w_{i,j}^{(l)} - \mu \frac{\partial E}{\partial w_{i,j}^{(l)}}, \quad (10)$$

$$b_i^{(l)} = b_i^{(l)} - \mu \frac{\partial E}{\partial b_i^{(l)}}, \quad (11)$$

式中: μ 为学习率, 取值范围为 $[0, 1]$ 。

2.4 大气参数模式

在实际观测条件下, 由于仪器限制等技术原因, 很难获得温度、压强廓线同步观测情况。为此, 采用大气分层模型来模拟温压在高度上的分布情况。本文使用美国 1976 年标准大气模式, 其应用的高度范围也符合中国标准^[15]。在 11 km 以下, 大气温度随高度降低, 表达式为

$$T_h = T_0 - \Gamma h, \quad (12)$$

式中: T_h 为高度 h 处的温度; T_0 为地面温度, T_0 由多普勒激光风廓线雷达配置的气象站同步得到; Γ 为温度的垂直递减率, 为常数 6.5×10^{-3} K/m。流体静力学方程表示为

$$\frac{dp}{p} = -\frac{g}{R_d T} dz。 \quad (13)$$

压强廓线则由式(13)代入式(12)得到

$$p_h = p_0 \left(1 - \frac{\Gamma h}{T_0} \right)^{\frac{g}{R_d \Gamma}}, \quad (14)$$

式中: p_h 为高度 h 处的压强; p_0 为地面压强, 与 T_0 相同, 由气象站同步得到; R_d 为干空气比气体常数, 为 287 J/(kg · K); g 为重力加速度。

3 数据处理和结果分析

3.1 边界层 C_n^2 模式和外尺度模型的建立

大气边界层是存在各种尺度湍流, 湍流输送起重要作用并导致气象要素日变化显著的低层大气, 其 C_n^2 廓线具有独特的指数递减趋势, Kaimal 等^[16]提出 C_n^2 随高度指数递减的经验分布规律, 其拟合经验表达式为

$$C_n^2 = A h^{-p}, \quad (15)$$

式中: A 为待拟合常数; p 的值约为 4/3。

Hufnagel-Vally 模型简称 HV 模型, 由 Ulrich 利用了 Valley 的假设, 将 Hufnagel 模型从 3 km 延

伸至近地面高度,使得该模型包含近地面层^[17-18]。其普遍应用的形式为

$$C_n^2(h) = 8.2 \times 10^{-16} W^2 (h/0.1)^{10} \exp(-h) + 2.7 \times 10^{-16} \exp(-h/1.5) + B \exp(-h/0.1), \quad (16)$$

式中: W 为 5~20 km 高度风速的均方根误差 (RMSE); B 为表征大气近地面光学湍流强度的参数。通常取 $W = 21, B = 1.7 \times 10^{-14} \text{ m}^{-2/3}$, 即为经典 HV5/7 模型。

选取随船 15 次探空实验,取 0~1.5 km 的探空数据,经预处理后以 50 m 为一层取平均得到一次实验的边界层 C_n^2 廓线。将 15 次探空实验按上述处理后取平均得到边界层 C_n^2 平均廓线,利用式 (3)、(15)、(16) 分别代表的 Dewan 外尺度模式、Wyngaard 模式、HV5/7 经验模式进行拟合得到图 2,纵坐标为高度,横坐标为 $\lg(C_n^2)$ 。不同模式的误差分析和拟合公式见表 1。如图 2 所示:在边界层内,光学湍流强度 $\lg(C_n^2)$ 的变化范围为 $[-13, -17]$,总体趋势上 $\lg(C_n^2)$ 随着高度增加而减小;在 200 m 以内, $\lg(C_n^2)$ 随着高度增加迅速从 -13.5 减小至 -15.8;在 200 m 以上, $\lg(C_n^2)$ 随着高度增加而减小缓慢,在 1.5 km 量级达到 -16 甚至更小。结合图 2 和表 1 对不同模型的拟合效果进行分析: Dewan 外尺度模式能结合常规气象参数很

好地反映出 C_n^2 变化特征,且量级及变化趋势均与实测数据相符, RMSE 为 0.1064, 相关系数达到 0.9813; HV 模式和 Wyngaard 模式从趋势上来说与实测数据相吻合,但二者均不能实际反映出 200 m 以内 C_n^2 随高度急剧减小的尖角状结构,两个模型具有一定的经验性,不能明确反映常规气象参数对 C_n^2 的影响情况,相关系数分别为 0.7505 和 0.8537, RMSE 分别为 0.4832 和 0.2588, 拟合效果明显差于 Dewan 外尺度模式。这也在一定程度上验证了此次工作中, Dewan 外尺度模式在精细反演边界层内高分辨率 C_n^2 廓线的优越性。

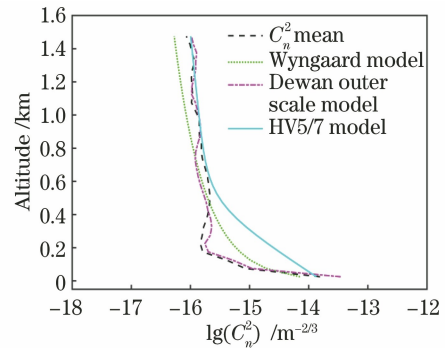


图 2 边界层不同模式下 C_n^2 廓线与实测 C_n^2 平均廓线对比

Fig. 2 Comparison of boundary layer C_n^2 profiles with measured C_n^2 mean profiles under different models

表 1 不同模式下的拟合函数和误差分析

Table 1 Fitting functions and error analysis under different models

Function and error model	Fitting function	RMSE	Correlation coefficient
Wyngaard model	$C_n^2 = 3.38 \times 10^{-13} \times h^{-1.2}$	0.2588	0.8537
Dewan outer scale model	$C_n^2 = \alpha M^2 \times 0.1^{1/3} \times 10^{1.4210+76.5312S}$	0.1064	0.9813
HV5/7 model	Eq. (16)	0.4832	0.7505

3.2 多普勒激光风廓线雷达反演边界层内高分辨率 C_n^2 廓线

选取 9 月份在海洋地区岛基观测效果较好,观测高度普遍在 800 m 以上的 6 天的多普勒激光风廓线雷达的风速数据来计算风切变参数 S , 对应日期天气情况如表 2 所示。根据近地面气象站同步观测的温度 T 和压强 P , 利用大气参数模式 [式 (12)、(14)] 近似反演边界层内温度和压强的时空变化。将其代入 3.1 节拟合得出的海洋地区 Dewan 外尺度模型, 反演出全天候边界层内 C_n^2 廓线, 取对数 $\lg(C_n^2)$, 如图 3 所示。总体而言: 强湍流层集中于近地层 100 m 以下, $\lg(C_n^2)$ 均大于 -15, 这可能与下垫面的剪切影响较大有关; 在 100 m 以上, C_n^2 随高

度增加而逐渐减小, $\lg(C_n^2)$ 集中在 $[-16, -17]$ 之间。对具体日期进行日变化分析, 其中虚线框代表白天较强的湍流趋势, 实线框代表夜晚较弱的湍流趋势。可以发现: 在晴天条件下, 9 月 1 日、9 月 5 日和 9 月 24 日具有较为明显的日变化特征, 中午 12 点左右受太阳辐射影响最强, 边界层状态活跃, $\lg(C_n^2)$ 较大, 在 -16 以上, 夜晚湍流则明显减弱, $\lg(C_n^2)$ 主要集中在 $[-16.5, -17.0]$ 之间, 9 月 5 日由于晴转多云, 虽有一定日变化, 但整天湍流较弱, 夜晚 $\lg(C_n^2)$ 甚至低于 -17; 多云或阴天情况下, 如 9 月 4 日和 9 月 15 日所示, 全天湍流均较弱, 无明显日变化趋势; 对于图中出现的特别情况, 如 9 月 1 日夜晩、9 月 2 日凌晨和 17 点左右, 湍流较强可能是与突发雷雨等局地对流有关。

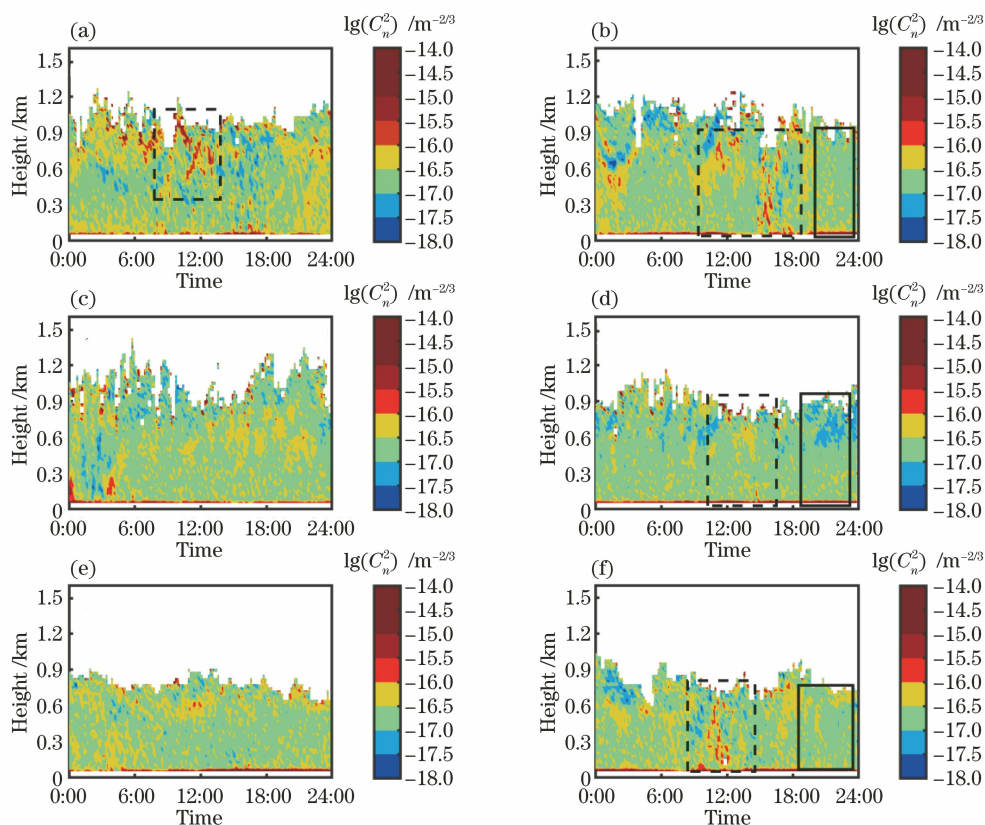


图 3 不同日期风廓线雷达反演的边界层内 C_n^2 廓线。(a) 2020-09-01; (b) 2020-09-02; (c) 2020-09-04; (d) 2020-09-05; (e) 2020-09-15; (f) 2020-09-24

Fig. 3 Boundary layer C_n^2 profile of the wind profile radar inversion on different dates. (a) 2020-09-01; (b) 2020-09-02; (c) 2020-09-04; (d) 2020-09-05; (e) 2020-09-15; (f) 2020-09-24

表 2 不同日期天气状况表

Table 2 Table of weather conditions on different dates

Date	Weather condition
2020-09-01	Sunny to thundershowers
2020-09-02	Cloudy to thundershowers
2020-09-04	Cloudy
2020-09-05	Sunny to cloudy
2020-09-15	Overcast to cloudy
2020-09-24	Sunny to thundershowers

3.3 边界层内 C_n^2 廓线估算模型

C_n^2 是多种大气参数共同影响作用的结果,综合考虑现有探测数据和模型的物理机制,我们选择三个常规气象参数分别为温度 T 、压强 P 和风速 V ,以及代表日变化的时间参数 t 作为模型的输入变量因子;选择 C_n^2 为唯一输出构建 BP 神经网络估算模型,估算模型的设计如图 4 所示。

选择图 3 反演出的 C_n^2 6 天的时空分布廓线(共 864 条廓线,31386 条记录)作为训练集构建 BP 神经网络模型,其中随机选取 80% 作为训练集,选取剩余的 20% 作为验证集。将随船实验中天气情况

较好的 6 天的实测探空数据(包括 3 天白天探空和 3 天夜晚探空的温度 T 、压强 P 、风速 V 以及放球时间 t)作为测试集输入到训练完毕的 BP 神经网络估算模型,估算 C_n^2 取对数 $\lg(C_n^2)$ 并与实测值进行比较,通过误差分析评价模型的泛化能力。

模型训练之前,需要对输入变量因子进行归一化处理并确定超参数。归一化将输入变量因子缩放到 $[-1, 1]$ 范围内,从而消除不同量纲对估算结果产生的影响,归一化公式为

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{x_{\max} - x_{\min}} + y_{\min}, \quad (17)$$

式中: y 为输入变量因子 x 归一化后的结果; y_{\max} 和 y_{\min} 分别为归一化范围设定的最大值和最小值,本文分别取 1 和 -1; x_{\max} 和 x_{\min} 分别为输入变量因子中的最大值和最小值。

超参数是在训练开始前设置值的参数,不是通过训练得到的值。通常情况下,需要对超参数进行优化,以提高机器学习的性能和效果。本文估算模型需要确定的超参数有:隐含层的层数、每层神经元




图 4 边界层内估算全天候 C_n^2 廓线的神经网络模型

Fig. 4 Neural network model for estimating all-weather C_n^2 profile in boundary layer

的个数、学习率。隐含层层数和个数的确定目前还没有普适的方法,但有一定经验参考,需要试错反复调试,在 $[0, 20]$ 内选取可行的神经元数目组合,反复实验运行该网络架构 20 次,将 20 次训练集的均方误差函数平均,取平均后的最小均方误差的网络架构作为最优网络架构,确定隐含层层数为 2,隐含层神经元个数分别为 8 和 10,此时训练集的最小均方误差为 0.004,建立起 4-8-10-1 的 BP 多层神经网络

估算模型,学习率采用传统默认值 0.1。超参数确定完成,即可代入 BP 神经网络模型,利用梯度下降算法,直到目标精度或者训练样本误差降低但验证集误差不再降低为止。

将这 6 天探空实验得到的温度 T 、压强 P 、风速 V 以及放球时间 t 代入 BP 神经网络估算模型,得到边界层 C_n^2 估算结果。图 5 为这 6 次探空实验边界层内廓线的估算结果。总体趋势来说,这 6 天估算

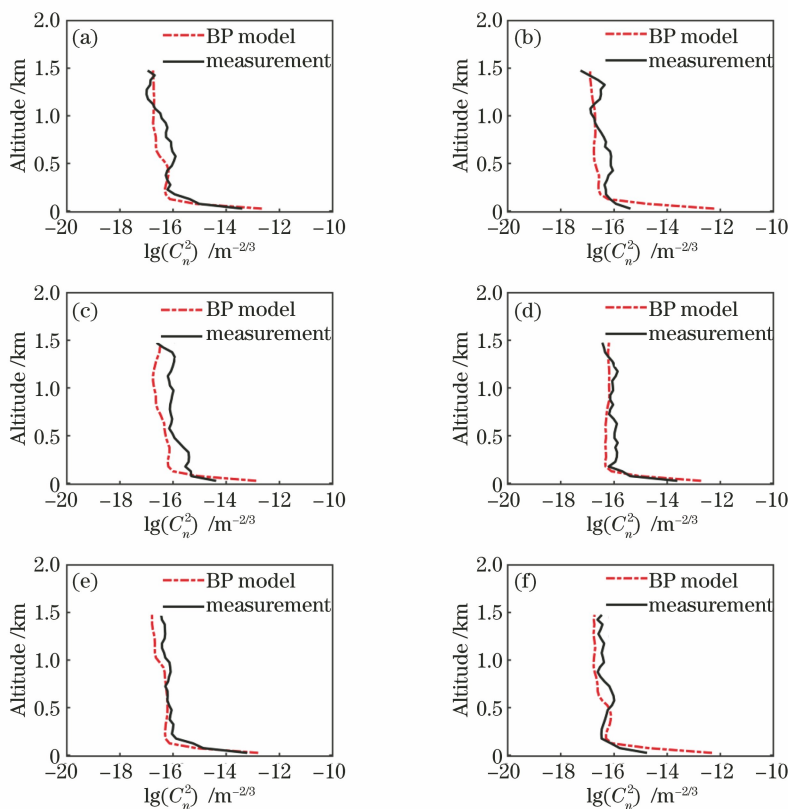


图 5 不同日期神经网络估算的边界层内廓线。(a) 2020-10-17;(b) 2020-10-18;(c) 2020-10-23;
(d) 2020-10-25;(e) 2020-10-26;(f) 2020-11-02

Fig. 5 Boundary layer profile of neural network estimates on different dates. (a) 2020-10-17; (b) 2020-10-18;
(c) 2020-10-23; (d) 2020-10-25; (e) 2020-10-26; (f) 2020-11-02

的廓线虽存在一定误差,但仍能较准确地反映出该时刻边界层随高度的指数变化规律。定量来说,图 5(b)和(f)分别为当地时间 18:29 和 19:23 的估算结果,可以发现,在 100 m 以下出现了 3 个量级的高估,这可能是因为该时段在“转换时刻”附近,近地面为稳定层结,湍流运动较弱,而 BP 模型中由于仪器受限在温度廓线上采用的是温度随高度递减的参数模式,并未考虑到夜间逆温和中性层结等变化情况可能造成此时间段 C_n^2 高估。在所有估算结果中,当高度在 200 m 以上时,均出现不同程度的低估,图 5(c)的低估程度最大,低估接近一个量级,其他日期的估算结果低估均不超过 0.5 个量级。这种程度的低估可能是下垫面不同,多普勒激光风廓线雷达为岛基观测,下垫面为陆地,随船探空的下垫面为海洋,这会造成边界层内热力因素的差异,因为温度切变也是猝发湍流的重要因素。同时使用的大气温度参数模式中假设不同高度具有相同的温度切变,这种模式误差也是造成 C_n^2 低估的另一重要因素。

3.4 误差分析

为定量描述 BP 神经网络模型的估算能力和泛化效果,选取 3 个数据统计量 RMSE、平均绝对误差(MAE)以及相关系数 R_{xy} ,分别对 $\lg(C_n^2)$ 进行分析。数据统计量的表达式分别为

$$E_{\text{RMSE}} = \sqrt{\sum_{i=1}^N \frac{1}{N} |y_i - x_i|^2}, \quad (18)$$

$$E_{\text{MAE}} = \sum_{i=1}^N \frac{1}{N} |y_i - x_i|, \quad (19)$$

$$R_{xy} = \frac{\sum_{i=1}^N (x_i - \bar{X})(y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{X})^2 (y_i - \bar{Y})^2}}, \quad (20)$$

式中: x_i 为某高度上实际测量值; y_i 为同高度 BP 神经网络模型的估算值; N 为探空 50 m 分层的数量,本文取 30; \bar{X} 为此次探空实际测量值的平均; \bar{Y} 为此次探空实验 BP 神经网络模型估计的平均值。

将 6 次探空模型估算值与探空实测值的 $\lg(C_n^2)$ 代入 3 组统计量公式中进行分析,得到误差分析结果(表 3)。可以看出,处于“转化时刻”的第 2 次探空实验估算效果较差, RMSE 达到 0.7057, 相关系数为 0.6521, 其余探空实验估算结果的相关系数都在 0.8000 以上,最高可达 0.9597, RMSE 均不大于 0.6, 主要在 0.3~0.4 之间。综合考虑白天和夜间的估算效果,得出表 4。可以看出: BP 神经网络的估算模型在估算白天 C_n^2 廓线的 RMSE 为 0.4332,

相关系数达到 0.8899; 夜间估算的 RMSE 为 0.5626, 相关系数为 0.7673。这说明了神经网络在白天的估算效果更佳, 夜间估算误差相对较大, 这可能是由于模型忽略了夜间逆温现象和湍流猝发性。

表 3 不同日期估算的 $\lg(C_n^2)$ 误差分析表

Table 3 Error analysis table of $\lg(C_n^2)$ estimation on different dates

Launch date	Launch time (local time)	RMSE	MAE	R_{xy}
2020-10-17	22:04	0.3680	0.2989	0.9004
2020-10-18	18:29	0.7057	0.4286	0.6521
2020-10-23	08:43	0.5986	0.5359	0.8326
2020-10-25	09:52	0.3156	0.2621	0.9314
2020-10-26	08:40	0.3245	0.2708	0.9597
2020-11-02	19:23	0.5621	0.3608	0.8960

表 4 白天和夜间估算 $\lg(C_n^2)$ 误差分析表

Table 4 Error analysis table of $\lg(C_n^2)$ estimation during day and night

Launch period	RMSE	MAE	R_{xy}
Day	0.4332	0.3575	0.8899
Night	0.5626	0.3628	0.7673

4 结 论

本文使用随船观测探空数据拟合了海洋地区的 Dewan 外尺度模型,并与其他统计模型进行对比分析,验证了 Dewan 外尺度模型在精细反映边界层内光学湍流方面的优越性。然后,使用岛基架设的相干多普勒激光风廓线雷达的高分辨率风速数据结合新的海洋 Dewan 外尺度模型反演 6 天边界层内 C_n^2 的全天候变化,具有一定的日变化特征。最后,利用多普勒激光风廓线雷达反演得到的 6 天 C_n^2 廓线,共计 864 条廓线,构建 BP 神经网络模型估算边界层内 C_n^2 廓线,并与实际值比较,发现 BP 神经网络估算模型能准确地估算出边界层内的 C_n^2 指数递减的变化趋势。定量来说,白天估算的相关系数为 0.8899, RMSE 为 0.4332, 夜间的估算效果较差,相关系数为 0.7673, RMSE 为 0.5626, 这可能是由于大气参数模式忽略了夜间逆温现象和湍流猝发性。因此,实现边界层温度廓线的实时变化同步观测是对该模型进行优化的重要思路,这也是以后对该模型优化可以展开的重要工作,为边界层预报 C_n^2 奠定了模型基础。

参 考 文 献

- [1] 饶瑞中. 光在湍流大气中的传播[M]. 合肥: 安徽科

- 学技术出版社, 2005.
- Rao R Z. Light propagation in the turbulent atmosphere [M]. Hefei: Anhui Science and Technology Press, 2005.
- [2] Gur'yanov A E, Kallistratova M A, Kutyrev A S, et al. The contribution of the lower atmospheric layers to the seeing at some mountain observatories [J]. *Astronomy and Astrophysics*, 1992, 262: 373-381.
- [3] Abahamid A, Vernin J, Jabiri A, et al. Optical turbulence outer scale and coherence outer scale at different astronomical sites [J]. *Proceedings of SPIE*, 2004, 5489: 190-195.
- [4] 孙刚, 翁宁泉, 肖黎明, 等. 大气温度分布特性及对折射率结构常数的影响 [J]. *光学学报*, 2004, 24(5): 592-596.
- Sun G, Weng N Q, Xiao L M, et al. Profile and character of atmospheric temperature [J]. *Acta Optica Sinica*, 2004, 24(5): 592-596.
- [5] 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.
- 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.
- [6] 韩亚娟, 吴晓庆, 罗涛, 等. 拉萨光学湍流探空测量与模式分析 [J]. *光学学报*, 2020, 40(6): 0601002.
- Han Y J, Wu X Q, Luo T, et al. Optical turbulence measurement over Lhasa using a meteorological radiosonde and model analysis [J]. *Acta Optica Sinica*, 2020, 40(6): 0601002.
- [7] 李航. 统计学习方法 [M]. 北京: 清华大学出版社, 2012.
- Li H. *Methods of statistical learning* [M]. Beijing: Tsinghua University Press, 2012.
- [8] 伊恩·古德费洛, 加书亚·本吉奥, 亚伦·库维尔. 深度学习 [M]. 赵申剑, 黎彧君, 符天凡, 译. 北京: 人民邮电出版社, 2017.
- Goodfellow I, Bengio Y, Courville A. *Deep learning* [M]. Zhao S J, Li Y J, Fu T F, Transl. Beijing: Posts and Telecom Press, 2017.
- [9] 周志华. 机器学习 [M]. 北京: 清华大学出版社, 2016.
- Zhou Z H. *Machine learning* [M]. Beijing: Tsinghua University Press, 2016.
- [10] 肖黎明, 翁宁泉, 马成胜, 等. C_n^2 探空仪的可靠性实验与数据处理方法 [J]. *合肥工业大学学报(自然科学版)*, 2004, 27(2): 179-182.
- Xiao L M, Weng N Q, Ma C S, et al. Experimental research on the reliability of C_n^2 sonde and its data processing method [J]. *Journal of Hefei University of Technology (Natural Science)*, 2004, 27(2): 179-182.
- [11] Kolmogorov A N. Local structure of turbulence in an incompressible viscous fluid at very high Reynolds numbers [J]. *Soviet Physics Uspekhi*, 1991, 30(4): 301-305.
- [12] 塔塔尔斯基. 湍流大气中波的传播理论 [M]. 北京: 科学出版社, 1978: 40-58.
- Tartaski B N. *Wave propagation in a turbulent medium* [M]. Beijing: Science Press, 1978: 40-58.
- [13] Coulman C E, Vernin J, Coqueugniot Y, et al. Outer scale of turbulence appropriate to modeling refractive-index structure profiles [J]. *Applied Optics*, 1988, 27(1): 155-160.
- [14] Dewan G A, Good R E, Beland R, et al. A model for C_n^2 (optical turbulence) profiles using radiosonde data: Pl-tr-93-2043 [R]. Hanscom: Phillips Laboratory, 1993.
- [15] 盛裴轩, 毛节泰, 李建国. 大气物理学 [M]. 2 版. 北京: 北京大学出版社, 2013.
- Sheng P X, Mao J T, Li J G. *Atmospheric physics* [M]. 2nd ed. Beijing: Peking University Press, 2013.
- [16] Kaimal J C, Wyngaard J C, Haugen D A, et al. Turbulence structure in the convective boundary layer [J]. *Journal of the Atmospheric Sciences*, 1976, 33(11): 2152-2169.
- [17] 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.
- [18] VanZandt T E, Green J L, Gage K S, et al. Vertical profiles of refractivity turbulence structure constant: comparison of observations by the Sunset Radar with a new theoretical model [J]. *Radio Science*, 1978, 13(5): 819-829.