

DOI: 10.12086/oee.2019.190082

基于 AlexNet 卷积神经网络的激光雷达飞机尾涡识别研究

潘卫军, 段英捷, 张强*, 吴郑源, 刘皓晨

中国民用航空飞行学院空中交通管理学院, 四川 广汉 618307



摘要: 为解决飞机尾涡威胁后机飞行安全问题, 保障空中交通安全, 提高机场和空域容量, 提出了一种基于 AlexNet 卷积神经网络模型的算法, 实现飞机尾涡的准确识别。结合多普勒激光雷达探测原理和 Hallck-Burnham 尾涡速度经典模型, 构建了 AlexNet 神经网络模型提取大气风场中的尾涡速度云图的图像特征, 识别飞机尾涡。研究表明, 该模型能够准确识别目标空域中的飞机尾涡, 网络模型收敛后对尾涡识别的准确率高达 91.30%, 并具有低虚警率, 能有效地实现对飞机尾涡的识别和预警, 达到尾涡监测的目的。

关键词: 尾涡识别; AlexNet 卷积神经网络; 目标识别; 多普勒激光雷达

中图分类号: TB872

文献标志码: A

引用格式: 潘卫军, 段英捷, 张强, 等. 基于 AlexNet 卷积神经网络的激光雷达飞机尾涡识别研究[J]. 光电工程, 2019, 46(7): 190082

Research on aircraft wake vortex recognition using AlexNet

Pan Weijun, Duan Yingjie, Zhang Qiang*, Wu Zhengyuan, Liu Haochen

Air Traffic Management Institute, Civil Aviation Flight University of China, Guanghan, Sichuan 618307, China

Abstract: In order to solve the flight safety issues threatened by wake vortex of leading aircraft, ensure air traffic safety, and improve the capacity of airdrome and airspace, an AlexNet convolutional neural network model algorithm is proposed to identify aircraft wake vortex. Combined with the detection principle of Doppler LiDAR and the classic model of Hallck-Burnham wake vortex velocity, the AlexNet neural network model was constructed to extract the image features of the wake vortex velocity images in the atmosphere and identify the aircraft wake vortex. The research shows that the model is able to accurately identify the aircraft wake vortex in the target airspace. After the network model converges, the accuracy rate reaches to 91.30%, which can effectively realize the identification work. Meanwhile, this study also demonstrates the low probability of false alarm of the AlexNet neural network in detecting wake vortex, which meets the requirement of early warning and monitoring of the aircraft wake vortex.

Keywords: wake vortex identification; AlexNet convolution neural network; target recognition; Doppler LiDAR

Citation: Pan W J, Duan Y J, Zhang Q, et al. Research on aircraft wake vortex recognition using AlexNet[J]. Opto-Electronic Engineering, 2019, 46(7): 190082

收稿日期: 2019-03-01; 收到修改稿日期: 2019-05-09

基金项目: 国家自然科学基金资助项目(U1733203); 民航局安全能力建设项目(TM2018-9-1/3); 四川省科技计划项目(2018JY0394); 大学生创新创业项目(S201910624014)

作者简介: 潘卫军(1968-), 男, 教授, 主要从事空中交通管理, 人工智能, 计算机仿真和雷达系统的研究。E-mail: panatc@sina.com
通信作者: 张强(1986-), 男, 博士, 副教授, 主要从事雷达技术与应用的研究。E-mail: 271198043@qq.com

1 引言

尾涡是指飞机在飞行时，由于翼尖处上下表面的空气压力差，产生的一对绕着翼尖的闭合涡旋。尾涡是飞机机翼升力的一个副产物，在飞机从起飞离地到降落的整个过程中都会产生^[1]。在近地阶段，强烈的尾涡会对其后方跟随的飞机产生滚转力矩，威胁飞行安全，并限制机场跑道容量^[2-4]。

基于上述问题，飞机尾涡的识别成为了航空研究中的重点问题。目前对于民航客机的尾涡探测与识别研究，主要包括理论分析、数值模拟和雷达试验等方法^[5]。其中，雷达试验已被公认为是尾涡探测与识别最为有效的工具之一^[6]。目前针对飞机尾涡的探测工具主要是多普勒激光雷达。2001年，Holzapfel 等人利用多普勒激光雷达在德国开展了多次尾涡实地探测实验，给出了估算尾涡涡流环量的方法^[7]。2006年，法国 Thales 公司使用 X 波段雷达在巴黎附近某机场进行了民航客机的尾涡探测实验^[8]。2008年，Frederic 等人在法国巴黎机场开展了 X 波段的激光雷达尾涡探测实验，以评估在多种大气条件下的尾涡监测能力^[9]。

近些年，随着深度学习的火热研究，卷积神经网络(convolutional neural network, CNN)成为一种用于激光雷达目标识别的新方法^[10]。现代激光雷达目标识别方法主要包括卷积神经网络(CNN)、支持向量机(support vector machine, SVM)方法、隐马尔科夫模型(hidden Markov model, HMM)等。由于 CNN 的通用性以及鲁棒性较好，且在模式分类领域避免了前期对图像的复杂预处理过程，具有更强大的信息表达能力，因此在激光雷达目标识别方面的研究中得到了广泛应用。本文在结合多普勒激光雷达探测原理、方式设计以及系统参量的基础上，提出了一种基于 AlexNet 卷积神经网络的模型对于大气风场中不同机型的飞机尾涡的识别方法，并通过准确率和虚警率验证其有效性。

2 激光雷达探测原理

激光雷达探测的主要原理是发射特定波长的激光波束对目标空域进行扫描，并通过接收器接收大气分子或气溶胶粒子对激光的向后散射信号，在探测空域中，由于大气分子和气溶胶粒子的布朗运动使得所捕获的散射信号产生多普勒展宽，而粒子的整体平均运动速度则导致了大气回波信号的多普勒频移^[11-12]，且多普勒频移 Δf_D 与探测到的尾涡径向速度 V_R 之间存在以下关系^[3]：

$$\Delta f_D = 2f_0 \frac{v}{c} = \frac{2}{\lambda_0} V_R , \quad (1)$$

式中： c 为光速， f_0 为经散射作用后的原频率， λ_0 为 f_0 对应的波长。

经 Hallock-Burnham vortex(HB)模型^[5]，可由径向速度反演得到切向速度，模型表述如下：

初始环量：

$$\Gamma_0 = \frac{4Mg}{\pi\rho VB} , \quad (2)$$

涡间距：

$$b_0 = \frac{\pi}{4} B , \quad (3)$$

切向速度：

$$V(r) = \frac{\Gamma_0}{2\pi} \cdot \frac{r}{r^2 + r_0^2} , \quad (4)$$

式中： M 为飞机进近时重量， g 为重力加速度常量， ρ 为当地空气密度， V 为飞机进近速度， r 为尾涡横截面上的点与涡核中心之间的距离， $r_0 = 0.052b_0$ 为尾涡涡核半径。

本文选取横向探测尾涡方式，即距离高度显示器(range-height-indication, RHI)模式，如图 1 所示，雷达发射激光波束在垂直于飞机飞行方向的横截面进行扫描，经处理得到目标空域内探测的飞机尾涡速度场云图，并利用卷积神经网络中的特征提取层处理方法实现激光雷达对于飞机尾涡识别工作。



图 1 激光雷达在国内某机场实地探测图
Fig. 1 LiDAR experiment at an airport in China

图 2 为 2018 年 9 月 5 日于国内某机场采集到的飞机尾涡分离阶段的速度场云图。图中背景风场 0~1 级风力，无强大气乱流，目标空域内存在两对速度相反，且大致成对称分布的尾涡。因大气湍流耗散率 ε 和 Brun-Vaisälä(BV)频率影响，尾涡在相互诱导作用下的演化规律不完全一致。经 H-B 涡模型验证，两对尾涡均在涡核中心处出现最大速度，并沿涡核半径方向速度递减。

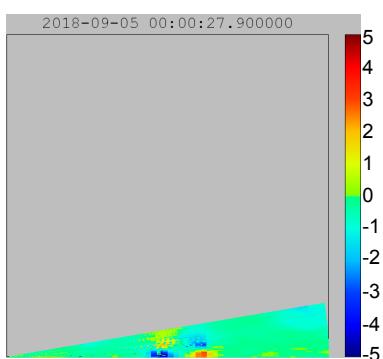


图 2 2018 年 9 月 5 日国内某机场飞机尾涡速度场云图

Fig. 2 September 5, 2018, at an airport in China, the vortex velocity image of an aircraft

3 基于 AlexNet 的飞机尾涡识别方法

3.1 卷积神经网络

卷积神经网络(Convolution neural network, CNN)是一种深度前馈神经网络，广泛应用于计算机视觉和模式分类领域^[13]。卷积神经网络的训练过程实质是一个参数不断学习更新的过程，训练给定一个初始随机参数，得到输出值，当输出值与标准值出现差异时，计算其误差，之后采用反向传播算法(back propagation, BP)，从输出层向反方向一层一层更新参数，直至训练精度达到最高。随着国内外深度学习研究的不断发展，CNN 在图像识别、目标检测等领域取得了巨大成功^[14]。而在激光雷达图像识别方面，卷积神经网络具有其独特的优点：1) 具备类脑功能，能够将特征提取与识别过程无差别融合；2) 局部感受域获取的特征与特征的平移、旋转和缩放无关；3) 权值共享结构

降低了网络模型的复杂度；4) 下采样利用局部相关性原理，在有效减少数据处理量的同时保留了原始结构信息^[15]。因此，CNN 被广泛应用于激光雷达的目标识别领域。

3.2 AlexNet 模型

卷积神经网络主要算法包括 8 层的 AlexNet、19 层的 VGGNet、22 层的 GoogleNet 和 200 层的 ResNet 等。理论上讲，神经网络的层数越深，其检测识别效果越优，但同时时间复杂度也越高。AlexNet 是 2012 年 ImageNet 竞赛冠军获得者 Alex Krizhevsky 设计的，该网络结构模型一经提出便引爆了神经网络的应用热潮，使得 CNN 成为在图像分类上的核心算法模型，在图像识别领域取得巨大成功，且由于该模型隐含层相对较少，从而能够快速地完成训练，在飞机尾涡识别方面有望实现实时识别并预警的功能，因此本文采用层数较少的 AlexNet 神经网络模型进行训练。AlexNet 神经网络模型算法结构图如图 3。

AlexNet 神经网络模型共含 8 层结构(不包括池化层和局部响应归一化)，其中前 5 层为卷积层，后 3 层为全连接层，网络参数设置如表 1 所示。

AlexNet 神经网络模型最后一层是由 1000 类输出的 Softmax 函数层用作分类。局部响应归一化层(local response normalization, LRN)出现在第 1 个及第 2 个卷积层后，而最大池化层出现在两个 LRN 层及最后一个卷积层后。线性整流函数(rectified linear unit, ReLU)激活函数则应用在这 8 层每一层的后面。因为 AlexNet 训练时使用了两块图形处理器(graphics processing unit, GPU)，因此该结构图中相关组件被拆为了两个部分^[16]。

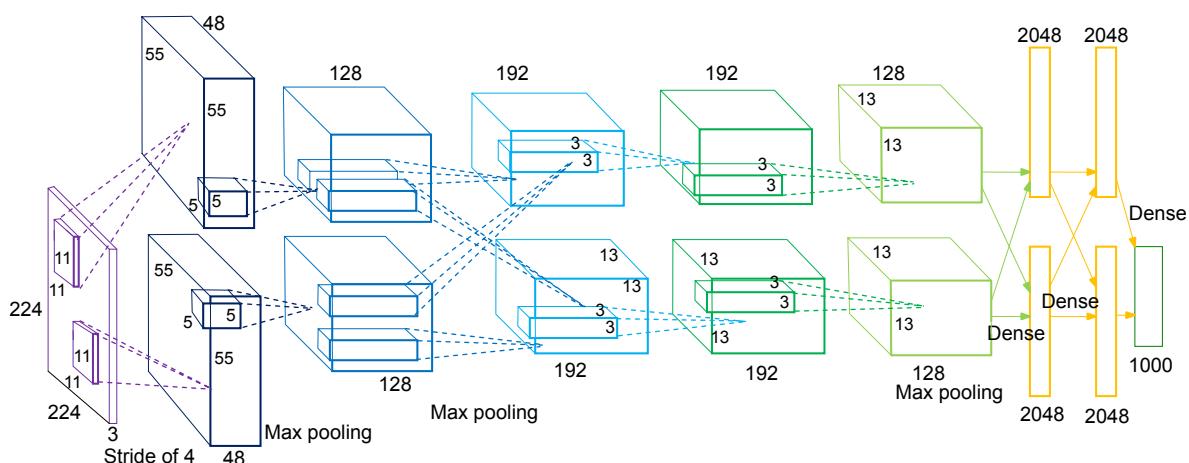


图 3 AlexNet 神经网络算法结构

Fig. 3 AlexNet algorithm structure

表 1 AlexNet 参数设置
Table 1 AlexNet parameter settings

Name	Type	Filter size	Stride	Padding	Output size
Input data	Color image	—	—	—	224×224×3
Conv1	—	7×7	4	0	55×55×96
Pool1	Max pooling	3×3	2	0	27×27×96
Conv2	—	5×5	1	2	27×27×256
Pool2	Max pooling	3×3	2	0	13×13×256
Conv3	—	3×3	1	1	13×13×384
Conv4	—	3×3	1	1	13×13×384
Conv5	—	3×3	1	1	13×13×384
Pool5	Max pooling	3×3	2	0	6×6×256
Fc6	—	—	—	—	4049
Fc7	—	—	—	—	4049
Fc8	—	—	—	—	1000
Softmax with loss					

表中 ,Name 为层名称 ,Type 为池化类型 ,Filter size 为过滤器尺寸 ,Stride 为步长 ,Padding 为边界填充数 ,Output size 为输出尺寸。在该模型前 5 层中 , 第 1、2、5 层卷积层后跟随了池化层(池化规则为最大池化 Max pooling) ; 第 3 层和第 4 层只有卷积层 , 没有池化层。后 3 层全连接层起到分类器的作用 , 对前层的特征进行一个加权和(卷积层是将数据输入映射到隐层特征空间)将特征空间通过线性变换映射到样本标记空间。

AlexNet 神经网络模型主要使用到的新技术如下 : 1) 成功使用 ReLU 作为 CNN 的激活函数 , 并验证了其在较深网络中的有效性 , 解决了 Sigmoid 在网络较深时的梯度弥散问题。 2) 训练时在最后的全连接层使用 Dropout 随机忽略一部分神经元 , 以避免模型过拟合 , 提高了精度。 3) 使用重叠的最大池化 , 解决了平均池化模糊化效果 , 提升了特征的丰富性。 4) 运用局部响应归一化(local response normalization , LRN)层 , 增强模型的泛能力。 5) 数据增强 , 减轻过拟合 , 提升泛化能力^[17]。在本文研究中 , 加之其具有较少的层数 , 时间复杂度少 , 有望实现尾涡的实时探测识别功能 , 故选择 AlexNet 模型作为识别模型来训练。

3.3 飞机尾涡识别

由于激光雷达在探测大气分子或者气溶胶粒子速度时采用多普勒原理 , 即仅有与发射激光波束方向相同的速度分量才能引起散射信号的多普勒频移 , 因此本实验采用在垂直于飞机飞行方向的横截面内进行俯

仰向上的扇形扫描(RHI 模式)^[18] , 该扫描方式能够较完整捕获飞机翼尖处涡流的生成、分离和耗散阶段。

为实现激光雷达探测飞机尾涡的高准确度 , 选取表 2 所示的 1.5 μm 脉冲相干多普勒激光雷达的系统参量用于尾涡探测。

表 2 1.5 μm 脉冲相干多普勒激光雷达的系统参量

Table 2 System parameters of 1.5 μm pulse coherent Doppler LiDAR

Name	Value
Observation mode	RHI
Detection range/m	45~915
Detection accuracy/m	30
Scan angel range/(°)	10~60
Scan step length/(°)	1.0

基于 AlexNet 卷积神经网络的飞机尾涡识别流程为通过激光雷达探测得到风场中关于速度的原始数据 , 经数据处理将其可视化 , 转化为如图 2 中所示的速度场云图 , 将采集得到的云图集通过预处理生成训练样本 , 输入 Caffe 框架中进行深度学习 , 训练结束后得到收敛的训练模型 , 即学习完成 , 模型学习得到关于尾涡的特征元素。对于待识别的尾涡样本云图 , 输入学习好的模型后 , 通过与特征库中的信号特征进行学习对比 , 进行识别测试 , 然后经 AlexNet 网络输出识别结果。基于 AlexNet 模型的飞机尾涡识别流程图如图 4 所示。

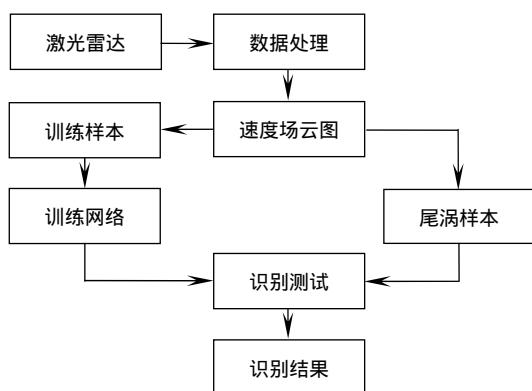


图 4 基于 AlexNet 模型的飞机尾涡识别流程

Fig. 4 Wake vortex identification process based on AlexNet model

4 仿真实验

4.1 实验平台

本文实验的深度神经网络搭建在 Caffe 框架上 , 运用 Python 语言编程实现 , 工作站为戴尔 T7810 工作站 , 内存为 16 G , 显卡为 MT4000 , 双核 CPU12 核心 , 3.4 G 主频。

4.2 样本处理与分类

为了提高对于尾涡识别的准确率 , 需要增加样本量。本实验采集了国内某机场 40 天内航班起飞的情况 , 该机场每日起飞航班约 500 架次 , 其中包括 A340 , A380 和 ARJ21 等机型。为合理识别并规避尾涡 , 实验

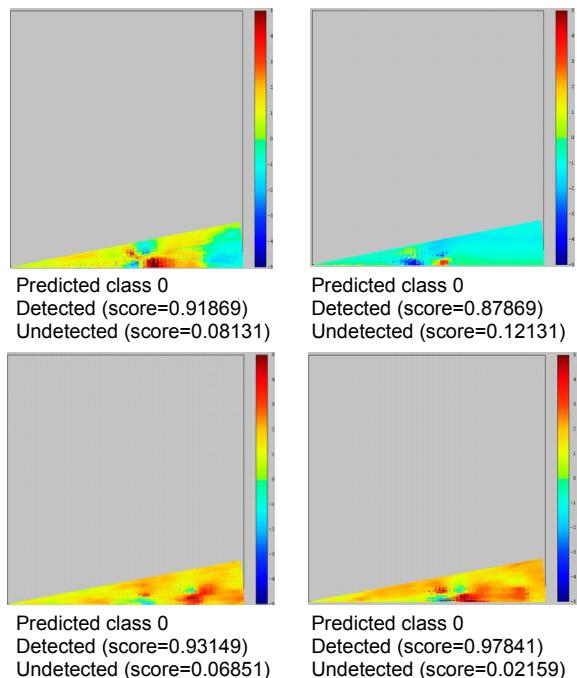


图 5 部分实验结果—AlexNet 对飞机尾涡的识别情况
Fig. 5 Part of experimental results—identification of the wake vortex by AlexNet

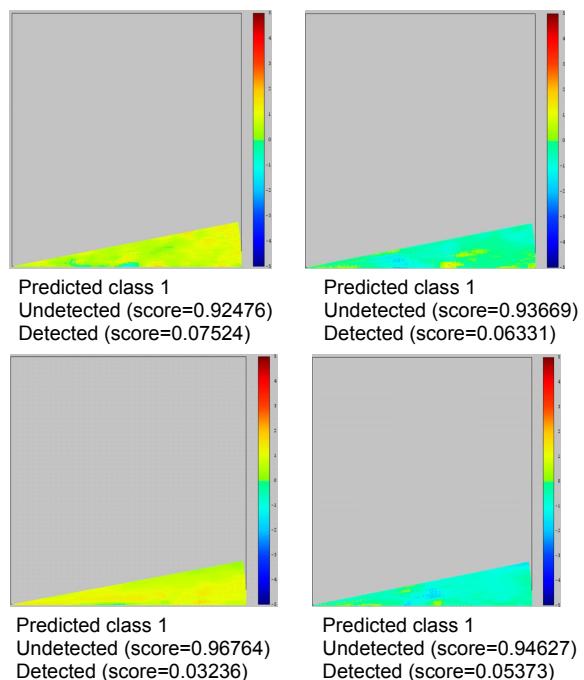
将训练集分为“探测到尾涡(Detected)”和“未探测到尾涡(Undetected)”两类 , 其中 , 由于尾涡在耗散末期大气层稳定性、湍流强度、风切变以及地面效应等原因 , 涡环量显著减少 , 对跟随后机已不构成威胁 , 因此将探测到的耗散末期的尾涡归为“未探测到尾涡”类 , 在实际的空中交通管制工作中更具有指导意义。

在图像深度学习中 , 为了丰富图像训练集 , 更好地提取图像特征 , 泛化模型 , 通常将样本图像进行数据增强^[19]。本实验采用旋转、多尺度放缩和随机剪切和 3 种算法进行训练数据增强 , 加大训练数据集的数据数量 , 使训练模型学习到更多的图片像素信息 , 从而提高模型的分类性能和泛化能力^[20]。本文实验共采集到两类训练集各 2000 张 , 并采用无放回随机采样方法选取 25% 的图片作为验证集 , 两类验证集各 500 张。

4.3 模型训练及识别结果

本文实验采用 AlexNet 网络模型 , 采集得到的样本在 Caffe 框架中训练 10000 次。学习率(Learning rate)控制模型的学习进度 , 若学习率设置太小 , 会导致网络收敛缓慢 , 学习效率显著降低 ; 若学习率设置太大 , 则参数更新的幅度就加剧 , 导致网络收敛到局部最优点 , 或者 loss 值直接开始增加。因此 , 经多次试验 , 设置基础学习率均为 0.01 , 动量系数为 0.9 , 尾涡识别测试的部分实验结果如图 5 所示。

由图 5 可以看出 , 当探测到飞机尾涡存在时 , 为



正样本，模型预测分类为 0；未探测到飞机尾涡存在时，为负样本，模型预测分类为 1。Score 值表示该图像被识别为预测分类下的概率值，用来验证模型的正确性与准确率。为验证模型泛化能力，图 5 中的样本分别采用在不同背景风场下、尾涡演化的不同阶段(尾涡的生成、分离和耗散阶段)的尾涡云图。识别结果表明，该模型在训练完成后具有较高水准的正确分类概率。在图 5 中对飞机尾涡的识别情况图中发现，该模型在针对大环量涡流时，其识别概率高达 97.84%；对于机型和风切变等因素影响下出现的小环量涡流，其识别概率也能到达 87.87%。对于未探测到尾涡情况，其识别概率均在 92%以上，表明 AlexNet 模型收敛后能准确区分出大气中是否存在飞机尾涡，特别是对于出现的大环量涡流，模型能够实现极高的识别概率，辅助空中交通管制员给出安全的尾流间隔指令。

5 算法分析

5.1 准确率及其质量评价

准确率(Accuracy, ACC, 用 η_{ACC} 表示)反映了分类器对整个样本的正确判定能力—能将正的样本判定为正，负的样本判定为负。计算式：

$$\eta_{\text{ACC}} = \frac{N_{\text{TP}} + N_{\text{TN}}}{N_{\text{TP}} + N_{\text{TN}} + N_{\text{FP}} + N_{\text{FN}}} , \quad (5)$$

式中： N_{TP} 为真正，将正类预测为正类数； N_{TN} 为真负，将负类预测为负类数； N_{FP} 为假正，将负类预测为正类数； N_{FN} 为假负，将正类预测为负类数。

图 6 为 AlexNet 神经网络测试的最终的准确率随迭代次数变化曲线。从图 6 可知，随着迭代次数的增加，AlexNet 神经网络模型对于尾涡识别的准确率逐渐上升，并在迭代次数约 8000 次时收敛，训练完成后，AlexNet 网络对于测试集的准确率为 91.30%，能够达

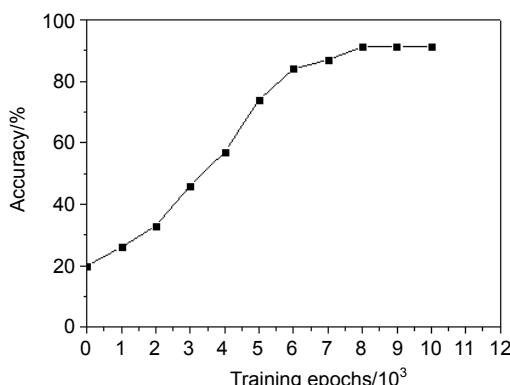


图 6 准确率随迭代次数变化曲线

Fig. 6 Accuracy rate with training epochs

到尾涡识别目的，为管制工作提供辅助决策信息。

5.2 损失函数及其质量评价

损失函数(Loss function)是用来估量模型的预测值与真实值的不一致程度，它是一个非负实值函数。损失函数输出值(loss value)表示预测值与真实值之间的误差，其值用来量化模型优劣，损失函数输出值越小，则模型的鲁棒性越好。

本模型采用交叉熵(cross entropy)函数作为损失函数，交叉熵刻画的是实际输出与期望输出的距离，即交叉熵的值越小，表明两个概率分布越接近。假设某样本的实际输出为 p ，而预计的输出为 q ，则 p 与 q 之间存在偏差，深度学习的目的即是通过不断地训练迭代，使得 p 越来越接近 q 。其数学表达式如下：

$$H(p, q) = -\sum_x p(x) \log q(x) . \quad (6)$$

图 7 是 AlexNet 神经网络模型训练时损失函数输出值的变化图。从图 7 可以看出，随着训练次数的不断增加，损失函数输出值逐步降低，当训练次数达到 6000 次左右时，该 AlexNet 网络趋于稳定，模型最优，此时能达到模型预测情况最接近实际情况。

为检验虚警率以验证 AlexNet 网络模型对于飞机尾涡识别的准确率，引入 Kolmogorov-Smirnov 非参数检验方法的双样本检验对识别结果进行校验^[21]，计算显示其对尾涡识别准确率在 90%以上，且虚警率为 2.70×10^{-4} ，表明该模型在训练后具备良好的识别能力。

从实验算法分析看出，应用基于 AlexNet 卷积神经网络模型，结合多普勒激光雷达数据，并将采集到的尾涡数据可视化，以实现对飞机尾涡的自动识别。对于一定涡环量的尾涡图像，AlexNet 神经网络模型可以进行高置信度识别，而当图像中含有未被充分训练的特征元素(尾涡在大气中的演化受多因素干扰，且由于背景风场的存在，可能对尾涡识别进行干扰)时，

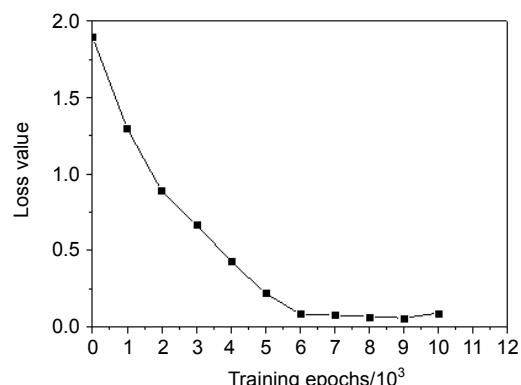


图 7 损失函数输出值随迭代次数变化曲线

Fig. 7 Output value of loss function with training epochs

识别结果出现不稳定现象。考虑到飞机尾涡在大气风场中的耗散特性，AlexNet 神经网络模型收敛后在测试集上的分类准确率已达到管制工作中对飞行器尾流间隔配备的要求，训练后模型也有较强的泛化能力，能够很好地满足空中交通管制工作中实际应用要求。

6 结 论

本文以卷积神经网络模型为基础，结合多普勒激光雷达原理，提出了一种基于 AlexNet 神经网络模型的算法，实现了对飞机尾涡的识别。实验结果表明，该模型能够较为准确地识别大气风场中尾涡的存在，并具有高准确率和低虚警率，能有效地为空中交通管制工作的分析决策提供参考，确定安全的尾流间隔，以实现飞机尾涡的预警和规避，保障飞行安全，提高机场容量。但本研究由于受机型和天气的影响，筛选得到的尾涡云图样本较少，同时因尾涡的不稳定性与背景风场的存在，模型中存在过拟合问题，未来应针对以上问题改进模型和算法，进一步完善深度学习在飞机尾涡识别方面的研究。

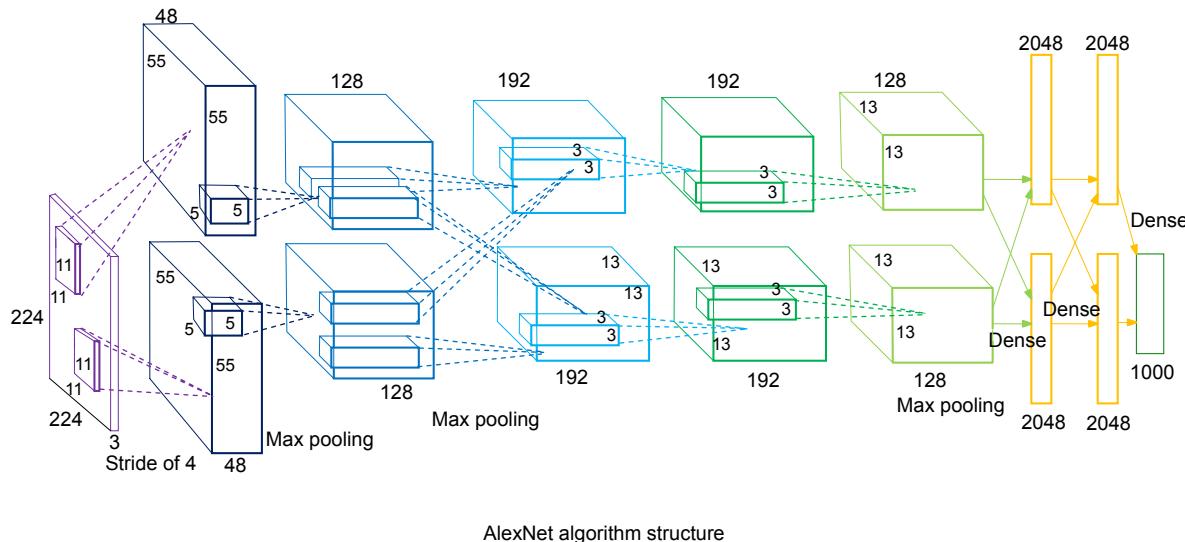
参 考 文 献

- [1] Hallock J N, Holzäpfel F. A review of recent wake vortex research for increasing airport capacity[J]. *Progress in Aerospace Sciences*, 2018, **98**: 27–36.
- [2] Gerz T, Holzäpfel F, Darracq D. Commercial aircraft wake vortices[J]. *Progress in Aerospace Sciences*, 2002, **38**(3): 181–208.
- [3] Frehlich R, Sharman R. Maximum likelihood estimates of vortex parameters from simulated coherent Doppler Lidar data[J]. *Journal of Atmospheric and Oceanic Technology*, 2005, **22**(2): 117–130.
- [4] Choroba P. Comprehensive study of the wake vortex phenomena to the assessment of its incorporation to ATM for safety and capacity improvements[D]. Slovakia: The University of Zilina, 2006.
- [5] Wei Z Q. The Research on modeling and simulation on flow field and safety spacing for wake vortex[D]. Tianjin: Civil Aviation University of China, 2008.
魏志强. 尾涡流场及安全间隔的建模与仿真计算研究[D]. 天津: 中国民航大学, 2008.
- [6] Köpp F, Rahm S, Smalikho I. Characterization of aircraft wake vortices by 2-μm pulsed Doppler lidar[J]. *Journal of Atmospheric and Oceanic Technology*, 2004, **21**(2): 194–206.
- [7] Holzäpfel F, Gerz T, Köpp F, et al. Strategies for circulation evaluation of aircraft wake vortices measured by lidar[J]. *Journal of Atmospheric and Oceanic Technology*, 2003, **20**(8): 1183–1195.
- [8] Barbaresco F, Jeantet A, Meier U. Wake vortex detection & monitoring by X-band doppler radar: paris orly radar campaign results[C]//Proceedings of 2007 IET International Conference on Radar Systems, Edinburgh, UK, 2007.
- [9] Barbaresco F, Meier U. Radar monitoring of a wake vortex: electromagnetic reflection of wake turbulence in clear air[J]. *Comptes Rendus Physique*, 2010, **11**(9): 54–67.
- [10] Profeta A, Rodriguez A, Clouse H S. Convolutional neural networks for synthetic aperture radar classification[J]. *Proceedings of SPIE*, 2006, **9843**: 98430M.
- [11] Wu Y H, Hu Y H, Dai D C, et al. Research on the technique of aircraft wake vortex detection based on 1.5 μm doppler lidar[J]. *Acta Photonica Sinica*, 2011, **40**(6): 811–817.
吴永华, 胡以华, 戴定川, 等. 基于 1.5 μm 多普勒激光雷达的飞机尾涡探测技术研究[J]. 光子学报, 2011, **40**(6): 811–817.
- [12] Li C, Liu J W, Zhao P E, et al. Correction method of tilt wind field of mobile wind lidar[J]. *Laser Technology*, 2017, **41**(3): 385–390.
李策, 刘俊伟, 赵培娥, 等. 机动型激光测风雷达倾斜风场修正算法研究[J]. 激光技术, 2017, **41**(3): 385–390.
- [13] Arel I, Rose D C, Karnowski T P. Deep machine learning - a new frontier in artificial intelligence research [Research Frontier][J]. *IEEE Computational Intelligence Magazine*, 2010, **5**(4): 13–18.
- [14] Yuan Q Z, Wei S J, Luo N. Research on SAR satellite target recognition system based on deep learning neural network[J]. *Aerospace Shanghai*, 2017, **34**(5): 46–53.
袁秋壮, 魏松杰, 罗娜. 基于深度学习神经网络的 SAR 星上目标识别系统研究[J]. 上海航天, 2017, **34**(5): 46–53.
- [15] Yin B C, Wang W T, Wang L C. Review of deep learning[J]. *Journal of Beijing University of Technology*, 2015, **41**(1): 48–59.
尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015, **41**(1): 48–59.
- [16] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems, South Lake Tahoe, USA: 2012: 1097–1105.
- [17] Zhang S H. Research on facial landmark localization based on deep convolutional neural network[D]. Wuhan: Huazhong University of Science and Technology, 2016.
张少华. 基于深度卷积神经网络的人脸基准点定位研究[D]. 武汉: 华中科技大学, 2016.
- [18] Hu Y H, Wu Y H. Study on the characteristic of aircraft wake vortex and lidar detection technique[J]. *Infrared and Laser Engineering*, 2011, **40**(6): 1063–1069.
胡以华, 吴永华. 飞机尾涡特性分析与激光探测技术研究[J]. 红外与激光工程, 2011, **40**(6): 1063–1069.
- [19] Duan M, Wang G P, Niu C Y. Method of small sample size image recognition based on convolution neural network[J]. *Computer Engineering and Design*, 2018, **39**(1): 224–229.
段萌, 王功鹏, 牛常勇. 基于卷积神经网络的小样本图像识别方法[J]. 计算机工程与设计, 2018, **39**(1): 224–229.
- [20] Dai W C, Jin L X, Li G N, et al. Real-time airplane detection algorithm in remote-sensing images based on improved YOLOv3[J]. *Opto-Electronic Engineering*, 2018, **45**(12): 180350.
戴伟聪, 金龙旭, 李国宁, 等. 遥感图像中飞机的改进 YOLOv3 实时检测算法[J]. 光电工程, 2018, **45**(12): 180350.
- [21] Pan W J, Zhang Q Y, Zhang Q, et al. Identification method of aircraft wake vortex based on doppler lidar[J]. *Laser Technology*, 2019, **43**(2): 233–237.
潘卫军, 张庆宇, 张强, 等. 多普勒激光雷达的飞机尾涡识别方法[J]. 激光技术, 2019, **43**(2): 233–237.

Research on aircraft wake vortex recognition using AlexNet

Pan Weijun, Duan Yingjie, Zhang Qiang*, Wu Zhengyuan, Liu Haochen

Air Traffic Management Institute, Civil Aviation Flight University of China, Guanghan, Sichuan 618307, China



AlexNet algorithm structure

Overview: Wake vortices develop as a consequence of the lift an aircraft produced to fly. For a wing generating lift, the pressure on the wing lower surface is higher than the pressure on the wing upper face. Therefore, air flows around the wing tip from the lower surface to the upper surface resulting in a strong vortex, the so-called “wing tip vortex”. An airplane affected by a wake vortex experience may cause rolling moment even air crash. Given that, how to recognize wake vortex and monitor it to improve the capacity of airdrome and airspace, has become a key issue in civil aviation industry. The traditional method of detecting wake vortex generally adopts Doppler LiDAR, which is considered one of the most effective approach. In this paper, the LiDAR made use of the range-height-indication mode to obtain the radial velocity of the wake vortex, and the tangential velocity was calculated by the Hallock-Burnham vortex model, and then converted the velocity data to the speed maps of the vortex through processing. With the rapid development of artificial intelligence, convolution neural networks has turned out to be a powerful tool to deal with image analysis. For this reason, this paper applied AlexNet neural network model combined with the detection principle of Doppler LiDAR to extract the image features of the wake vortex velocity images in the atmosphere and identified the aircraft wake vortex by training a large amount of vortex maps. Aiming at perfecting the data sets, this experiment collected the flight departure data within 40 days of an airport in China. The airport took off about 500 flights a day, including A340, A380 and ARJ21 and so on. The AlexNet was trained and tested on the designed data sets, which involved 4000 training sets and 1000 validation sets and the training epochs were set as 10000. The qualitative experiment results show that after the network model converges, the accuracy rate reaches to 91.30%, which can effectively realize the identification work, monitoring of the aircraft wake vortex, as well as early warning. This research demonstrates the high accuracy and low probability of false alarm of the AlexNet neural network in detecting wake vortex and is capable to provide decision-making information for air traffic control work.

Citation: Pan W J, Duan Y J, Zhang Q, et al. Research on aircraft wake vortex recognition using AlexNet[J]. *Opto-Electronic Engineering*, 2019, **46**(7): 190082

Supported by National Natural Science Foundation of China (U1733203), Civil Aviation Authority Safety Capacity Building Project (TM2018-9-1/3), Sichuan Science and Technology Program (2018JY0394), and Innovation and Entrepreneurship Program of CAFUC (S201910624014)

* E-mail: 271198043@qq.com