

基于深度卷积神经网络的大气湍流强度估算

马圣杰^{1,2},郝士琦^{1,2*},赵青松^{1,2},王勇^{1,2},王磊^{1,2}

¹国防科技大学脉冲功率激光技术国家重点实验室,安徽 合肥 230037; ²电子制约技术安徽省重点实验室,安徽 合肥 230037

摘要 提出了一种基于深度卷积神经网络估算大气湍流折射率结构常数 C_n^2 的方法。将湍流影响下的高斯光束光 斑图像作为神经网络的输入,利用深度卷积神经网络提取图像的特征信息,得到 C_n^2 大小,并采用平均绝对误差、平 均相对误差、均方根方差和相关系数四个统计量来衡量模型的估算效果。结果表明,该模型能够根据湍流影响下 的高斯光束光斑图像对 C_n^2 进行估算,当迭代 500 次时,相关系数为 99.84%,各项误差均在 2%左右。该模型在大 气湍流特性分析及大气湍流强度估算等领域有一定应用价值。

1 引 言

当激光在大气中传输时,由大气湍流引起的折 射率随机起伏^[1]破坏了激光光束的相干性,导致激 光发生光强起伏、光束漂移、光束扩展和到达角起伏 等现象^[2-3],使得激光光束质量下降。因此,了解大 气湍流的性质具有重要意义。通常采用折射率结构 常数 C_n^2 衡量大气湍流强度,以进一步分析大气湍 流对激光传播的影响。

仪器测量和模式估算是获取 C_n^2 时空分布的两种最常用方法。Wyngaard 等^[4] 首次引入了温度结构常数 C_T^2 以间接估算 C_n^2 。Friehe 等^[5] 引入温度-水汽互相关结构常数 C_{Tq} ,并证明了 C_{Tq} 对 C_n^2 的贡献率高达 24%。Davidson 等^[6]利用 bulk 方法估算了海洋表面的 C_n^2 。Andreas^[7] 根据 MOS 理论,并结合 Wyngaard 等得到的 C_T^2 与高度的经验函数,对雪面及海面上的 C_n^2 进行了估算。然而,上述方法在中性和稳定大气条件下的误差较大。20 世纪 90 年代以后出现了利用数值预报模式对 C_n^2 进行估算的方法。Frehlich 等^[8] 基于 WRF 模式对 C_n^2 进行了估算,并与高空测量结果进行了对比,估算结果与原始数据吻合较好。青春等^[9-11]使用 WRF 模式对

不同地点的 C²_n 进行了估算,并与探空气球测量的 数据进行了对比,结果显示,垂直廓线方向上的估算 结果与探空气球测量数据具有较好的吻合度。

近些年,机器学习算法被广泛应用于气象等领域。Wang等^[12]使用人工神经网络,将温度、相对湿度等气象参数作为神经网络的输入,对 Mauna Loa 附近海面的 C_n^2 进行了估算,结果表明该方法能够较为准确地估算出湍流强度,突出了人工神经网络估算 C_n^2 的优势。吕洁^[13]采用 BP 神经网络对成都地区和青海省德令哈地区的 C_n^2 进行了估算,但估算精度有待提高。

本文提出了一种利用大气湍流影响下的高斯光 束光斑图像估算 C²_n的方法。该方法将大气湍流影 响下的高斯光束光斑图像作为神经网络的输入,通 过大量训练获得了网络模型,利用深度卷积神经网 络强大的数据拟合与图像处理能力,完成了从图像 到 C²_n数值的估算。在实际应用中,可以用相机接 收不同强度大气湍流影响下的高斯光束光斑图像, 并通过仪器测量对应的 C²_n以建立数据集,进而对 神经网络进行训练得到网络模型。将湍流影响下的 高斯光束光斑图像作为神经网络的输入即可估算出

*E-mail: liu_hsq@126.com

收稿日期: 2020-06-28; 修回日期: 2020-07-22; 录用日期: 2020-08-10

基金项目:国家自然科学基金(61571446,61671454)

研究论文

第 48 卷 第 4 期/2021 年 2 月/中国激光

对应的 C²_n,为估算大气湍流强度提供了一种新 思路。

2 大气湍流对激光传播的影响

2.1 大气湍流模拟

通过数值仿真生成随机相位屏以模拟湍流环境,进而研究大气湍流影响下的激光传输^[14]。根据 波前相位表达式的不同,生成随机相位屏的方法可 以分为两类^[15-16],即功率谱反演法和 Zernike 多项 式法。相比于 Zernike 多项式法,功率谱反演法具 有可操作性强、结构简单、计算速度快等优点,因此 本文采用功率谱反演法生成随机相位屏,并结合多 相位屏模型模拟激光在大气湍流中的传播。如图 1 所示,在多相位屏模型中,高斯光束在两个相位屏之 间的传播可以看成是真空中的传播,当高斯光束经 过某一相位屏时,之前所有的相位扰动会叠加到当 前的波前上,直至传播到最后一个相位屏上。功率 谱反演法的基本思想是用一对复高斯随机数矩阵对 大气湍流的功率谱进行滤波,然后进行逆傅里叶变 换得到大气扰动相位^[17]:

$$\varphi(x,y) = C \sum_{k} \sum_{k} R(K_{x},K_{y}) \sqrt{F_{\varphi}(K_{x},K_{y})} \exp\left[j(K_{x}x+K_{y}y)\right] , \qquad (1)$$

式中:空域内 $x = m \Delta x$, $y = n \Delta y$, $\Delta x \setminus \Delta y$ 为取样间 隔, $m \setminus n$ 为整数; 波数域内 $K_x = m' \Delta K_x$, $K_y = n' \Delta K_y$, $\Delta K_x \setminus \Delta K_y$ 为取样间隔, $m' \setminus n'$ 为整数; C 为常数; $R(K_x, K_y)$ 为零均值单位方差的高斯随 机数; $F_{\varphi}(K_x, K_y)$ 是由大气折射率起伏引起的相 位畸变的近似功率谱密度。在各向同性的湍流环 境下, 通常采用 Kolmogorov 模型作为折射率功 率谱:

$$\Phi_{n}(K,z) = 0.033C_{n}^{2}(z)K^{-11/3}, \qquad (2)$$

式中:C²_n(z)为传播方向上的折射率结构常数;K 为 三维空间波数。与 z 轴方向垂直的任意薄层切片 上的大气相位功率谱为

 $F_{\varphi}(K_{r}) = 2\pi k^{2} \times 0.033 K_{r}^{-11/3} \int_{z}^{z+\Delta z} C_{n}^{2}(\xi) d\xi$, (3) 式中: k 为波数; z 为高斯光束传播距离; Δz 为相邻



phase screen



2.2 湍流影响下的高斯光束

为了模拟高斯光束在大气湍流中的传输,采用 基模高斯光束并假设光束沿 z 轴方向传播,高斯光 束的光场表达式为

$$E_{00}(r,z) = \frac{E_0}{w(z)} \exp\left\{\frac{-r^2}{w^2(z)} - j\left\{k\left[z + \frac{r^2}{2R(z)}\right] - \arctan\frac{z}{f}\right\}\right\},\tag{4}$$

式中: E_0 为常数; $r^2 = x^2 + y^2$,其中(x, y)为点坐标;波数 $k = 2\pi/\lambda$,其中 λ 为波长;高斯光束的共焦参数 $f = \frac{\pi w_0^2}{\lambda}$,其中 w_0 为高斯光束的腰斑半径;传播距离为 z 时高斯光束等相位面上的光斑半径

 $w(z) = w_0 \sqrt{1 + (\frac{z}{f})^2}$;传播距离为 z 时高斯光束等 相位面的曲率半径 $R(z) = z + \frac{f^2}{z}$ 。根据多相位屏模 型,高斯光束经过 j + 1 个相位屏后的光场表达式为

$$E(r, z_{j+1}) = f^{-1} \left\{ f \left\{ E(r, z_j) \exp[j\varphi_{j+1}(x, y)] \right\} \times \exp(-j \frac{K_x^2 + K_y^2}{2k} \Delta z_{j+1}) \right\},$$
(5)

式中: $E(r,z_{j})$ 为第 j 个相位屏处的光场; z_{j+1},z_{j} 分 别为第 j+1 个和第 j 个相位屏的位置; $\Delta z_{j+1} = z_{j+1} - z_{j}; f(g)$ 和 $f^{-1}(g)$ 分别为傅里叶变换和傅里 叶逆变换;*φ_{j+1}(x*,*y*)为第*j*+1个相位屏造成的相位 扰动。根据(5)式可以仿真得到大气湍流影响下的 高斯光束光斑图像,具体仿真参数如表1所示。

研究论文

Table 1 Simulation parameters						
Parameter	Simulation value					
λ /nm	632.8					
w_0/cm	2					
z /m	1000					
$\Delta x / \mathrm{cm}$	0.04					
Number of grid elements	768					
Width of phase screen $L\ /m$	0.5					
Distance of phase screen l /m	200					
$C_{ m n}^{2}/{ m m}^{-2/3}$	$1.0 \times 10^{-16} - 1.0 \times 10^{-13}$					

表 1 仿真参数 Table 1 Simulation perometer

冬	2(a)	为未	:受湍	流影	响的	」标准	高斯	光束	的	光
---	------	----	-----	----	----	-----	----	----	---	---

斑图像,图 2 (b)~(g)为不同 C_n^2 影响下的高斯光 束光斑图像。可以看出,标准高斯光束的光斑图像 呈现规则的圆形,湍流影响下的高斯光束光斑分布 不再均匀。从光斑的变化趋势可以看出,光斑畸变 程度随着湍流强度的增强而增加。当湍流强度较小 时,如图 2(b)、(c)所示,高斯光束光斑中心区域受 到的影响较小,只有边缘有轻微程度的畸变,此时光 斑形状仍大致保持圆形;随着湍流强度的增大,高斯 光束中心也发生轻微程度的畸变,边缘部分的畸变 程度增加,此时光斑形状也发生改变,不再呈现圆 形;当 C_n^2 增加到 10^{-14} m^{-2/3} 数量级时,边缘部分发 生了严重的畸变,光斑形状难以辨认,湍流对高斯光 束的影响非常大。



图 2 标准高斯光束及不同强度大气湍流影响下的高斯光束光斑图像。(a)标准高斯光束;(b) $C_n^2 = 1.0083 \times 10^{-16} \text{ m}^{-2/3}$; (c) $C_n^2 = 3.4093 \times 10^{-16} \text{ m}^{-2/3}$;(d) $C_n^2 = 3.2796 \times 10^{-15} \text{ m}^{-2/3}$;(e) $C_n^2 = 8.1228 \times 10^{-15} \text{ m}^{-2/3}$;(f) $C_n^2 = 2.6489 \times 10^{-14} \text{ m}^{-2/3}$;(g) $C_n^2 = 9.7925 \times 10^{-14} \text{ m}^{-2/3}$

Fig. 2 Spot images of standard Gaussian beam and Gaussian beams under influence of atmospheric turbulence with different intensities. (a) Standard Gaussian beam; (b) $C_n^2 = 1.0083 \times 10^{-16} \text{ m}^{-2/3}$; (c) $C_n^2 = 3.4093 \times 10^{-16} \text{ m}^{-2/3}$; (d) $C_n^2 = 3.2796 \times 10^{-15} \text{ m}^{-2/3}$; (e) $C_n^2 = 8.1228 \times 10^{-15} \text{ m}^{-2/3}$; (f) $C_n^2 = 2.6489 \times 10^{-14} \text{ m}^{-2/3}$; (g) $C_n^2 = 9.7925 \times 10^{-14} \text{ m}^{-2/3}$

3 基于深度卷积神经网络的 C_n^2 估算

3.1 VGG16 模型

根据上述分析,大气湍流对高斯光束的影响相 当于附加了一个相位扰动项,文献[18]利用深度卷 积神经网络对大气湍流影响下的高斯光束光斑图像 进行了相位提取。在此基础上,本文提出了一种基 于深度卷积神经网络的 C² 估算方法,将大气湍流 影响下的高斯光束光斑图像作为神经网络的输入, 利用深度卷积神经网络对湍流影响下的高斯光束光 斑图像进行特征提取并得到 C² 。

深度卷积神经网络在卷积神经网络的基础上增 加了神经网络的深度,在图像处理方面更有优势。 本文采用的 VGG16 模型是由牛津大学 VGG 团队 提出的,该模型在 2014 年 ImageNet 竞赛定位任务 中获得第一名,在分类任务中获得第二名。如图 3 所示,VGG16 模型是由 13 个卷积层和 3 个全连接 层叠加而成的。VGG16 模型的输入为湍流影响下 的高斯光束光斑图像,输入图像大小为 224×224。 当输入图像 经过 2 个 3×3 大小的卷积层 (convolution)后,得到大小为 224×224 的特征图; 经过最大池化层(max pooling)后得到大小为 112× 112 的特征图,经过 2 个 3×3 大小的卷积层后,得 到大小为 56×56 的特征图,经过 3 个 3×3 大小的 卷积层后,得到大小为56×56的特征图;经过最大

第 48 卷 第 4 期/2021 年 2 月/中国激光



图 3 VGG16 模型结构 Fig. 3 Structure of VGG16 model

池化层后得到大小为 28×28 的特征图,经过 3 个 3× 3 大小的卷积层后,得到大小为 28×28 的特征图; 经过最大池化层后得到大小为 14×14 的特征图,经 过 3 个 3×3 大小的卷积层后,得到大小为 14×14 的特征图;经过最大池化层后得到大小为 7×7 的特 征图,并与之后的 3 个全连接层(fully connected layer)相连,最后由 softmax 层得到输出结果。神经 网络模型中激活函数选取 Relu函数。

3.2 VGG16 估算结果及分析

本文随机选取 $1.0 \times 10^{-16} \sim 1.0 \times 10^{-13} \text{ m}^{-2/3}$ 范围内的 C_n^2 ,并得到对应的湍流影响下的高斯光束 光斑图像。选取 3000 张图像作为训练集进行训练 以得到网络模型,选取 300 张图片作为测试集以分 析模型的训练效果。为了衡量估算结果的可靠性, 本文选取平均绝对误差(E_{MAE})、平均相对误差 (E_{MRE})、均方根方差(E_{RMSE})以及相关系数(R_{xy})四 个统计量作为衡量依据,具体计算公式^[19]为

$$E_{\text{MAE}} = \sum_{i=0}^{N} \frac{|\Delta i|}{N}, \qquad (6)$$

$$E_{\rm MRE} = \sum_{i=0}^{N} \frac{E_{\rm MAE}}{\left|\sum_{i=0}^{N} \left(\frac{x_i}{N}\right)\right|} \times 100\%, \qquad (7)$$

$$E_{\text{RMSE}} = \sqrt{\sum_{i=0}^{N} \frac{(\Delta i)^2}{N}}, \qquad (8)$$

$$R_{xy} = \frac{\sum_{i=0}^{N} (x_i - \bar{x}) (y_i - \bar{y})}{\sqrt{\sum_{i=0}^{N} (x_i - \bar{x})^2 \sum_{i=0}^{N} (y_i - \bar{y})^2}}, \quad (9)$$

式中: $\Delta i = y_i - x_i$ 为第*i*个实际值 y_i 与对应估算值 x_i 之间的误差; \overline{x} 为 x_i 的平均值; \overline{y} 为 y_i 的平均 值;N为数据的个数。

图 4 为 VGG16 模型下估算值与实际值的散点

图、累积概率分布图和频率分布直方图。对比 图 4(a1)、(b1)、(c1)、(d1)可以看出,随着迭代次数 的增加,模型估算结果与实际值之间的相关性逐渐 增加。当迭代次数为1时,数据之间的相关性并不 是很高,散点图分布比较杂乱,模型的训练结果不是 很理想;当迭代次数为10时,数据之间的相关性有 所增加,但此时大部分数据在虚线以下,表明此时模 型的估算值要小于实际值,虽然估算结果有一定提 高,但仍未达到理想效果;当迭代次数为20时,散点 图更接近虚线,数据之间的相关性得到进一步提高, 模型训练效果得到优化;当迭代次数增加到 500 时, 散点图近似呈直线,与虚线几乎重合,此时估算结果 与实际值之间的差距较小,模型较为理想。从频率分 布直方图和累积概率分布图可以看出,当迭代次数较 小时,频率分布直方图参差不齐,累积概率曲线之间 的差距较为明显,估算值和实际值之间的误差较大; 随着迭代次数的逐渐增加,频率分布直方图越来越平 坦,累积概率曲线之间的差距也逐渐减小;当迭代次 数为500时,估算值与实际值的频率分布几乎一致, 且累积概率曲线几乎重合,模型估算结果较为可靠。

分析图 4(b1)、(c1)可以得到,当迭代次数不大时, 随着湍流的增强,散点图偏离虚线的程度增加,强湍流 条件下的估算误差大于弱湍流和中等强度湍流条件下 的估算误差;随着迭代次数的增加,强湍流条件下的估 算结果得到了改善,散点图与虚线之间的差距减小。

表 2 为不同迭代次数下的四个统计量的计算结 果,随着迭代次数的增加, E_{MAE}、E_{MRE}和 E_{RMSE}都逐 渐减小;当迭代次数为 20 时, E_{MAE}、E_{MRE}和 E_{RMSE} 基本上都控制在 5% 左右, 相关系数已经达到了 99.24%;当迭代次数为 500 时, 各项误差进一步减 小到 2% 左右, 相关系数进一步增加到 99.84%, 此 时模型估算结果较为理想。



图 4 VGG16 模型下 lg C_n² 估算值与实际值的散点图、频率分布直方图和累积概率分布图。(a1)(a2)(a3)迭代 1次; (b1)(b2)(b3)迭代 10次;(c1)(c2)(c3)迭代 20次;(d1)(d2)(d3)迭代 500次

Fig. 4 Scatter plots, frequency distribution histograms, and cumulative probability distribution diagrams of estimation value and actual value of lg C²_n by VGG16 model. (a1) (a2) (a3) Number of iterations is 1; (b1) (b2) (b3) number of iterations is 10; (c1) (c2) (c3) number of iterations is 20; (d1) (d2) (d3) number of iterations is 500

第 48 卷 第 4 期/2021 年 2 月/中国激光

表 2	不同迭代次数下 VGG16 模型的四个统计量
Table 2	Four statistics of VGG16 model under different
	numbers of iterations

Number of iterations	$E_{\rm MAE}$	$E_{\rm MRE}$	$E_{\rm RMSE}$	R_{xy}
1	0.0845	0.1635	0.1099	92.32%
10	0.0432	0.0837	0.0577	98.16%
20	0.0272	0.0527	0.0349	99.24%
500	0.0133	0.0258	0.0171	99.84%

为了进一步验证该方法的可行性,降低随机性 对估算效果的影响,将同一湍流强度下不同时刻的 高斯光束光斑图像作为测试集,对 VGG16 神经网 络的估算效果进行分析。当 C_n^2 分别为 1.0× 10^{-16} ,1.0×10⁻¹⁵,1.0×10⁻¹⁴,1.0×10⁻¹³ m^{-2/3} 时,对估算结果的标准差进行计算,结果如表 3 所 示,可以看出,VGG16 神经网络在弱湍流条件下的 估算效果较好,而在强湍流条件下的估算效果较差。

表 3 不同湍流强度下估算结果的标准差

Table 3 Standard deviation of estimation results under

different turbulence intensities

$C_{ m n}^2$	$1.0 \times 10^{-16} m^{-2/3}$	$1.0 \times 10^{-15} m^{-2/3}$	$1.0 \times 10^{-14} m^{-2/3}$	$1.0 \times 10^{-13} \text{ m}^{-2/3}$
Standard deviation	0.071	0.0996	0.1453	0.2669

3.3 VGG16 模型估算效果与 AlexNet 模型估算效 果的对比

为了验证基于深度卷积神经网络的方法在估算 大气湍流强度方面的优势,本文用传统的 AlexNet 神经网络模型对 C²_n进行估算,并进行对比分析。 AlexNet 模型是由 5 个卷积层、3 个全连接层和 1 个 Softmax 层组成,因此在网络结构上 VGG16 的 结构更为具体,且 VGG16 模型用多个 3×3 大小的 卷积核代替 AlexNet 模型中 7×7 大小的卷积 核^[20],能够更好地保留图像的性质,并且在保证具 有相同感知野的条件下,增加了网络的深度,系统能 学习更复杂的模式^[21]。

AlexNet模型的估算结果如图 5 所示。对比 图 4、5 可得,在相同迭代次数下,VGG16 模型的估 算结果具有更好的相关性,AlexNet 神经网络的估 算效果不如 VGG16。表 4 为 AlexNet 模型在不同 迭代次数下的四个统计量,结果表明,当迭代次数为 500 时,AlexNet 模型也能很好地对 C²_n进行估算, 但迭代次数较小时估算效果不是很理想。表 5 为两 种模型在相同迭代次数下的四个统计量的对比,可 以看出,在相同的迭代次数下,VGG16 模型三种误 差的大小几乎为 AlexNet 模型相同误差的一半,这 充分证明了深度卷积神经网络在图像处理领域的优 势;从相关性的角度来看,VGG16 模型得到的结果 有更高的相关系数。结果表明,相对于传统的 AlexNet 神经网络,VGG16 模型在湍流强度估算上 更具优势。 表 4 不同迭代次数下 AlexNet 模型的四个统计量

Number of iterations	$E_{\rm MAE}$	$E_{\rm MRE}$	$E_{\rm RMSE}$	R_{xy}
1	0.1902	0.3682	0.2325	59.38%
10	0.0866	0.1677	0.1149	94.80%
20	0.0691	0.1338	0.0856	97.41%
500	0.0269	0.0522	0.0340	99.27%

表 5	不同迭	代次数日	「两种	模型的	四个统计量
-----	-----	------	-----	-----	-------

Table 5 Four statistics of two models under different numbers of iterations

Number of iterations	Model	$E_{\rm MAE}$	$E_{\rm MRE}$	$E_{\rm RMSE}$	$R_{_{xy}}$
1	AlexNet	0.1902	0.3682	0.2325	59.38%
	VGG16	0.0845	0.1635	0.1099	92.32%
10	AlexNet	0.0866	0.1677	0.1149	94.80%
	VGG16	0.0432	0.0837	0.0577	98.16%
20	AlexNet	0.0691	0.1338	0.0856	97.41%
	VGG16	0.0272	0.0527	0.0349	99.24%
500	AlexNet	0.0269	0.0522	0.0340	99.27%
	VGG16	0.0133	0.0258	0.0171	99.84%

综合以上分析,可以看出,基于深度卷积神经网络估算大气湍流强度的方法是可行的。相比于传统的 AlexNet 网络模型,深度卷积神经网络在湍流强度估算上更具优势。随着迭代次数的增加, E_{MRE} 和 E_{RMSE} 逐渐减小,相关性越来越高,各项误差也都能控制在较小的数值范围内。



图 5 AlexNet 模型下 lg C²_n 估算值与实际值的散点图、频率分布直方图和累积概率分布图。(a1)(a2)(a3)迭代 1次;(b1) (b2)(b3)迭代 10次;(c1)(c2)(c3)迭代 20次;(d1)(d2)(d3)迭代 500次

Fig. 5 Scatter plots, frequency distribution histograms, and cumulative probability distribution diagrams of estimation value and actual value of lg C_n² by AlexNet model. (a1) (a2) (a3) Number of iterations is 1; (b1)(b2)(b3) number of iterations is 10; (c1)(c2)(c3) number of iterations is 20; (d1)(d2)(d3) number of iterations is 500

4 结 论

提出了一种基于深度卷积神经网络估算 C² n 方法,将湍流影响下的高斯光束光斑图像作为深度 卷积神经网络的输入,利用卷积层逐层提取图像的 特征信息,再经过大量数据集的训练,得到网络模 型,进而估算出 C² 的大小。相比于传统的 AlexNet 神经网络,VGG16 模型采用更小尺寸的卷积核,能 够更好地保留图像的特征,在图像的特征提取上更 具优势,估算效果更好。因此,可以通过进一步优化 神经网络结构来提高估算效果,这为湍流强度的估 算提供了一种新思路。

参考文献

- [1] Liu M W, Li Y C. Propagation of OFDM-OAM optical signal in atmospheric turbulence [J]. Acta Optica Sinica, 2019, 39(7): 0706002.
 刘旻雯,李迎春. OFDM-OAM 光信号在大气湍流中的传输[J]. 光学学报, 2019, 39(7): 0706002.
- [2] Zhang D X, Chen Z B, Xiao C, et al. Generation of high-precision turbulence phase screen based on modified atmosphere spectrum [J]. Acta Photonica Sinica, 2020, 49(6): 0601002.
 张冬晓,陈志斌,肖程,等.基于修正大气谱的湍流 相位屏高精度生成方法[J].光子学报, 2020, 49 (6): 0601002.
- [3] Wang F, Yu J Y, Liu X L, et al. Research progress of partially coherent b eams propagation in turbulent atmosphere[J]. Acta Physica Sinica, 2018, 67(18): 184203.

王飞,余佳益,刘显龙,等.部分相干光束经过湍流 大气传输研究进展[J].物理学报,2018,67(18): 184203.

- [4] 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.
- [5] Friehe, C A, La Rue J C, Champagne F H, et al. Effects of temperature and humidity fluctuations on the optical refractive index in the marine boundary layer[J]. Journal of the Optical Society of America, 1975, 65(12): 1502-1511.
- [6] Davidson K L, Schacher G E, Fairall C W, et al. Verification of the bulk method for calculating overwater optical turbulence [J]. Applied Optics, 1981, 20(17): 2919-2924.
- [7] Andreas E L. Estimating C_n^2 over snow and sea ice from meteorological data [J]. Journal of the Optical Society of America A, 1988, 5(4): 481-495.

- [8] Frehlich R, Sharman R, Vandenberghe F, et al. Estimates of C_n² from numerical weather prediction model output and comparison with thermosonde data
 [J]. Journal of Applied Meteorology and Climatology, 2010, 49(8): 1742-1755.
- [9] Qing C, Wu X Q, Li X B, et al. Estimation of atmospheric optical turbulence profile by WRF model at Gaomeigu[J]. Chinese Journal of Lasers, 2015, 42 (9): 0913001.
 青春,吴晓庆,李学彬,等.WRF模式估算丽江高美 古大气光学湍流廓线[J].中国激光, 2015, 42(9): 0913001.
- [10] 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.
- [11] Qing C, Wu X Q, Li X B, et al. Use of weather research and forecasting model outputs to obtain nearsurface refractive index structure constant over the ocean[J]. Optics Express, 2016, 24(12): 13303-13315.
- [12] 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.
- [13] LüJ. Research on estimating model of atmospheric optical turbulence [D]. Hefei: University of Science and Technology of China, 2017.
 吕洁.大气光学湍流预报模式研究[D]. 合肥:中国科学技术大学,2017.
- [14] Li Y J, Zhu W Y, Rao R Z. Simulation of random phase screen of non-Kolmogorov atmospheric turbulence [J]. Infrared and Laser Engineering, 2016, 45(12): 1211001.
 李玉杰,朱文越,饶瑞中.非Kolmogorov大气湍流 随机相位屏模拟[J]. 红外与激光工程, 2016, 45 (12): 1211001.
- [15] Ma C B, Huang K, Ao J. Numerical simulation of random phase screen under the Kolmogorov and non-Kolmogorov turbulence model [J]. Computer and Digital Engineering, 2019, 47(12): 2982-2988.
 马春波,黄可,敖珺. Kolmogorov 与 Non-Kolmogorov 湍流相位屏的数值仿真方法研究[J]. 计 算机与数字工程, 2019, 47(12): 2982-2988.
- [16] 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.

- [17] Niu C J, Lu F, Han X E. Propagation properties of Gaussian array beams transmitted in oceanic turbulence simulated by phase screen method [J]. Acta Optica Sinica, 2018, 38(6): 0601004.
 牛超君, 卢芳, 韩香娥. 相位屏法模拟高斯阵列光束 海洋湍流传输特性[J]. 光学学报, 2018, 38(6): 0601004.
- [18] Xu Q W, Wang P P, Zeng Z J, et al. Extracting atmospheric turbulence phase using deep convolutional neural network [J]. Acta Physica Sinica, 2020, 69(1): 014209.
 徐启伟, 王佩佩, 曾镇佳, 等. 基于深度卷积神经网 络的大气湍流相位提取[J]. 物理学报, 2020, 69 (1): 014209.
- [19] 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.

- [20] Liu M J, Cao Y Z, Zhu S Y, et al. Feature fusion video target tracking method based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2020, 57(4): 041502.
 刘美菊,曹永战,朱树云,等.基于卷积神经网络的特征融合视频目标跟踪方法[J].激光与光电子学进展, 2020, 57(4): 041502.
- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10) [2020-05-10]. https://arxiv.org/abs/ 1409.1556.

Atmospheric Turbulence Intensity Estimation Based on Deep Convolutional Neural Networks

Ma Shengjie^{1,2}, Hao Shiqi^{1,2*}, Zhao Qingsong^{1,2}, Wang Yong^{1,2}, Wang Lei^{1,2}

¹ State Key Laboratory of Pulse Power Laser Technology, National University of Defense Technology, Hefei, Anhui 230037, China; ² AnHui Province Key Laboratory of Electronic Restriction, Hefei, Anhui 230037, China

Abstract

Objective Atmospheric turbulence causes a random fluctuation in the refractive index. When a laser propagates in atmospheric turbulence, the light intensity fluctuation phenomenon during beam propagation occurs, seriously influencing laser propagation. Because different atmospheric turbulence intensities have different effects on laser propagation, it is significantly important to estimate the atmospheric turbulence intensity. In general, the refractive index structural constant C_n^2 of the atmospheric turbulence on laser propagation. Traditional estimation methods include instrument measurement and model estimation. The instrument measurement allows building an experimental platform to directly measure C_n^2 , in contrast, the model estimation allows obtaining C_n^2 by measuring other atmospheric parameters and establishing a model. In recent years, deep learning has allowed achieving good results in the field of image processing, which can extract the feature information of an image layer by layer. This study proposes a method to estimate the refractive index structural constant C_n^2 of atmospheric turbulence based on deep convolutional neural networks. The neural network model is built to extract the features of the light spot images under the influence of atmospheric turbulence and the turbulence information is obtained to estimate the turbulence intensity.

Methods A spot image under the turbulence influence contains the turbulence information. In deep learning, neural networks can extract the characteristic parameters of an image. Based on the above mentioned information, neural network models are built to estimate the turbulence intensity. According to the phase screen theory, the Gaussian beam spot images under the influences of different turbulences are simulated. The spot images are divided into a dataset and a test set. Three-thousand images are selected as the training set, and a neural network model is used to obtain the estimation models. Three-hundred images are used as a test set to analyze the estimated results. In addition, the influences of different network structures on the estimation results are analyzed, which provides a new way for estimating turbulence intensity.

Results and Discussions In this study, a traditional AlexNet network model and a VGG16 deep convolutional

neural network model are established. VGG16 is optimized on the basis of the traditional convolutional neural network, which increases the layer numbers of the network, reduces the size of the convolution kernel, and has more advantages on feature information extraction of images. The light spot images at different moments under the same turbulence intensity are selected as the inputs of the neural network to verify the feasibility of the above mentioned method and obtain the corresponding estimation results. Moreover, the standard deviation is calculated, and the estimation results are analyzed. The results show that the method can well estimate the turbulence intensity, and the standard deviation increases with the turbulence intensity. To better analyze the results of the neural network model and measure the estimation results, four statistics, i.e., mean absolute error (E_{MAE}), mean relative error (E_{MRE}) , root-mean-square variance (E_{RMSE}) , and correlation coefficient (R_{xy}) , are selected. The spot images under the influences of different turbulence intensities are randomly selected as the inputs of the neural network model to obtain the corresponding output. The estimation results of the two neural network models are shown in Table 5. After 20 iterations, the estimation result of the VGG16 neural network model is relatively ideal, the correlation coefficient reaches 99%, and E_{MAE} , E_{MRE} , and E_{RMSE} are controlled within 5%. After 500 iterations, E_{MAE} , E_{MRE} , and E_{RMSE} are further reduced to 2%. By analyzing Table 5, it can be seen that both models can well estimate the turbulence intensity after 500 iterations, and the estimation effect of VGG16 is better than that of the AlexNet neural network model. When the number of iterations is the same, E_{MAE} , E_{MRE} , and E_{RMSE} estimated by the VGG16 neural network model are less than half of those of the AlexNet neural network model. Compared with the traditional AlexNet neural network model, the VGG16 neural network model optimizes the network structure and improves the estimation effect to a certain extent.

Conclusion In this study, a method based on deep convolutional neural network model is proposed to estimate turbulence intensity. First, the laser spot images under the influence of turbulence can be simulated according to the classical phase screen theory. Then, the laser spot images under the influence of turbulence are taken as the inputs of the deep convolutional neural network model, and the convolutional layer of the deep convolutional neural network model, and the convolutional layer. After the training of a large number of datasets, the network model is obtained, and the turbulence intensity is estimated. Finally, the estimated effect is analyzed. Compared with the traditional AlexNet neural network model, the VGG16 model adopts a small convolution kernel, which can better retain the image properties, and has high advantages on image feature extraction and better estimation effect. Therefore, the neural network model can be further optimized to improve the estimation effect, which provides a new way to estimate turbulence intensity.

Key words atmospheric optics; atmospheric turbulence; refractive index structural constant; deep convolutional neural network; turbulence intensity estimation

OCIS codes 010.1330; 010.3310; 200.4260