

# 基于人工神经网络的近地面光学湍流估算

陈小威<sup>1,2</sup>, 朱文越<sup>1,2\*</sup>, 钱仙妹<sup>1,2\*\*</sup>, 罗涛<sup>1,2</sup>, 孙刚<sup>1,2</sup>, 刘庆<sup>1,2</sup>, 李学彬<sup>1,2</sup>, 翁宁泉<sup>1,2</sup>

<sup>1</sup>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;

<sup>2</sup>先进激光技术安徽省实验室, 安徽 合肥 230037

**摘要** 通过构建人工神经网络模型估算中国西北高原地区近地面光学湍流。对多层感知器(MLP)的结构进行优化,其输入层包括10个特征,隐含层包括40个神经元。探讨已建多层感知器的性能,结果表明:当训练集和测试集来自同一地区时,模型的平均相对误差为1.34%,折射率结构常数的实测值和估计值的拟合优度为0.94;当训练集和测试集来自不同地区时,多层感知器的泛化能力需进一步提高。

**关键词** 大气光学; 光学湍流; 多层感知器; 估计精度

中图分类号 P427.1

文献标志码 A

doi: 10.3788/AOS202040.2401002

## Estimation of Surface Layer Optical Turbulence Using Artificial Neural Network

Chen Xiaowei<sup>1,2</sup>, Zhu Wenyue<sup>1,2\*</sup>, Qian Xianmei<sup>1,2\*\*</sup>, Luo Tao<sup>1,2</sup>, Sun Gang<sup>1,2</sup>,  
Liu Qing<sup>1,2</sup>, Li Xuebin<sup>1,2</sup>, Weng Ningquan<sup>1,2</sup>

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

<sup>2</sup>Anhui Laboratory of Advanced Laser Technology, Hefei, Anhui 230037, China

**Abstract** This paper presents an estimate of surface layer optical turbulence in Northwest China using an artificial neural network. We optimize the configuration of the multilayer perceptron (MLP), including 10 features in the input layer and 40 neurons in the hidden layer. The performance of the constructed MLP is investigated. The results show that when the training set and testing set are from the same site, the mean relative error of the model is 1.34%. The goodness of fit between measured and estimated refractive index structure constants is 0.94. We propose that when the training set and testing set come from different sites, the generalization ability of the MLP should be enhanced.

**Key words** atmospheric optics; optical turbulence; multilayer perceptron; estimation accuracy

**OCIS codes** 010.1290; 010.1330

## 1 引 言

折射率结构常数  $C_n^2$  表征大气折射率变化的强度,是评估激光大气传输效应的重要参数。近地面大气活动复杂,空气-地表能量交换活动较强,光学湍流效应对光束传播影响较大,研究近地面  $C_n^2$  对光电系统的实际应用具有重要意义<sup>[1-4]</sup>。

为了量化近地面  $C_n^2$ ,可以用物理模式估算,也可以用仪器测量。物理模式建立在相似理论的基础

上,该理论受大气稳定条件的限制,同时涉及如动量、通量等众多参数,且估算结果精度有待提高<sup>[5-8]</sup>;测量仪器,如超声风速仪、风雷达,能够准确测量  $C_n^2$ ,但仪器造价昂贵且难以大范围开展测量实验<sup>[9-10]</sup>。人工神经网络(ANN)通过常规气象参数估算  $C_n^2$ ,能够避免上述难题,是新的  $C_n^2$  量化方法<sup>[11-12]</sup>。ANN模仿生物神经系统的组成和功能,通过大量数据建立输入-输出之间的关系,确定神经元之间的权重和联系,神经网络建立后就能对新的

收稿日期: 2020-08-03; 修回日期: 2020-08-27; 录用日期: 2020-09-19

基金项目: 科工局国防基础科研计划、先进激光技术安徽省实验室主任基金(20191002)、脉冲功率激光技术国家重点实验室主任基金(SK2020ZR08)、中国科学院科技创新重点实验室基金(CXJJ-19S028)

\* E-mail: zhuwenyue@aiofm.ac.cn; \*\* E-mail: qianxianmei@aiofm.ac.cn

输入进行预测。在众多的 ANN 结构中,多层感知器(MLP)因自适应的训练算法、可靠的映射能力,在模式识别、序列预测、方程近似等领域得到了广泛应用<sup>[13-18]</sup>。Wang 等<sup>[11]</sup>在不同的大气稳定度条件下估算近地面湍流,并建立了具有“5-5-1”结构的 MLP,其中输入层包括 5 个参数,即温度、相对湿度、气压、位温梯度及风切变,隐藏层包含 5 个神经元,然而,并未介绍 MLP 结构的建立过程,MLP 的估算精度和泛化能力需进一步优化提高。

本文使用中国西北高原不同地区的测量数据,通过特征选择方法确定输入特征,使用遗传算法确定隐含层中的神经元个数,最后分析估算结果的精度并探讨了这种方法在不同地区的适用性。

## 2 实验和数据

2012 年 7 月至 2014 年 6 月,测量地点位于中国西北高原的某观测点 1,2012 年 3 月至 2012 年 6 月,测量地点位于观测点 1 相距 100 km 的观测点 2。近地面常规气象参数和  $C_n^2$  由近地面大气参数测量系统测量得到,如图 1 所示。该系统分为距离地面高度 2 m 和 6 m 两层,每层安装一个温度脉动仪和 WXT520 型气象传感器。气象传感器测量绝对温度  $T$ [K]、气压  $P$ [hPa]、相对湿度  $R_H$ [%]、风速  $V$ [m/s]及风向  $D$ [°]。温度脉动仪测量两点温差,可通过 Kolmogorov-Obukhov 湍流近似<sup>[1]</sup>得到温度结构函数:

$$C_T^2 = \langle [T(x) - T(x+r)]^2 \rangle \cdot r^{-2/3}, \quad (1)$$

式中: $\langle \cdot \rangle$ 表示系综平均; $r$ 表示位于  $x$  和  $x+r$  位置的两个探测器的距离。每个高度上, $C_n^2$  的表达式为

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

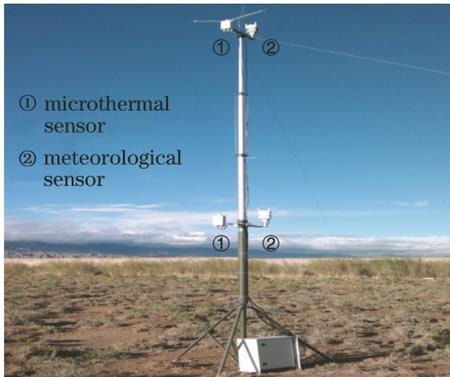


图 1 近地面大气参数测量系统

Fig. 1 Surface-layer atmospheric parameter measuring system

$C_n^2$  的测量误差( $\mu$ )源自温度响应误差( $\mu_1$ )、采集计算误差( $\mu_2$ )、计算原理误差( $\mu_3$ )及铂丝等硬件受环境影响所引起的误差( $\mu_4$ )<sup>[19]</sup>。合成后的  $C_n^2$  测量不确定度为

$$\mu = \sqrt{\mu_1^2 + \mu_2^2 + \mu_3^2 + \mu_4^2}. \quad (3)$$

实验检测表明,温度响应误差小于 1.5%,数据采集计算误差为 1.2%,计算原理误差小于 6.5%,硬件受环境影响所引起的误差小于 5%,由(3)式可计算得到  $C_n^2$  的测量误差小于 10%,对应  $\log C_n^2$  的误差小于 0.4%。

## 3 神经网络结构的优化

在众多的神经网络结构中,MLP 因可靠的映射估计功能被广泛应用。前馈 MLP 由 1 个输入层、若干隐含层及 1 个输出层构成,每层包含若干神经元,如图 2 所示。输入层中的每个神经元代表一个输入特征,输入信息传播到第一个隐含层,继续向后传播直至输出层。相邻层的神经元之间通过权重因子建立联系,权重和输入信息相互作用后得到输出信息。MLP 比较输出值和实际值的误差,通过后向传播算法对权重因子进行不断修正,使估计值和测量值的偏差最小<sup>[14]</sup>。

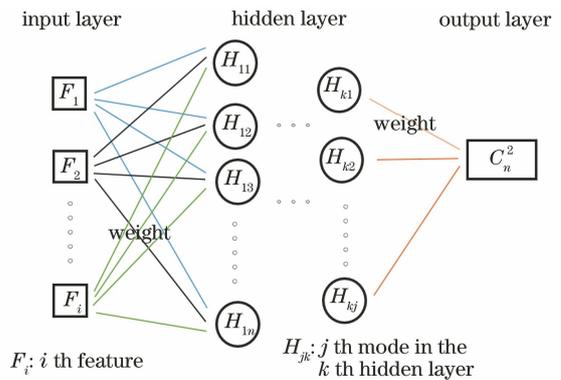


图 2 MLP 神经网络结构

Fig. 2 MLP neural network structure

MLP 的性能取决于输入特征、模型结构及训练算法。MLP 模型的优化和映射计算建立在输入特征(即图 2 中输入层中的神经元)确定的基础上,不恰当的特征会造成过拟合或欠拟合问题,因而输入特征的选择非常重要。确定 MLP 模型结构主要是确定隐含层层数和每层神经元个数,研究表明,具有单个隐含层的 MLP 已能够高精度地映射复杂的函数关系<sup>[17]</sup>,本文将隐含层层数确定为 1,即图 2 中隐含层中只有一层神经元。通常用误差后向传递算法训练模型,结果表明,Levenberg-Marquardt 算法最

稳健、效率最高<sup>[14]</sup>。因此使用 Levenberg-Marquardt 后向传播算法,结构优化的重点是确定 MLP 输入特征和隐含层中的神经元个数。

### 3.1 输入特征选择

特征选择的目的是从待选输入参数中删除无用和冗余的参数,以降低输入特征维数。遗传算法是特征选择方法中的一种,从随机初始输入开始搜索,通过选择、交叉、变异操作逐步产生新的解,经过进化迭代后,收敛于最优解<sup>[20]</sup>。最终,通过全局搜索,从备选特征集中确定最优输入特征。具体步骤如下。

1) 使用 10 位二进制染色体对特征子集进行编码,每位染色体对应一个待选特征。每位染色体上的基因值 1 和 0 分别表示对应的特征被选择与否。例如,0011000000 表明 10 个特征中,只有第三个和第四个特征被选中。

2) 随机产生  $N$  个染色体,每个染色体表征一个特征子集。此处  $N$  也是遗传算法的群体数。

3) 将每个染色体代表的特征子集代入 MLP,计算相应的适应度函数。此处适应度函数定义为估算值和真实值的平均绝对偏差。

4) 选择、交叉和变异。遗传算法进入选择-交叉-变异循环,直至满足停止准则。偏差函数值较小

的染色体有较大的生存和产生后代的概率。交叉过程产生的个体遗传了母代的部分特征,变异过程改变染色体的基因以实现全局搜索。

使用的遗传算法参数如下:群体大小为 100,交叉概率为 0.8,变异概率为 0.01,最大迭代数为 100。

图 3(a)为 2 m 高度处连续三天  $C_n^2$  的日变化特征,若无特别说明,下文  $C_n^2$  特指取对数后的原始  $C_n^2$  数据。图 3(b)~(e)中实线分别代表 2014 年 5 月 16 日 2 m 高度处温度、相对湿度、气压及风速的日变化,虚线分别代表 2 m 和 6 m 高度间的温差  $\Delta T$ 、相对湿度差  $\Delta R_H$ 、气压差  $\Delta P$  及风速差  $\Delta V$ 。可以看出, $C_n^2$  显示了典型的日变化特征,白天变化缓慢而夜间变化剧烈,在早晚两个“转换时刻”, $C_n^2$  值较小。 $C_n^2$  的日变化特征表明, $C_n^2$  值和一天中的时刻存在特定关系,因而将时刻作为一个备选的输入特征。理论研究表明, $C_n^2$  值不仅和单点大气参数有关,还受周围大气参数梯度或混合过程的影响<sup>[1]</sup>。为了尽可能多地考虑环境参数的影响,选取下述参数作为备选特征:2 m 高度处的温度、气压、相对湿度、风速、风向;2 m 和 6 m 高度间的温差、气压差、相对湿度差、风速差。因而,备选输入特征集包含时刻和气象参数共 10 个输入特征。

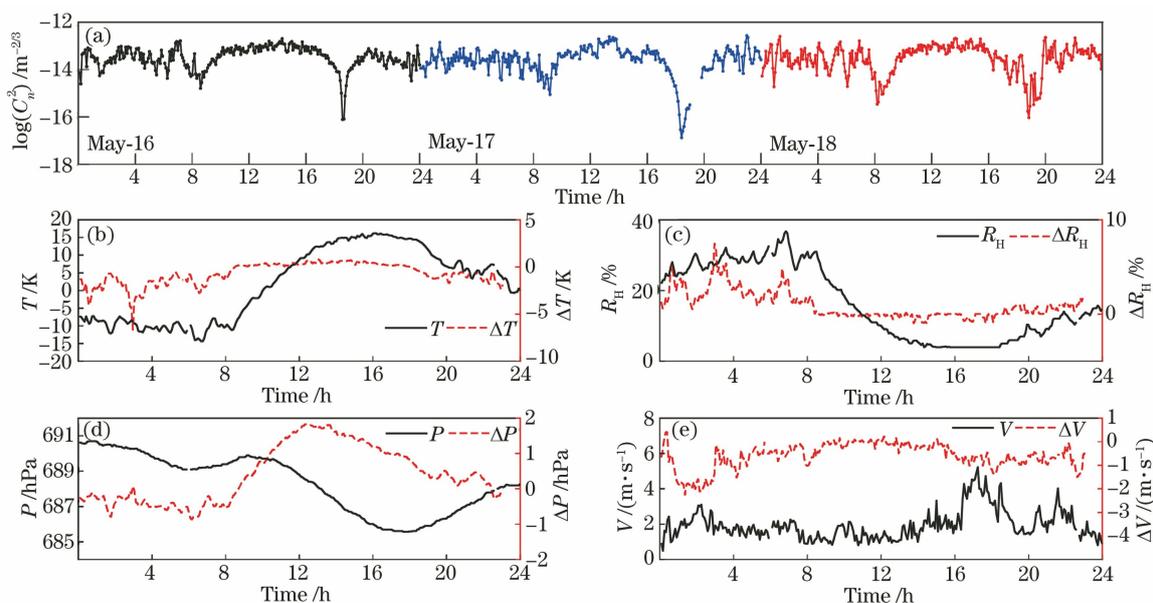


图 3  $C_n^2$  (2014 年 5 月 16 日至 18 日)和气象参数(2014 年 5 月 16 日)的日变化。

(a)  $C_n^2$ ; (b) 温度; (c) 相对湿度; (d) 气压; (e) 风速

Fig. 3 Daily evolution of  $C_n^2$  (16 to 18 May 2014) and meteorological parameters(16 May 2014).

(a)  $C_n^2$ ; (b) temperature; (c) relative humidity; (d) pressure; (e) wind speed

将 10 个备选特征输入至 MLP,此时 MLP 包含一个隐含层,隐含层中有 40 个神经元。图 4 为使用遗传算法选择特征时的计算结果,可以看出,随着遗传代数的增加, $C_n^2$  估计值和测量值的平均绝对误差逐渐减小,在 66 代以后平均绝对误差基本不变,染色体 1111111111 占主导地位,此时染色体对应的 MLP 模型估计值和测量值的平均绝对误差最小,该染色体即为最优。需要指出的是,多次尝试表明,遗传算法的随机初始化对结果没有影响,不同的初始实现均能得到上述同样的结论。

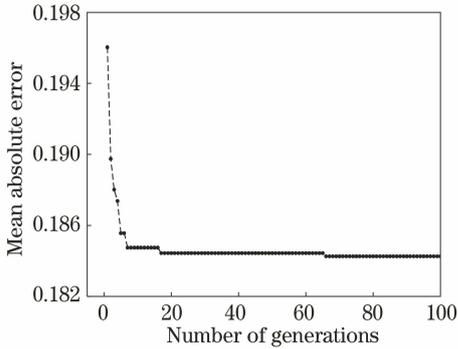


图 4 特征选择过程中遗传算法迭代计算结果  
Fig. 4 Iterative computation result of genetic algorithm in feature selection process

特征选择结果表明,10 个备选输入特征均应当确定为输入特征。(2)式中, $P$ 、 $T$  及  $\Delta T$  是  $C_n^2$  的直接计算参数,因而这 3 个参数的选择符合预期;由于光学湍流与风速切边、风速混合过程有关, $\Delta V$  表征上述物理过程;时刻参数的选择突出了  $C_n^2$  日变化时间信息的重要性;选择  $V$ 、 $R_H$ 、 $\Delta R_H$ 、 $D$  和  $\Delta P$ ,可能是因为它们日变化特征和  $C_n^2$  存在某种对应关系。

### 3.2 隐含层神经元的确定

给定输入特征和输出变量后,关键问题是确定 MLP 隐含层中的神经元个数。隐含层神经元的最

优个数取决于映射关系的复杂性。研究表明,增加隐含层中的神经元个数并不能提高 MLP 的性能,神经元过多会发生过拟合问题进而增加泛化误差。反之,神经元过少会发生欠拟合问题进而降低估计精度。目前,尚无标准的方法确定隐含层中的神经元个数,一种广泛应用的方法是交叉验证,即通过实现估计精度和泛化能力的平衡来确定神经元个数<sup>[21]</sup>。

根据交叉验证方法的思路,将观测点 1 的测量数据随机分为三个部分:训练集占 60%,验证集占 20%,测试集占 20%。训练集用于训练模型并给出估计误差,验证集给出模型的泛化误差并指导神经元的选择,测试集用于确定最终的模型误差。采用两个指标描述  $C_n^2$  测量值和估计值的误差,即平均绝对误差  $M_{AE}$  和拟合优度  $R^2$ ,定义分别为

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |Y_i - T_i|, \quad (4)$$

$$R^2 = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(T_i - \bar{T})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (T_i - \bar{T})^2}}, \quad (5)$$

式中: $Y_i$  和  $T_i$  分别为  $C_n^2$  实测值和估计值序列; $\bar{Y}$  和  $\bar{T}$  分别为相应的均值; $i$  为样本序号。

对机器学习算法而言,当训练集和验证集的估算误差最小时,算法的性能最优。当神经元个数较少时,MLP 的估算性能较低,估算误差较大;当神经元个数较多时,MLP 结构冗余度较大,估算误差随着神经元个数的增加而变大。交叉验证结果如图 5 所示,可以看出,当神经元个数为 40 时,训练集和验证集估算结果的平均绝对误差和拟合优度差别最小,表明,此时 MLP 的估算性能最佳,因而隐含层中的神经元个数确定为 40。

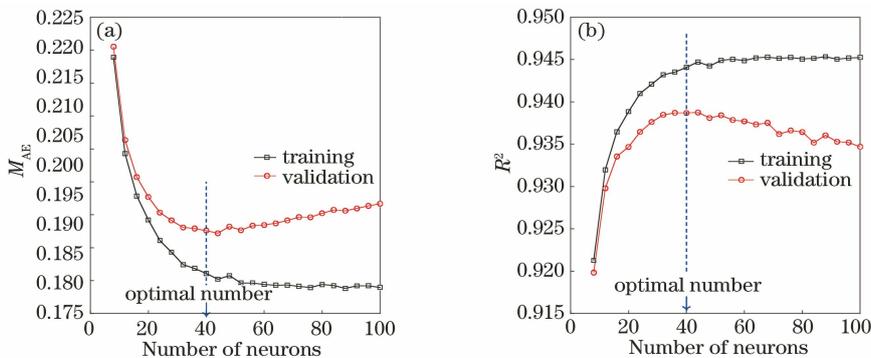


图 5 MLP 模型性能随神经元个数的变化。(a)  $M_{AE}$ ; (b)  $R^2$   
Fig. 5 Performance of MLP model varying with number of neurons. (a)  $M_{AE}$ ; (b)  $R^2$

## 4 结 果

通过特征选择和交叉验证过程,MLP 的结构最终确定为 10-40-1,即输入层包含 10 个特征,隐含层只有一层且包含 40 个神经元,输出层输出估算结果  $C_n^2$ 。用测试集评估 MLP 的性能。使用四个统计参数描述估计误差,平均绝对误差  $M_{AE}$  和方均根误差  $M_{SE}$  分别表征一阶和二阶绝对误差,平均相对误差  $M_{RE}$  表征相对误差,拟合优度  $R^2$  描述实测值和估计值的相关性。 $M_{SE}$  和  $M_{RE}$  的表达式分别为

$$M_{SE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - T_i)^2}, \quad (6)$$

$$M_{RE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - T_i}{T_i} \right| \times 100\%。 \quad (7)$$

计算结果表明, $C_n^2$  估计值和实测值的平均绝对误差、方均根误差、平均相对误差及拟合优度值分别为 0.19、0.27、1.34% 及 0.94。

图 6 为连续 32 天  $C_n^2$  估计值和实测值的日变化,其中实线是 1000 次估算结果的 50% 分位数,圆点表示实测值。可以看出:估算结果和实测值的变化趋势高度一致;两者在白天差别较小,在夜间部分时段差别较大,在“转换时刻”, $C_n^2$  的部分估计值较大。夜间和早晚“转换时刻”, $C_n^2$  变化剧烈,出现剧烈变化的极值,此时 MLP 对极值的估算能力较弱。

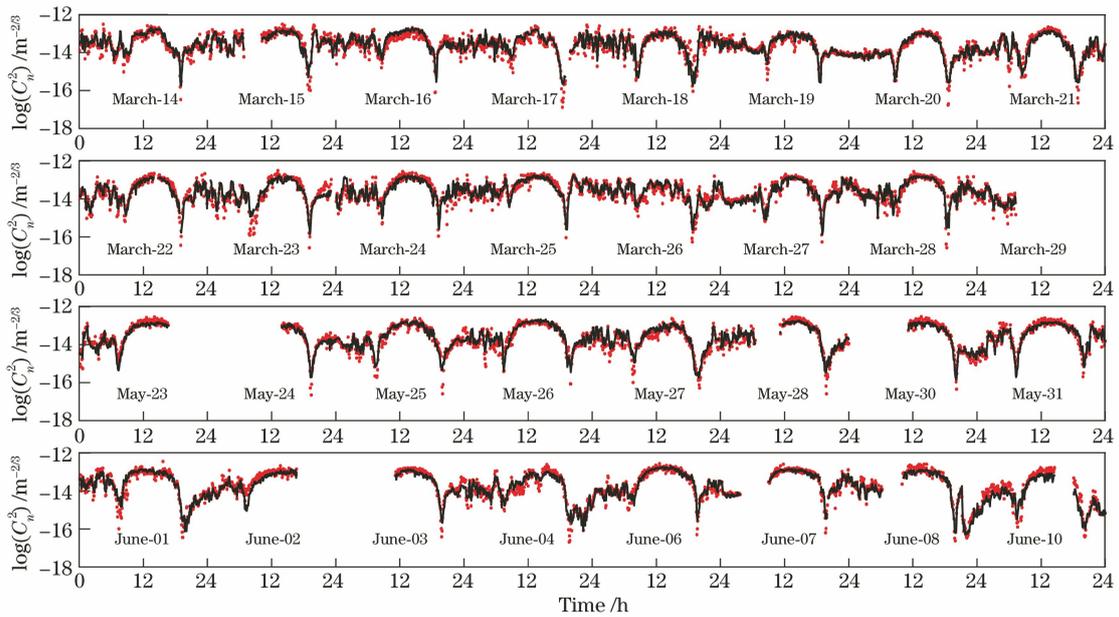


图 6 观测点 1 处  $C_n^2$  估计值和实测值

Fig. 6 Estimated value and measured value of  $C_n^2$  in observation point 1

将图 6 中 32 天的数据分为白天、夜间及转换时刻 3 个时段,图 7 对三个时段的  $C_n^2$  估计值和实测

值进行比较。两者的拟合优度在夜间为 0.88,在白天为 0.86,在转换时刻为 0.87。文献[11]中,拟合

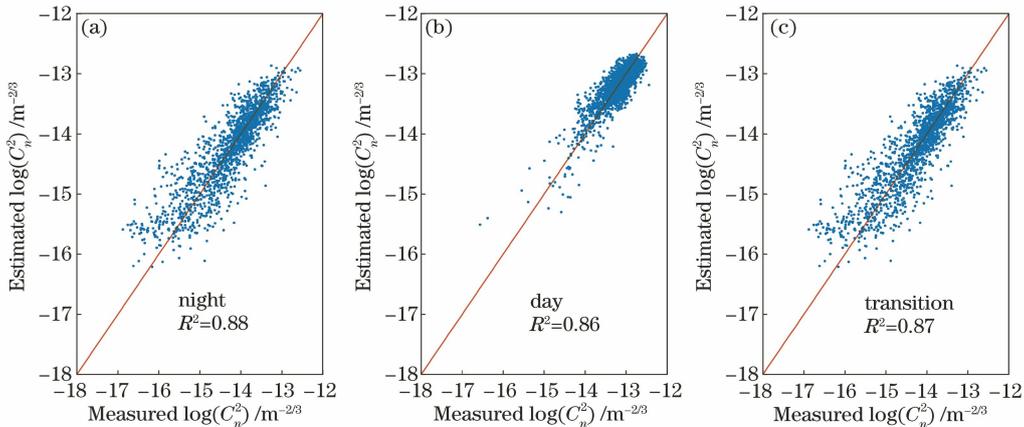


图 7 夜间、白天和转换时刻下  $C_n^2$  估计值和实测值

Fig. 7 Estimated value and measured value of  $C_n^2$  in nighttime, daytime, and transition time

优度在弱/中性稳定的夜间为 0.87, 白天为 0.83, 强稳定的夜间为 0.63。可见, 对 MLP 的输入特征进行选择, 对模型结构进行优化有助于提高 MLP 的性能。

上文对观测点 1 的实测数据进行训练并建立了 MLP, MLP 可以通过常规气象参数可靠地估算观测点 1 的  $C_n^2$ 。将观测点 2 的常规气象参数引入已建立的 MLP,  $C_n^2$  估计值和实测值对比如图 8 所示,

实线是估计值, 圆点是实测值。可以看出, 两者变化趋势基本一致, 但估计值普遍大于实测值, 两者平均相对误差为 4.8%。由于 MLP 所建立的输入-输出映射关系取决于当地的气象参数和  $C_n^2$ , 不同地区地理环境和大气特性不同, 会影响气象参数和  $C_n^2$  的映射关系, 而已建 MLP 的 10 个输入特征均为局地大气参数, 并未包含当地宏观地理气象参数, 使 MLP 模型具有地区依赖性。

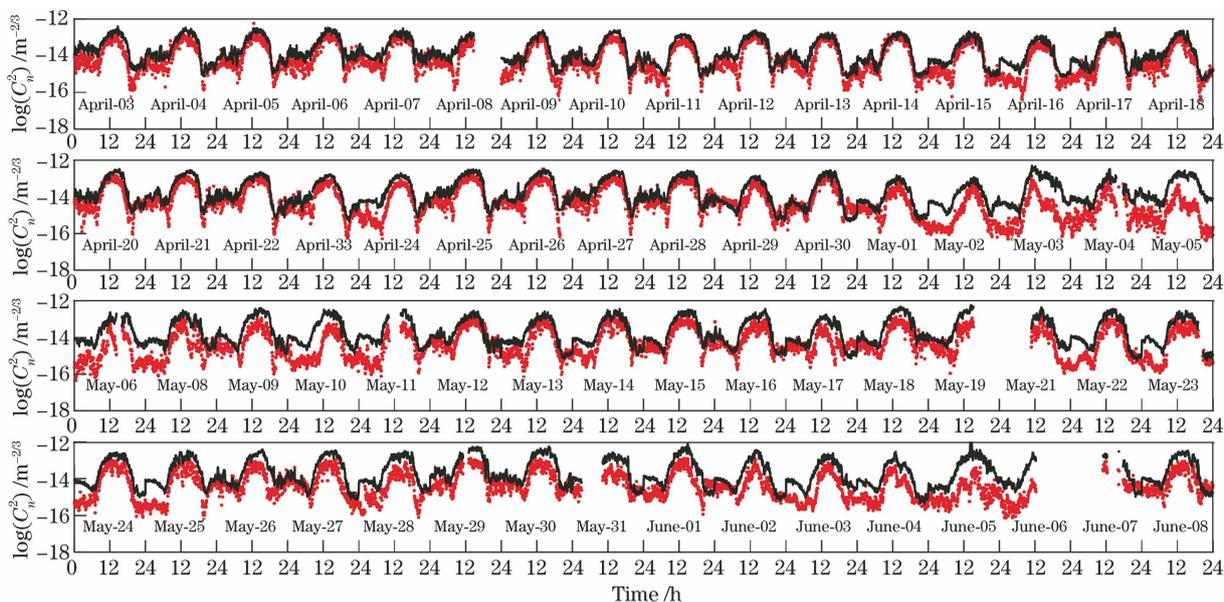


图 8 观测点 2 处  $C_n^2$  估计值和实测值

Fig. 8 Estimated value and measured value of  $C_n^2$  in observation point 2

## 5 结 论

使用人工神经网络估算近地面光学湍流强度  $C_n^2$ 。通过训练大量实测气象数据建立了 MLP, 对 MLP 模型的结构和输入特征进行优化, 并分析了 MLP 的估算精度和泛化能力。1) 使用遗传算法对输入特征进行选择, 最终确定温度、气压、相对湿度、风速、风向、温差、气压差、相对湿度差、风速差、时刻共 10 个输入参数。通过交叉验证确定隐含层中的神经元个数, 结果表明, 当神经元个数为 40 时, 训练集和测试集的估算精度差别较小, 此时模型性能达到最优。优化后的 MLP 结构包括 10 个输入特征、40 个神经元及 1 个输出。2) 评估了 MLP 的估算精度和泛化能力。观测点 1 数据建立的 MLP 对当地的  $C_n^2$  估计精度较高,  $C_n^2$  估计值和实测值的平均绝对误差、方均根误差、平均相对误差及拟合优度分别为 0.19、0.27、1.34% 及 0.94。观测点 1 数据建立的 MLP 对其他地区的  $C_n^2$  估计精度较低, MLP 估计值普遍大于实测值, 表明 MLP 的泛化能力有待

提高。

人工神经网络通过自适应训练算法, 建立常规气象参数和光学湍流强度的映射关系, 能够实现对  $C_n^2$  的精确估算, 然而此方法的泛化能力有待提高。下一步, 可引入海拔、地形等宏观参数作为输入, 提高 MLP 在不同地区的适用性。同时, 可尝试在昼夜模型和转换时刻模型下对 MLP 进行训练, 或使用其他神经网络结构提高模型的估算精度和泛化能力。

## 参 考 文 献

- [1] Smith F G. Atmospheric propagation of radiation [M]//Beland R R. Propagation through atmospheric optical turbulence. Bellingham: SPIE, 1993: 159-232.
- [2] Andrews L C, Phillips R L. Laser beam propagation through random media [M]. 2nd ed. Bellingham: SPIE, 2005.
- [3] Luo C K, Lu F, Miao Z F, et al. Propagation and spreading of radial vortex beam array in atmosphere

- [J]. *Acta Optica Sinica*, 2019, 39(6): 0601004.  
 骆传凯, 卢芳, 苗志芳, 等. 径向阵列涡旋光束在大气中的传输与扩展[J]. *光学学报*, 2019, 39(6): 0601004.
- [4] Ge X L, Yue X F, Wang B Y, et al. Beam spreading and phase singularities' behavior of non-diffracting vortex beams through turbulent atmosphere[J]. *Acta Optica Sinica*, 2019, 39(9): 0901001.  
 葛筱璐, 岳喜福, 王本义, 等. 湍流大气中无衍射涡旋光束的展宽及相位奇点的演化[J]. *光学学报*, 2019, 39(9): 0901001.
- [5] Wyngaard J C, Izumi Y, Collins S A. Behavior of the refractive-index-structure parameter near the ground [J]. *Journal of the Optical Society of America*, 1971, 61(12): 1646-1650.
- [6] Kunkel K E, Walters D L. Modeling the diurnal dependence of the optical refractive index structure parameter [J]. *Journal of Geophysical Research: Oceans*, 1983, 88(C15): 10999-11004.
- [7] He P, Nunalee C G, Basu S, et al. Current status and challenges in optical turbulence simulations in various layers of the Earth's atmosphere [J]. *Proceedings of SPIE*, 2014, 9224: 92240F.
- [8] He P, Basu S. Extending a surface-layer  $C_n^2$  model for strongly stratified conditions utilizing a numerically generated turbulence dataset[J]. *Optics Express*, 2016, 24(9): 9574-9582.
- [9] Wang P, Wu X Q. Experimental study of effects of humidity fluctuation on the refractive index structure parameter for visible radiation [J]. *Acta Optica Sinica*, 2014, 34(4): 0401003.  
 汪平, 吴晓庆. 湿度起伏对可见光折射率结构常数影响的实验研究 [J]. *光学学报*, 2014, 34(4): 0401003.
- [10] Zhang C Y, Weng N Q, Gao H, et al. Research and theoretical simulation on the optical-wave refractive-index structure constant using wind profile radar[J]. *Acta Optica Sinica*, 2013, 33(3): 0301004.  
 张彩云, 翁宁泉, 高慧, 等. 基于风廓线雷达的光波段折射率结构常数方法研究与理论仿真[J]. *光学学报*, 2013, 33(3): 0301004.
- [11] 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.
- [12] 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.
- [13] Gardner M W, Dorling S R. Artificial neural networks (the multilayer perceptron): a review of applications in the atmospheric sciences [J]. *Atmospheric Environment*, 1998, 32(14/15): 2627-2636.
- [14] Hu Y H, Hwang J N. *Handbook of neural network signal processing*[M]. London: CRC Press, 2018.
- [15] Yee E, Ho J. Neural network recognition and classification of aerosol particle distributions measured with a two-spot laser velocimeter [J]. *Applied Optics*, 1990, 29(19): 2929-2938.
- [16] Guo H, Korablinova N, Ren Q S, et al. Wavefront reconstruction with artificial neural networks [J]. *Optics Express*, 2006, 14(14): 6456-6462.
- [17] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators [J]. *Neural Networks*, 1989, 2(5): 359-366.
- [18] 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.
- [19] Hefei Institute of Physical Science, Chinese Academy of Sciences. *Micro-thermal meter: Q/HY 09—2017* [S]. Hefei: Hefei Institute of Physical Science, Chinese Academy of Sciences, 2017.  
 中国科学院合肥物质科学研究院. *温度脉动仪: Q/HY 09—2017* [S]. 合肥: 中国科学院合肥物质科学研究院, 2017.
- [20] Wang X P, Cao L M. *Genetic algorithm: theory, application and implementation of software*[M]. Xi'an: Xi'an Jiaotong University Press, 2002.  
 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.
- [21] Li H. *Methods of statistical learning*[M]. Beijing: Tsinghua University Press, 2012.  
 李航. *统计学习方法* [M]. 北京: 清华大学出版社, 2012.