

基于卷积神经网络的激光雷达湍流预警

庄子波¹, 邱岳恒², 林家泉², 宋德龙²

- (1. 中国民航大学 飞行分校, 天津 300300;
2. 中国民航大学 电子信息与自动化学院, 天津 300300)

摘要: 为实现湍流的自动化预警, 提出了一种基于卷积神经网络的激光雷达湍流预警算法。首先, 该方法将激光雷达获取的风速数据进行速度结构函数的构建; 然后, 拟合出涡流耗散率, 进而将涡流耗散率构建为像素数据集。将数据集输入一种由两个卷积层、两个全连接层、一个 softmax 层、若干激活函数组成的卷积神经网络分类模型进行湍流识别; 最后, 采用学习率递减的方法来调整模型的参数对网络进行训练, 网络收敛后, 其损失度低至 3%, 通过对比实验表明网络的准确度可达到 85%。运用中川机场 2016 年机组报告进行对比分析, 结果表明: 文中方法对大气湍流的预警命中率可达 80%、误报率为 13.3%、虚警率为 6.7%, 该方法与 Hog-SVM 分类方法相比, 命中率显著提高, 从而证明了该卷积神经网络模型在湍流预警中泛化能力强, 提高了预警效率, 能够为管制员和气象预报人员提供一种判断依据。

关键词: 大气湍流; 多普勒激光雷达; 卷积神经网络; 湍流预警

中图分类号: P412.1 文献标志码: A DOI: 10.3788/IRLA20210320

Turbulence warning based on convolutional neural network by lidar

Zhuang Zibo¹, Qiu Yueheng², Lin Jiaquan², Song Delong²

- (1. College of Flight Technology, Civil Aviation University of China, Tianjin 300300, China;
2. College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In order to realize automatic turbulence warning, a novel turbulence warning algorithm based on convolution neural network(CNN) by lidar was proposed. Firstly, the velocity structure function was constructed from the wind speed data obtained by lidar; Then, the eddy dissipation rate was fitted, and then the eddy dissipation rate was constructed as a pixel data set. The data set was input into the CNN model composed of two convolution layers, two fully connected layers, one softmax layer and several activation functions for turbulence identification. The learning rate decreasing method is used to adjust the parameters of the model to train the network. After the network converges, the loss is as low as 3%. The comparative experiment shows that the accuracy of the network reaches 85%. Based on the flight crew report of Zhongchuan airport in 2016, the results show that the hit rate of this method for atmospheric turbulence warning is 80%, the false alarm rate is 13.3%, and the distort alarm is 6.7%. Compared with the Hog-SVM classification method, the hit rate of this method is significantly improved, which proves that the convolution network model has strong generalization ability in turbulence warning, and improves the warning efficiency significantly. It can provide a judgment basis for relevant weather forecasters.

Key words: atmospheric turbulence; Doppler lidar; convolutional neural network(CNN); turbulence warning

收稿日期: 2021-05-19; 修订日期: 2021-06-20

基金项目: 国家自然科学基金民航联合基金重点项目 (U1433202); 江苏省重点研发计划 (社会发展) 项目 (BE2021685)

作者简介: 庄子波, 男, 副教授, 硕士, 主要从事航空气象方面的研究。

0 引言

大气湍流是由各种尺度的涡旋连续分布叠加而成,是有序和无序相结合的复杂运动;存在相干结构和间歇性等现象;表现为风速的时间不规则性和空间的不均匀性;其统计特性表现为随机性、非线性和高时变性^[1]。湍流各个尺度之间伴随着剧烈的能量交换和较大的风切变。当飞机在飞行终端区起飞或进近时遭遇飞行湍流,空速突然改变引起飞机升力发生突变,导致飞机突然爬升或突然掉高度,尤其在低空遭遇晴空湍流时,容易引发飞机失速,导致飞机复飞,严重时飞行员不能及时采取补救措施,从而引发飞行事故。

湍流严重影响着飞行安全和运行效率,湍流发生时风的高时变性和非线性使得对湍流的探测和预警是近年来研究的热点和难点^[2]。多普勒激光雷达具有很高的时空分辨率,是晴空条件下风场探测的有效手段。德国航空航天中心大气物理研究所研发了激光雷达的集成探测系统以便进行湍流测量,以指导飞机避开大气湍流^[3]。美国在支持下一代空中运输系统的 NNEW(NextGen Network Enabled Weather) 系统报告中也指出多普勒激光雷达是湍流探测的重要手段^[4]。2020年以来,北京大兴机场引进了国外的激光雷达在机场进行风场探测。2016年以来,中国民航大学课题组在兰州机场开展了激光雷达的风场探测实验,开始针对国内机场开展国产激光雷达的湍流预警研究。

国际民航组织推荐使用涡流耗散率的立方根(EDR^{1/3})来表征湍流的强度^[5]。2010年以来,陈柏结^[6]等用激光雷达通过重构结构函数来计算 EDR^{1/3},计算出湍流强度为飞行员提供参考,该方法计算的湍流强度与飞行员报告有很好的一致性,证明了方法的有效性,但是该方法受湍流强度和信噪比的影响较大,且不适合业务化和智能化的湍流预警,需对激光雷达获取的涡流耗散率进行再次处理和强度的识别。

蒋立辉^[7]等对激光雷达获取的图像样本提取其形状特征和纹理特征,进行了风切变的组合识别;应用小波不变矩的方法提取风切变图像特征后,结合相关分类器对四种风切变进行分类识别^[8]。陈晓清等^[9]将激光成像雷达所测的距离像奇异值特征提取后,应用支持向量机对特征图像进行识别,结果表明识别率

较高。上述研究表明将激光雷达获取的风场信息用图像的形式来表示,采用相关算法对其进行特征提取,从而实现风切变、湍流等的分类和识别是可行的。

近年来,深度卷积神经网络(Convolutional Neural Network, CNN)进行湍流识别方面的研究有很多成果可以借鉴。徐启伟^[10]等提出了一种基于 CNN 模型,在光束传输中将受湍流影响的光强图训练学习后提取其湍流相位。蓝章礼等^[11]提出一种 CNN 模型对受湍流影响的模糊退化图像进行特征提取,分类出不同湍流强度的航拍图像。尹宵丽等^[12]针对不同湍流强度背景下,运用 CNN 训练叠加光束在大气湍流信道传输时的相位图,结果表明该模型的准确度较高。上述研究证明了 CNN 方法对大气湍流特性研究和图像重构等方面具有重要的应用价值。

Vasudevan S^[13]提出一种衰减学习率来训练深度神经网络,并且对衰减范围进行了测试,结果表明在更短时间内获得较好的准确性。Keskar N S^[14]在小批量随机梯度下降的基础上提出一种非单调学习率衰减策略,相对于 Newbob 方法,该策略提升了卷积网络的准确度。屈景怡^[15]等针对 CNN 在训练中网络性能不稳定等问题,采用衰减因子的方法来提升模型的稳定性,实验结果表明该方法能够有效降低网络在训练过程中的波动问题。综上所述,可以通过调整 CNN 的学习衰减率和调整衰减因子等方法来提高模型的稳定性和准确性。

文中基于激光雷达实验平台 2016~2017 年期间的测风数据,根据相关湍流模型拟合出机场进近空域内不同子扇区的涡流耗散率 ϵ 。然后将每个子扇区的 ϵ 转化为图片中的每个像素点,进而建立了数据集。将数据集输入至卷积神经网络中进行训练,对机场终端区湍流强度的图像进行特征提取与学习,根据损失度函数和准确度来衡量该湍流预警模型的分类能力。为验证该方法的预警能力与有效性,将该网络模型与经典的速度结构函数法进行横向的性能对比,并结合兰州中川机场收录的机组报告对模型进行对比分析。最后为验证预警模型的性能将文中建立的湍流预警模型与 Hog-SVM(Histogram of oriented gradient - Support Vector Machine) 进行对比,实验结果表明该模型预警能力良好。

1 数据集的建立

1.1 多普勒激光雷达实验平台

采用 1.55μm 多普勒激光雷达 (windmap) 在兰州中川机场进行低空测风实验, 实验平台如图 1 所示, 选取在 2016~2017 年之间的风速数据进行研究。将每个扇区的风速转化为一个涡流耗散率, 并进一步转化为二维图像, 构建用于训练的数据集。

考虑湍流的耗散特性和机场的探测需要, 多普勒激光雷达采用 PPI(Plan Position Indicator) 的扫描方式进行 fengc, 其中雷达的相关参数如表 1 所示。



图 1 多普勒激光雷达示意图

Fig.1 Schematic diagram of Doppler lidar

表 1 激光雷达的相关参数

Tab.1 Relevant parameters of lidar

Parameter	Value
Wavelength/nm	1550
Sampling interval/ns	2.5
Laser pulse width/ns	200
Pulse repetition frequency/kHz	10
Accumulated pulse number	5000
Range resolution/m	30
Maximum detection distance/km	6

1.2 图像数据集

大气湍流是由平均风速加脉动风速构成^[16], 激光雷达获取径向风速后, 首先对每个子扇区内的径向风速进行空间平均得出平均风速。经计算后得出径向风速与平均风速之差即湍流的脉动速度 $v'(R, \theta)$, 可以表示为:

$$v'(R, \theta) = v(R, \theta) - \bar{v}(R, \theta) \quad (1)$$

式中: $v(R, \theta)$ 为子扇区内某点的径向速度; $\bar{v}(R, \theta)$ 为代表子扇区的平均风速。

根据 Kolmogorov 湍流模型由脉动风速可构建速度结构函数 $D(s)$ ^[6], $D(s)$ 本质上是一个协方差函数, 涡流耗散率的求解实质为理论湍流模型与实际模型拟合逼近。将速度结构函数的协方差模型和 Kolmogorov^[17] 的湍流模型拟合求出涡流耗散率, 可以表示为:

$$\varepsilon = \left(\frac{2^{4/3} \pi}{\sqrt{3} \Gamma(1/3) \Gamma(4/3) C_v} \right)^{3/2} \frac{\sigma_v^3}{L_o} = \frac{0.933 \ 668 \sigma_v^3}{L_o} \quad (2)$$

根据含有激光雷达参数的 von Kármán 模型与雷

达所测径向风速构建的实际湍流模型进行拟合。在计算过程中, 拟合结果满足 χ^2 分布, 可以表示为:

$$\chi^2 = \frac{1}{N_s} \sum_{k=1}^{N_s} \frac{[\hat{D}_v(k\Delta s) - D(k\Delta s, \sigma_v, L_o)]^2}{D^2(k\Delta s, \sigma_v, L_o)} \quad (3)$$

式中: δ_v 为径向风速的标准差; $D_*(*)$ 为由径向风速构建的湍流结构函数; Δs 为距离门之间的长度; N_s 为滞后数据点的数目, 该参数可以根据工程试验中的情况进行调节。在实际测量中, 由于干扰和波动对激光传输和雷达信号处理模块的影响, 公式 (3) 无法恒等于 0, 采用最大似然估计的方法, 求出 δ_v^3/L_o 的最小值。然后代入公式 (2) 中得出目标参数 ε 。经过上述的处理过程, 将 ε 平铺至二维平面内后, 生成了数据集, 将每个实验周期所有的 ε 置入二维平面内。图像内每个像素点用每个子扇区 ε 表示, 进而将一个实验周期的径向风速数据转化为一张二维图像, 其中颜色的鲜艳程度代表 ε 数值的大小, 如图 2 所示给出包含 3 类大气湍流的部分数据集。

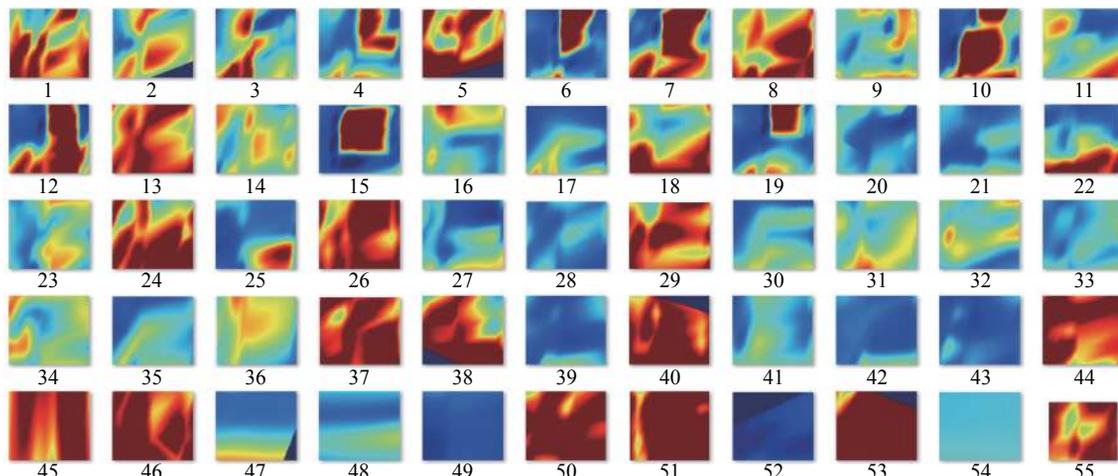


图 2 部分数据集的示意图

Fig.2 Schematic diagram of part of the data

2 卷积神经网络湍流预警模型

2.1 卷积神经网络模型的构建

随机选取数据集中的某一样本,作为网络的输入图像,如图 3 所示。

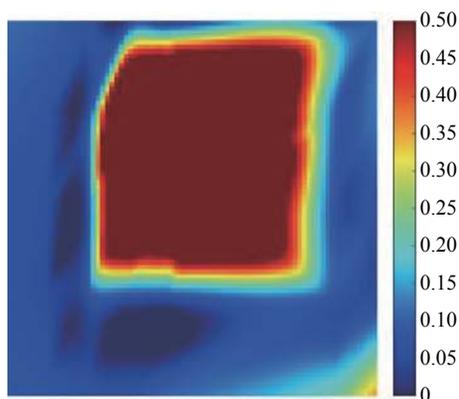


图 3 网络输入层涡流耗散率图像

Fig.3 Network input layer eddy current dissipation rate image

网络的输入层读取像素信息,将其转化为三通道数字矩阵后,分别输入至第一个卷积层中进行计算。对不同通道其特征提取器卷积核各不相同^[18],并且不同的湍流种类,使得每个卷积核获得不同的提取倾向。由像素点构成的数字矩阵与卷积核进行计算,进而提取出若干个数字特征,由数字特征构成的矩阵便是该卷积层的输出。

卷积层为线性运算,若简单地将卷积层相互连接会出现退化现象。为增强网络整体的拟合能力和泛化能力,在每个卷积层后增加 Relu 层,该结构的优势

在于能将上一层输出结果中较差的特征值进行剔除。Relu 层的函数表达为:

$$Relu = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (4)$$

第一个卷积层的输出经过非线性处理后,将 3 通道的数字特征进行叠加,转化为图像后,如图 4 所示。

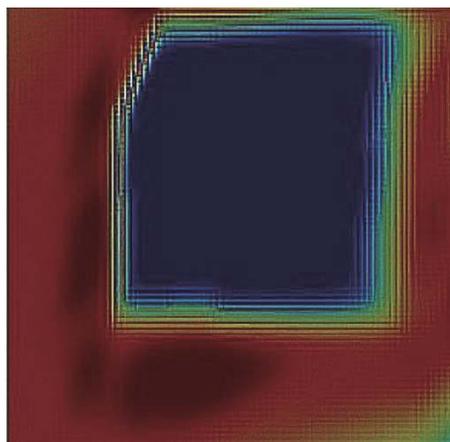


图 4 第一个卷积层的输出结果图

Fig.4 Output result graph of the first convolutional layer

将上述输出结果作为下一层的输入,与第二层卷积层进行计算,其运算过程与上述第一步相同,经非线性处理后结果如图 5 所示。

该 CNN 模型中的卷积模块后设置两个全连接层。此结构能将湍流的数字特征映射至样本空间,整合其特征信息,将湍流的分类结果进行显式表达。根据网络的结构和数据集的规模,将两个全连接层的神

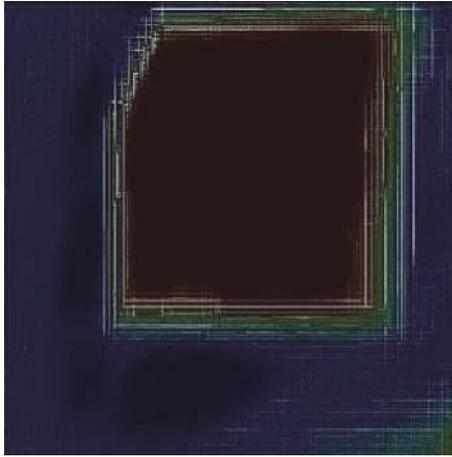


图 5 第二个卷积层的输出结果

Fig.5 Output of the second convolutional layer

经元个数分别设为 20 和 3。卷积层提取出的湍流数字特征驱动全连接层后,将其输出的特征信息汇合至分类模块激活 Softmax 函数中,使网络输出层得出三种不同强度的大气湍流^[19]。输出层设定:(1) 100-强烈湍流;(2) 001-中度湍流;(3) 010-轻度湍流。

采用交叉熵 Softmax loss 函数^[20-21],进行分类结果输出表示为:

$$J_x = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k l\{x_i \in c_j\} \ln \frac{e^{w_j^T x_i}}{\sum_{l=1}^k e^{w_l^T x_i}} \right] \quad (5)$$

式中: w_j 为权值 $w \in R^{d \times k}$ 第 j 列的矢量; $x_i \in c_j$ 表示样本 x_i 为第 j 类样本; $l\{*\}$ 为示性函数,若*表达式为真,取 1,相反为 0。

图 3 经过前向传播后,由损失函数得出分类结果与给定标签之间的误差。反向求出每个卷积层的权值与误差的关系,然后对卷积核内部的参数进行修正。如公式 (6)、(7) 所示:

$$\frac{\partial E_{total}}{\partial w} = \frac{\partial E_{total}}{\partial out} \times \frac{\partial out}{\partial net} \times \frac{\partial net}{\partial w} \quad (6)$$

式中: E_{total} 为网络输出的总体误差; w 为未更新的卷积核权值; ∂out 为激活函数对卷积层未激活的导数; ∂net 为卷积层上每个通道上的误差总和。

$$w^+ = w - \eta \times \frac{\partial E_{total}}{\partial w} \quad (7)$$

式中: w^+ 为更新后的卷积核权值; η 为学习率。网络结构如图 6 所示。

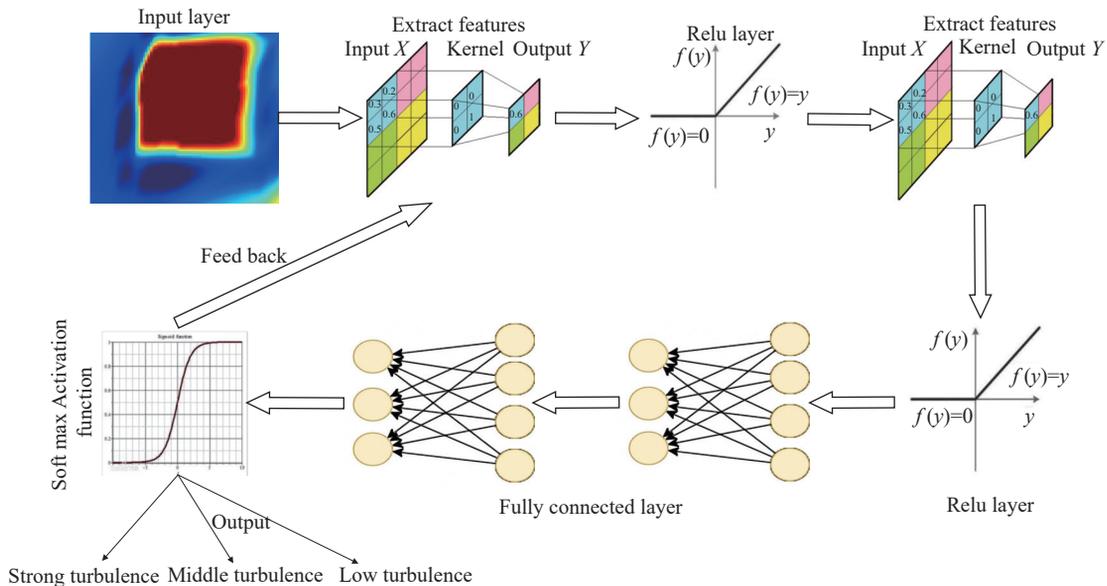


图 6 卷积神经网络结构图

Fig.6 Diagram convolutional neural network structuream

2.2 卷积神经网络的训练与评价

将图像数据集输入至文中所搭建的湍流预警卷积神经网络模型中对该网络进行训练,其训练的流程如

图 7 所示。

在训练过程中,对模型的评价如图 8 所示。

此次训练一共有 60 次迭代,每 25 次迭代后进行

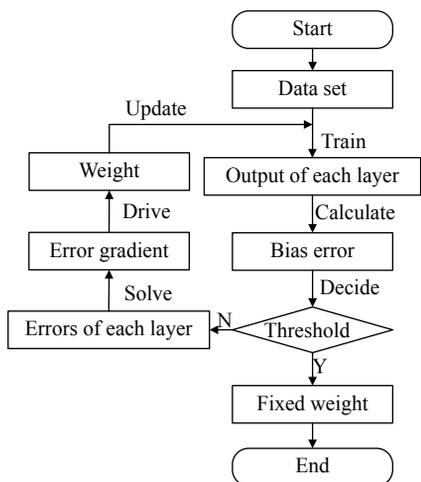


图 7 CNN 训练模型图

Fig.7 Diagram of CNN training model

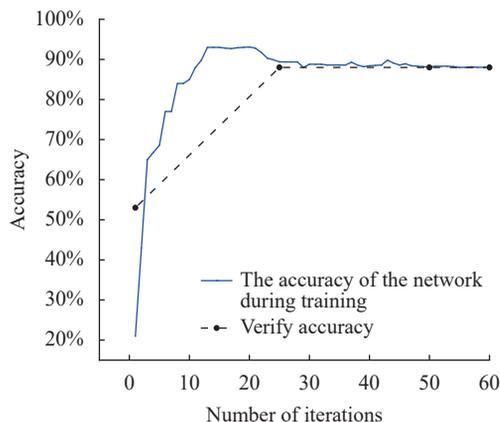


图 8 卷积神经网络训练过程图

Fig.8 Diagram of convolutional neural network training process

一次验证。图中蓝线为训练过程中网络的准确度,黑色虚线为验证准确度。可以看出网络在 25 轮迭代前,训练准确度有一定的波动,验证准确度逐步增加。在 25 轮迭代后,训练的准确度与验证准确度两条曲线逐步趋向一致,二者之间的差距逐渐减少,曲线平稳且准确度波动较少。表明网络本身开始收敛,对湍流信息图像中的特征有了较好的认知,验证结果较好。

2.3 网络训练的参数调节

采用学习率递减的方法对网络参数进行设置。在迭代一定程度后,将学习率适当的衰减,控制梯度下降的速度,使得网络快速收敛。另外,根据数据特点,每个像素点都是每个子扇区的涡流耗散率的情况。最初设定的扇区区域较大,为了更好的提取湍流

特征,在训练过程中应该更加关注小特征,因此用学习率递减的方法,使得卷积网络提取局部特征的权重加大。在训练过程中随着迭代次数的增加,将学习率每次以 10^{-2} 的衰减因子进行递减。学习率的递减与网络验证准确度的关系如图 9 所示。

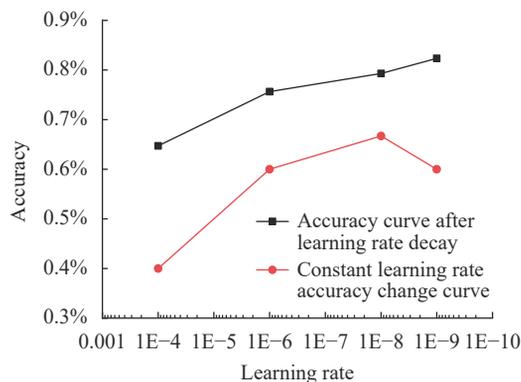


图 9 递减的学习率与网络准确度关系的示意图

Fig.9 Schematic diagram of the relationship between decreasing learning rate and network accuracy

由图 9 可知,随着学习率的递减,网络的训练准确度极速递增。训练结束时收敛至 85% 左右。因此,在网络训练中,对学习率进行有规律的衰减,能够使网络模型获得更高的判断准确度。

2.4 网络训练结果的评价

在训练过程中,用损失函数来衡量网络对测试集进行判断的好坏程度。损失函数实质上是指预测和实际数据的差距程度。损失函数变化曲线如图 10 所示。

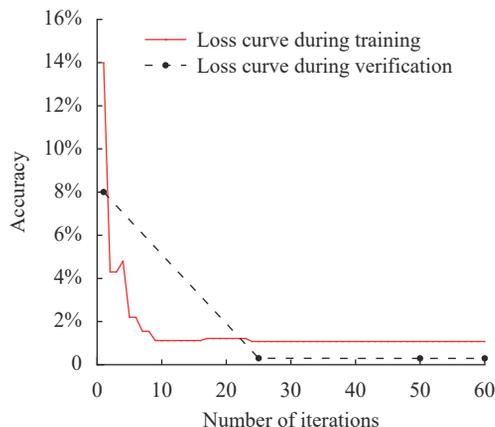


图 10 训练过程中损失度函数示意图

Fig.10 Schematic diagram of loss function during training

图中红色曲线为训练过程中的损失曲线,黑色虚线为网络做验证时的损失曲线。由上图可知,在迭代次数在 0~12 次时训练过程中的损失曲线处于逐渐下降的过程。在第 15 次迭代后,该曲线保持平稳,最后维持在 3% 左右。迭代次数在 0~15 次迭代期间,验证的损失曲线一直处于平稳下降的过程。至迭代次数达到 15 次以后,达到平稳状态。网络模型在训练过程中的损失度和自我验证损失度都低至 3% 以下。在训练后期,损失度曲线都趋向于平稳,证明该湍流预警模型性能良好。

3 方法验证与分析

为验证模型在工程上预警能力和本身的泛化能力,对该模型进行实测数据验证与分析。在实验环境一致的情况下,进行了三个测试实验。首先将收敛的网络模型与传统的速度结构函数法进行对比分析,用于测试实验的数据来源于激光雷达连续 20 天的测风数据。将测试数据输入至网络中,将网络的输出标签结果与传统速度结构函数法进行对比分析。其统计结果如表 2 所示。

表 2 两组方法的湍流告警统计

Tab.2 Turbulence warning statistics of the two methods

Date	CNN(L/M/H)	Vsf(L/M/H)	Times of false positives
2016.11.25	H	L	1
2016.11.26	H	H	0
2016.11.27	H	H	0
2016.11.28	L	L	0
2016.11.29	H	H	0
2016.11.30	M	M	1
2016.12.01	M	M	0
2016.12.02	L	H	1
2016.12.03	H	H	0
2016.12.04	H	H	0
2016.12.05	M	M	0
2016.12.06	L	L	0
2016.12.07	M	M	0
2016.12.08	H	H	0
2016.12.09	L	L	0
2016.12.10	L	L	0
2016.12.11	H	L	1
2016.12.12	H	H	0
2016.12.13	H	H	0
2016.12.14	H	H	0

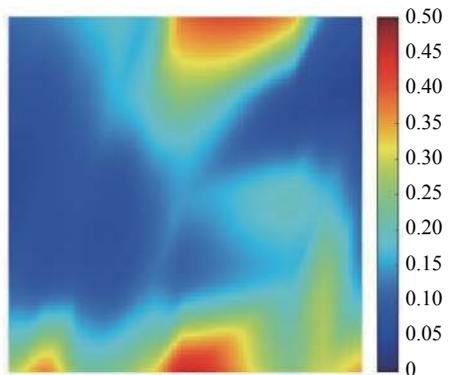
在实验环境一致的情况下,分别运用速度结构函数与卷积神经网络两种方法对同一测试集中测风数据进行湍流预警测试。如表 2 所示,在 20 次独立实验中,有 3 组对比实验结果有着明显的差异,文中方法相对于速度结构函数法,共给出了 3 次误判,文中方法的预警命中率可达到 85%。

在 3 次误报中,12 月 2 日速度结构函数的输出结

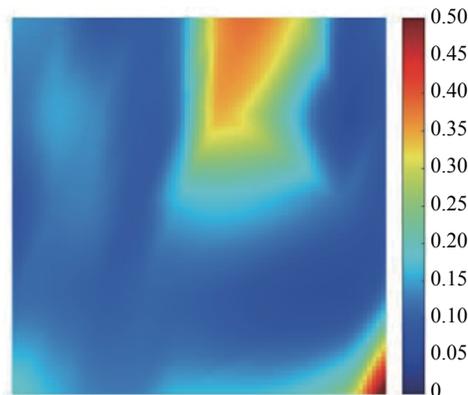
果为轻微湍流,而网络模型的结果为强烈湍流,认为此次为网络模型对湍流进行了一次虚假告警,进而认为该网络模型的虚警率为 33.3%。

除虚警外,两次误报中速度结构函数都给出强烈湍流的告警,而网络模型只是做出轻微湍流的判断。首先对原始数据进行分析,其图像如图 11 所示。

由图 11 可知,这两日的风场特征比较相似,其中



(a) 11月25日数据的图像
(a) Image of data on November 25



(b) 12月11日数据图像
(b) Data image on December 11

图 11 两次误报的原始数据图像

Fig.11 Original data image of two false positives

强烈湍流特征都位于图像的边缘,说明处在激光雷达的探测边缘,且该特征对于整个图像来说占比较小。另一方面由于激光雷达测风实验次数有限,导致数据集中上述天气情况的数据较少。从网络结构上进行分析,模型产生误报的原因可能为卷积核对于边缘特征的提取能力较低,对这两日的图像特征提取不够全面。两种方法对湍流预警的判断情况统计如图 12 所示。

图中,纵轴 $y=1$ 时为轻微湍流; $y=2$ 时为中度湍流; $y=3$ 时为强烈湍流。除三次误报外,两种方法预警的一致性较好。从对比实验得出,卷积神经网络模型的预警命中率较高,表明网络的泛化能力较高,可进行湍流预警。

将上述实验的网络模型,应用到真实风场中进行测试实验并与飞行员的机组报告进行比对。飞行员的机组报告是现阶段航空中对大气湍流状况判断的有效数据来源。收集了 2016 年 7 月至 2017 年 5 月兰

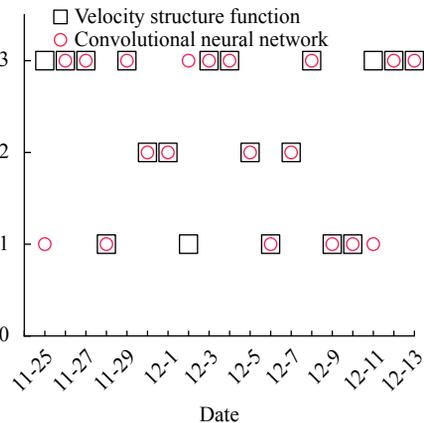


图 12 两种方法对湍流判断情况示意图

Fig.12 Diagram of the judgment of turbulence by two methods

州中川机场附近空域航班遭遇湍流的机组报告 15 起。根据航班遭遇湍流的时刻,结合当时多普勒激光雷达的探测情况,将激光雷达的探测数据输入至网络中进行分类识别,为验证该模型的分类能力和湍流预警能力,将其与传统的 Hog-SVM 分类法进行分类对比。用同一训练集对 Hog-SVM 模型进行训练,然后将上述 15 组航班遭遇湍流机组报告时刻的激光雷达探测的相关数据图像输入到 Hog-SVM 分类模型中进行识别,两种方法与机组报告数据的识别结果如表 3 所示。

由表 3 可知,根据机组报告进行的 15 次对比实验中,CNN 做出了 12 次正确的判断,3 次错误的判断。在 3 次的错误判断中,有两次做出了对湍流强度错误的判断,这种情况下认为该分类结果为对湍流的误报。另一次错误分类是对湍流的强度分类错误,将此类错误的判断归于虚警告警。根据当时航班的机组报告,距兰州中川机场 36 号跑道入口 3 km 处有湍流存在,将同一时刻、位置的数据输入至网络中,该模型并没有发出告警信号。根据 2016 年 10 月 15 日 CH7792 航班的机组报告,该机在距离 36 号跑道 2 海里左右,高度为 600 英尺左右遭遇湍流,飞机剧烈颠簸导致终止进近,备降其他机场,而网络模型仅给出轻度湍流。

根据表 3,在 15 起机组报告中,Hog-SVM 做出了 6 次错误判断,其预警率只达到 60%。在这 6 次错误判断中,Hog-SVM 模型的分类结果都是将机组报告的强烈湍流分类为轻度湍流,由此认为该模型对湍流的强度判断都属于误报。两种湍流预警方法对 15 起机组报告的命中情况,如图 13 所示。

表 3 两种方法对 15 组机组报告做出的判断结果

Tab.3 Judgment results made by two methods on 15 sets of unit reports

Date	CNN Alarm statistics(T/F)	Classified statistics(T/F)	Hog-SVM Alarm statistics(T/F)	Classified statistics(T/F)
2016.07.20	T	T	T	T
2016.09.03	T	T	T	T
2016.09.07	F	F	F	F
2016.09.10	T	T	T	T
2016.09.11	T	T	T	T
2016.09.20	T	T	T	T
2016.09.24	T	T	F	F
2016.10.15	T	F	F	F
2016.11.06	T	T	F	T
2017.04.13	F	F	T	T
2017.04.17	T	T	T	T
2017.05.06	T	T	T	T
2017.05.09	T	T	T	T
2017.05.13	T	T	F	F
2017.05.14	T	T	F	F

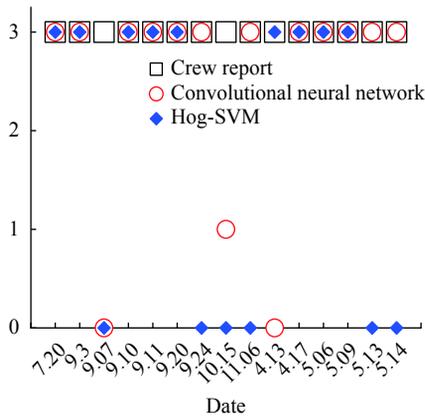


图 13 两种预警方法命中湍流的情况示意图

Fig.13 Schematic diagram of two early warning methods hitting turbulence

图 13 中, $y=0$ 时表示为预警方法做出的错误判断; $y=1$ 时表示为卷积网络做出的错误分类; $y=2$ 时表示为预警方法对湍流程度做出中度类别的判断; $y=3$ 时表示为预警方法做出的判断与机组报告的情况一致。

综上所述, 文中所搭建的 CNN 模型, 对湍流的预警性能较优, 能够对湍流进行有效的预警, 其预警命中率可达到 80%, 误报率为 13.3%, 虚警率为 6.7%。相对于 Hog-SVM 模型, 此模型的命中率高出 20%, 证明了该湍流预警模型的有效性与可行性。

4 结 论

提出了一种 CNN 网络的湍流识别模型, 对激光雷达获取的晴空湍流进行分类与识别, 实现激光雷达对湍流的自动化高效预警。将构建的数据集输入模型进行训练后, 采用了学习率递减的方法对网络的参数进行设置, 运用网络分类准确度与损失度函数对该模型进行了性能的评价。

为验证文中所提出的预警模型, 分别与经典湍流预警的速度结构函数法进行横向对比, 与机组报告进行纵向对比。根据同一训练集对经典的 Hog-SVM 图像分类法训练后, 对机组报告的相关湍流数据进行验证。对比实验的结果表明: 在横向对比中, 文中提出的湍流预警模型的预警命中率可达到 85%。提出的卷积预警模型相对于经典的分类算法, 其分类准确度提升了 20%。文中所提出的湍流预警方案在智能化等方面有了一定的提升, 能够为相关气象预报人员提供一种判断依据, 为未来民航业实现智能化的湍流预警提供一定的参考。

参考文献:

[1] Bonin T A, Choukulkar A, Brewer W A, et al. Evaluation of turbulence measurement techniques from a single Doppler

- lidar [J]. *Atmospheric Measurement Techniques*, 2017, 10(8): 1-26.
- [2] Leung M Y T, Zhou Wen, Shun Chiming, et al. Large-scale circulation control of the occurrence of low-level turbulence at Hong Kong international airport [J]. *Advances in Atmospheric Sciences*, 2018, 35(4): 435-444.
- [3] Wildmann N, Pschke E, Roiger A, et al. Towards improved turbulence estimation with Doppler wind lidar velocity-azimuth display (VAD) scans [J]. *Atmospheric Measurement Techniques*, 2020, 13(8): 4141-4158.
- [4] Dyk R V, Pariseau D H, Dodson R E, et al. Systems integration of unmanned aircraft into the national airspace: Part of the federal aviation administration next generation air transportation system[C]//IEEE Symposium on Systems and Information Engineering Design, SIEDS, 2012:1-25, 34.
- [5] Organization I. Meteorological Service for International Air Navigation: Annex 3 to the Convention on International Civil Aviation[M]. Chicago: International Civil Aviation Organization, 1998.
- [6] Chan P W. Validating the turbulence parameterization schemes of a numerical model using eddy dissipation rate and turbulent kinetic energy measurements in terrain-disrupted airflow [J]. *Meteorology & Atmospheric Physics*, 2010, 108(3-4): 95-112.
- [7] Jiang Lihui, Gao Zhiguang, Xiong Xinglong, et al. Study on type recognition of low attitude wind shear based on lidar image processing [J]. *Infrared and Laser Engineering*, 2012, 41(12): 3410-3415. (in Chinese)
- [8] Jiang Lihui, Chen Hong, Zhuang Zibo, et al. Recognition on low-level wind shear of wavelet invariant moments [J]. *Infrared and Laser Engineering*, 2014, 43(11): 3783-3787. (in Chinese)
- [9] Chen Xiaoqing, Ma Junguo, Fu Qiang, et al. Target recognition using singular value feature for laser imaging radar [J]. *Infrared and Laser Engineering*, 2011, 40(9): 1801-1805. (in Chinese)
- [10] Xu Qiwei, Wang Peipei, Zeng Zhenjia, et al. Extracting atmospheric turbulence phase using deep convolutional neural network [J]. *Acta Physica Sinica*, 2020, 69(1): 286-296. (in Chinese)
- [11] Lan Zhangli, Kuang Heng, Li Zhan, et al. Study on CNN-based turbulence image degradation intensity classification [J]. *Computer Systems & Applications*, 2019, 28(4): 199-204. (in Chinese)
- [12] Yin Xiaoli, Guo Yilin, Cui Xiaozhou, et al. Method of mode recognition for Multi-OAM multiplexing based on convolutional neural network [J]. *Journal of Beijing University of Posts and Telecommunications*, 2019, 42(1): 47-52. (in Chinese)
- [13] Vasudevan S. Mutual information based learning rate decay for stochastic gradient descent training of deep neural networks [J]. *Entropy*, 2020, 22(5): 560.
- [14] Keskar N S, Saon G. A nonmonotone learning rate strategy for SGD training of deep neural networks[C]// IEEE International Conference on Acoustics. IEEE, 2015.
- [15] Qu Jingyi, Zhu Wei, Wu Renbiao. Image classification for dual-channel neural networks based on attenuation factor [J]. *Systems Engineering and Electronics*, 2017, 39(6): 1391-1399. (in Chinese)
- [16] Davies F, Collier C G, Pearson G N, et al. Doppler lidar measurements of turbulent structure function over an urban area [J]. *Journal of Atmospheric & Oceanic Technology*, 2003, 21(5): 753-761.
- [17] Zhang Zhaoshun, Cui Guixiang, Xu Chunxiao. Theory and Modeling of Turbulence[M]. Beijing: Tsinghua University Press, 2005. (in Chinese)
- [18] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [19] Wu Jiaquan. Research on neural network based ECG classification algorithm and energy-efficient architecture[D]. Hangzhou: Zhejiang University, 2020. (in Chinese)
- [20] Huang Xu, Ling Zhigang, Li Xiuxin. Discriminative deep feature learning method by fusing linear discriminant analysis for image recognition [J]. *Journal of Image and Graphics*, 2018, 23(4): 510-518. (in Chinese)
- [21] Luo Chang, Wang Jie, Wang Shiqiang, et al. General deep transfer features based high resolution remote scene classification [J]. *Systems Engineering and Electronics*, 2018, 40(3): 682-691. (in Chinese)