

# 风云四号卫星东南沿海热带气旋强度深度学习估算

崔林丽<sup>1</sup>, 陈昭<sup>2</sup>, 于兴兴<sup>2</sup>, 陈光琛<sup>2</sup>, 王晓峰<sup>1</sup>, 陆一闻<sup>1</sup>, 郭巍<sup>1</sup>

1. 上海市气象局 上海市生态气象和卫星遥感中心, 上海 200030;

2. 东华大学 计算机科学与技术学院, 上海 201620

**摘要:** 热带气旋 TC (Tropical Cyclone) 是影响中国的一个重要天气系统。TC 强度准确估测对台风灾害防御具有至关重要的意义。本文基于第二代静止气象卫星风云四号 (FY-4A) 多通道扫描成像辐射计 AGRI (Advanced Geosynchronous Radiation Imager) 资料, 建立了台风强度识别的深度卷积神经网络模型 CNN (Convolutional Neural Network), 对台风强度不同等级和台风中心最大风速进行了试验。结果表明, CNN 模型具有良好的高维非线性处理能力和算法稳定性, 能对 TC 强度进行有效估计, 不同 TC 强度等级识别精度均在 97% 以上, 近中心最大风速平均绝对误差 MAE (Mean Absolute Error) 为 1.75 m/s, 均方根误差 RMSE (Root Mean Square Error) 为 2.04 m/s。CNN 可有效挖掘卫星 TC 形态的深层信息, 对台风强度的定量化估测具有较高的应用前景。

**关键词:** 遥感, 热带气旋, FY-4A/AGRI 卫星云图, 深度卷积神经网络, 强度估测

**引用格式:** 崔林丽, 陈昭, 于兴兴, 陈光琛, 王晓峰, 陆一闻, 郭巍. 2020. 风云四号卫星东南沿海热带气旋强度深度学习估算. 遥感学报, 24(7): 842-851

Cui L L, Chen Z, Yu X X, Chen G C, Wang X F, Lu Y W and Guo W. 2020. Deep learning estimation of tropical cyclone intensity along the southeast coast of China using FY-4A satellite. Journal of Remote Sensing (Chinese), 24 (7): 842-851 [DOI:10.11834/jrs.20209124]

## 1 引言

热带气旋 TC (Tropical Cyclone) 是破坏力最强的气象灾害之一, 它所携带的强风和强降水对人民生命财产安全和社会经济发展都具有重大的影响, 因此, 准确预报 TC 的路径和强度一直以来都是气象预报的一个重要方向, 但相对于台风路径的预报, 目前台风强度的预报水平进展缓慢 (郑峰等, 2016; 戴李杰, 2018)。

作为数值预报技术的重要补充, 气象卫星逐渐成为台风全天候监测的重要手段, 特别是在 20 世纪 70 年代, 美国学者 Dvorak 结合多年预报经验和气象侦察飞机观测资料, 提出了一套基于卫星图像台风云型特征进行台风强度估计的技术 (Dvorak, 1975, 1984, 1995), 成为缺少飞机探测条件下台风强度确定的世界通用标准 (许映龙等, 2015)。然而, Dvorak 技术的主观性较大, 估计 TC

强度的精度在很大情况下取决于预报员的经验和训练, 因此, 多年来, 如何利用卫星云图对 TC 强度进行更客观的估计, 国内外学者进行了广泛的尝试 (Velden 等, 1998; Kidder 等, 2000; Bankert 和 Tag, 2002; 王瑾和江吉喜, 2005; Yu 等, 2006; Olander 和 Velden, 2007; Piñeros 等, 2008, 2011; Fetanat 等, 2013; 王新和郭强, 2014; 鲁小琴等, 2014; Rodríguez-Herrera 等, 2015; Knaff 等, 2015; 钱金芳等, 2015; Zhao 等, 2016; 袁猛等, 2018)。鉴于台风自身云型复杂多变, Dvorak 技术的成功之处就是综合考虑了复杂的台风云系形态、布局以及对流云分布等多种指标, 但现有的研究试验多是基于统计的线性回归, 因此在表达动态变化的复杂 TC 云型特征方面仍有不足。

近年来, 深度学习 (Deep Learning) 技术已经在语音识别、图像识别、目标检测、遥感图像分

收稿日期: 2019-05-26; 预印本: 2019-09-30

基金项目: 上海市自然科学基金(编号:18ZR1434100); 上海气象科技联合中心合作基金(编号:LHZX201601)

第一作者简介: 崔林丽, 1975年生, 女, 研究员, 研究方向为卫星遥感理论与应用。E-mail: cllcontact@163.com

类等领域获得了很大进展, 成为各领域的研究热点 (Krizhevsky 等, 2012; Girshick 等, 2014; Deng 等, 2015; Zhong 等, 2017)。相比基于统计的线性回归法, 深度学习算法具有更优秀的高维非线性建模能力 (郑远攀等, 2019), 含有更多隐含层的深度卷积神经网络 CNN (Convolutional Neural Network) 也具有更复杂的网络结构, 能够准确识别具有位移和轻微形变的输入模式 (周飞燕等, 2017), 这对随时间动态变化的 TC 强度监测具有重要的意义。

鉴于此, 本文基于 FY-4A/AGRI 卫星资料, 采用深度卷积神经网络 (CNN) 模型, 对 TC 强度级别和台风中心风速进行了客观、快速区分和定量化估计试验, 这既是机器学习方法应用于 TC 强度监测分析的新实践, 还可以进一步发展和完善卫星遥感 TC 客观定强技术, 为卫星 TC 监测提供技术参考和新思路。

## 2 数据与方法

### 2.1 卫星资料

文中的卫星资料来源于风云四号静止气象卫星 A 星 (FY-4A), 该卫星于 2016-12-11 成功发射, 经星上定标后于 2018-05-01 正式投入气象业务运行, 是第二代静止气象卫星的首发星。与第一代静止气象卫星风云二号 (FY-2) 携带的红外和可见光自旋扫描辐射计 (VISSR) 相比, FY-4A 搭载的多通道扫描成像辐射计 (AGRI) 通道数由 5 个增加至 14 个, 空间分辨率最大为 500 m, 覆盖了可见光、短波红外、中波红外和长波红外等波段, 星上辐射定标精度为 0.5 K, 灵敏度 0.2 K, 具体特性见表 1。

为了有效挖掘台风云图信息, 本文共选取 2017 年 7 例台风的 FY-4A/AGRI 进行分析, 台风编号分别为 1705、1709、1710、1711、1718、1719 和 1721, 其中强热带风暴 2 例, 台风 1 例, 强台风 2 例, 超强台风 2 例, 空间分辨率统一为 4 km, 时间分辨率为 10—60 min。

### 2.2 台风资料

为了对卫星影像进行裁切、等级标记以及台风强度估计与校验, 本文还需要获取每个台风的

中心位置 (台风中心经纬度) 和台风强度 (中心最大风速) 信息, 该信息主要参考中央气象台业务下发的台风报文资料, 该资料通常每 3 h 发布一次台风位置、强度信息, 加密观测时更新频率为 1 次/h。

表 1 FY-4A/AGRI 光谱波段设置和主要探测对象  
Table 1 The setting of FY-4A/AGRI spectral band and main detection objects

通道	波段范围/ $\mu\text{m}$	中心波长/ $\mu\text{m}$	空间分辨率/ km	主要探测对象
1	0.45—0.49	0.47	1	气溶胶
2	0.55—0.75	0.65	0.5	雾、云
3	0.75—0.90	0.825	1	植被
4	1.36—1.39	1.375	2	卷云
5	1.58—1.64	1.61	2	云、雪
6	2.10—2.35	2.225	2	卷云、气溶胶
7	3.50—4.00	3.725H	2	火点
8	3.50—4.00	3.725L	4	地表
9	5.80—6.70	6.25	4	高层水汽
10	6.90—7.30	7.1	4	中层水汽
11	8.00—9.00	8.5	4	底层水汽
12	10.3—11.3	10.8	4	云和下垫面温度
13	11.5—12.5	12.0	4	云和下垫面温度
14	13.2—13.8	13.5	4	云顶高度

## 3 CNN 算法设计与模型特征

在气象上, 表达台风强度通常有两种方法, 一是采用国际惯例和中国气象局“关于实施热带气旋等级国家标准” (T19201-2006), 依据台风中心附近最大风力范围将台风分为热带低压 (10.8—17.1 m/s)、热带风暴 (17.2—24.4 m/s)、强热带风暴 (24.5—32.6 m/s)、台风 (32.7—41.4 m/s)、强台风 (41.5—50.9 m/s) 和超强台风 ( $\geq 51.0$  m/s) 共 6 个等级; 二是直接对近中心最大风速或中心最低气压值进行估测实现台风定量估测。深度学习模型如果直接利用离散的风速指标值进行标定, 这对前期的样本准备无疑是个很大的挑战, 几乎难以实现。因此, 本文借助卫星云图模式识别思想, 首先将卫星云图按照台风风速等级强度分类体系进行分类, 然后在获得较高分类精度的情况下进而采用线性估计方法实现台风风速估计。

文中设计的深度卷积神经网络 (CNN) 模型

结构如图1所示, 主要包含输入层、卷积层、池化层、全连接层以及输出层, 给定一幅台风图像, 通过输入层进入深层CNN网络, 充分提取台风的纹理和光谱特征, 最后在输出层得到台风强度等级分类结果。各层参数具体设置如表2所示, 其中 Conv-表示卷积层, MaxPool-表示池化层, Fc-表示全连接层。首先输入层, 考虑FY-4A可见光(1—6波段)通道在夜间缺测, 因此设计了白天和夜间两层输入模式, Conv-01为白天输入层, 时间为前一日21:01至当日08:59(世界时)的

FY-4A全波段(1—14波段)台风影像图, Conv-02为夜间输入层, 输入当日09:00—21:00(世界时)的FY-4A后8个红外通道(7—14波段)的台风影像图, 卷积核大小均为 $1 \times 1$ , 平移步长为1, 输出特征数为8。为了保证后续处理的一致性, 两层输入分别将白天和夜间的不同光谱特征输入各自的卷积采样通道, 经过特征变换得到尺寸相同 $[240, 8]$ 的特征层, 即分别得到8个大小为 $240 \times 240$ 的特征谱。

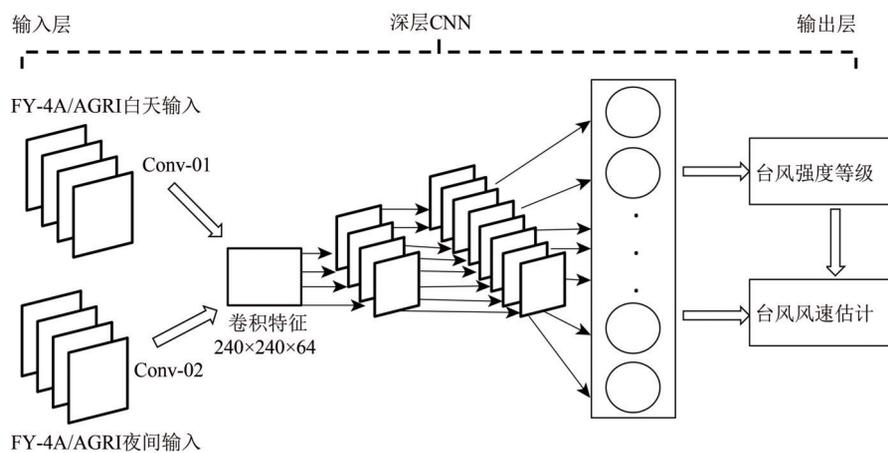


图1 基于CNN台风定强分类网络结构图

Fig. 1 The CNN network structural chart of typhoon intensity classification

表2 基于CNN的TC定强算法的模型结构参数

Table 2 Model structure parameters of TC intensity estimation algorithm based on CNN

层	输入尺寸	输出尺寸	核尺寸	步长	参数个数
Conv-01	[240, 240, 14]	[240, 240, 8]	[1, 1]	1	224
Conv-02	[240, 240, 8]	[240, 240, 8]	[1, 1]	1	128
Conv-1	[240, 240, 8]	[238, 238, 64]	[3, 3]	1	5120
MaxPool-1	[238, 238, 64]	[119, 119, 64]	[2, 2]	2	0
Conv-2	[119, 119, 64]	[117, 117, 128]	[3, 3]	1	81920
MaxPool-2	[117, 117, 128]	[58, 58, 128]	[2, 2]	2	0
Conv-3	[58, 58, 128]	[56, 56, 256]	[3, 3]	1	327680
MaxPool-3	[56, 56, 256]	[28, 28, 256]	[2, 2]	2	0
Conv-4	[28, 28, 256]	[26, 26, 324]	[3, 3]	1	829440
MaxPool-4	[26, 26, 324]	[13, 13, 324]	[2, 2]	2	0
Conv-5	[13, 13, 324]	[11, 11, 512]	[3, 3]	1	1658880
MaxPool-5	[11, 11, 512]	[5, 5, 512]	[2, 2]	2	0
Fc-1	[5, 5, 512]	[2048]	[ $2 \times 2 \times 256, 3584$ ]	—	26216448
Fc-2	[2048]	[512]	[3584, 2048]	—	26216448
Fc-3	[512]	[6]	[2048, 6]	—	3078
Softmax	[6]	[6]	—	—	0

接着, 利用卷积层对上一层提取的特征图进行2维卷积操作, 进一步提取图像的空间和光谱特征, 卷积核尺寸为 $3 \times 3$ , 平移步长为1, 输出特征数为64, 并利用Relu函数对特征进行非线性变换, 得到64个大小为 $238 \times 238$ 的特征。卷积函数为

$$y_{i,j,k}^{(l)} = R \left( \sum_{d_1=0}^{D_1} \sum_{d_2=0}^{D_2} \sum_{d_3=0}^{D_3} x_{i+d_1, j+d_2, d_3}^{(l)} \cdot w_{d_1, d_2, d_3}^{(l,k)} \right) \quad (1)$$

式中,  $x_{i+d_1, j+d_2, d_3}^{(l)}$  表示第 $l$ 层输入图像 $x$ 在 $(i+d_1, i+d_2, d_3)$ 位置的值,  $w_{d_1, d_2, d_3}^{(l,k)}$  表示第 $k$ 个卷积核在 $(d_1, d_2, d_3)$ 位置的值,  $D_1, D_2, D_3$  分别表示卷积核的尺寸,  $y_{i,j,k}^{(l)}$  表示输出的特征图 $y$ 在 $(i, j, k)$ 位置的值,  $R(\cdot)$  为线性整流函数ReLU (Rectified Linear Unit), 该函数可以让模型具备拟合复杂数据的能力, 同时能够缓解深层网络训练时产生的梯度消失问题, 其数学表达式为

$$R(x) = \max(0, x) \quad (2)$$

在池化层中, 为了对卷积层得到的特征图进行降维, 提升模型的平移不变性, CNN模型利用最大池化操作, 求出采样窗口中特征的最大值, 并作为降维后的特征, 最大池化操作能够更多地保留图像的局部纹理信息, 这对台风强对流云团的特征识别具有很好的指示意义。最大池化公式为

$$y_{i,j,k}^{(l)} = \max(x_{i,j,k}^{(l)}, \dots, x_{i+D_1, j+D_2, k}^{(l)}) \quad (3)$$

式中,  $\max(\cdot)$  表示取最大值操作,  $D_1, D_2$  表示池化窗口的大小。

全连接层主要起到“分类器”的功能, 其原理是将卷积、池化和激活函数层得到的特征进行映射, 得到与分类识别相对应的一组特征并输出到输出层, 利用softmax层, 得到每个输入样本属于各个台风级别的概率, 进而估计出该图像样本所在的台风强度级别。全连接层和softmax的原理分别见式(4), 式(5)

$$y_j^{(l)} = \sum_{i=1}^{D_1} x_i^{(l)} \cdot w_{ij}^{(l)} \quad (4)$$

式中,  $w$  表示权重矩阵。

$$P(c) = \frac{\exp(y_c^{(L)})}{\sum_{i=1}^c \exp(y_i^{(L)})} \quad (5)$$

式中,  $y_i^{(L)}$  表示最后一层全连接层的输出向量,  $i = 1, 2, \dots, C$ ,  $C$  为强度类别的个数,  $P(c)$  表示该台风属于第 $c$ 类的概率。输出层可以利用 $P(c)$ 根据式(6)求出该台风所属强度类别。

$$\hat{y}_c = \arg \max P(c) \quad (6)$$

最后, 为了量化得到台风的风速信息, 文中以softmax输出的概率值做参考进行风速线性估计, 具体取softmax层输出所属类别概率最大的两类, 然后利用式(7)与该类对应台风级别的风速上界行加权平均, 得到该时刻的台风最大风速值。

$$\hat{y}_s = P(c_1) \cdot R_{c_1} + P(c_2) \cdot R_{c_2} \quad (7)$$

式中,  $P(c_i)$  表示第 $i$ 类的概率值,  $R_{c_i}$  表示类别 $C_i$ 的风速上界。

## 4 台风强度估计流程

首先模型需要输入FY-4A/AGRI数据, 原始图像为中国气象局下发的区域扫描图, 像素大小为 $1400 \times 2748$ , 大范围图像一方面可能会包含其它云团信息从而干扰台风识别效果, 而且也影响模型运算效率。为了避免上述问题, 需要先对FY-4A/AGRI进行预处理, 即定位和裁切。FY-4A/AGRI数据采用CGMS LRIT/HRIT全球规范定义的静止卫星标称投影, 地理坐标可基于WGS84参考椭球计算或通过FY-4标称网格文件查找表获取。FY-4A/AGRI空间分辨率为4 km, 台风直径一般为600—1000 km, 最大的可达2000 km, 因此文中以相应时刻的台风中心经纬度为基准选取周围 $240 \times 240$ 大小的区域作为该时刻的台风样本集, 共计1047个训练样本, 不同等级样本图见表3。然后对照相应时间的台风报文强度信息对其风速所在级别一一进行分级标注, 再将各训练样本图像按照时间分别输入事先定义好的CNN模型中进行模型训练, 直至模型训练达到要求; 最后, 将训练好的模型参数、训练样本的真实强度和损失函数值保存, 再用测试样本集对模型分类精度进行测试, 进一步获取模型模拟精度, 具体处理流程见图2。

表3 不同台风等级采样表

Table 3 The sample table for different typhoon levels

台风级别	标记级别	热带气旋样例				
热带低压	1					
		热带风暴	2			
				强热带风暴	3	
台风	4					
		强台风	5			
				超强台风	6	

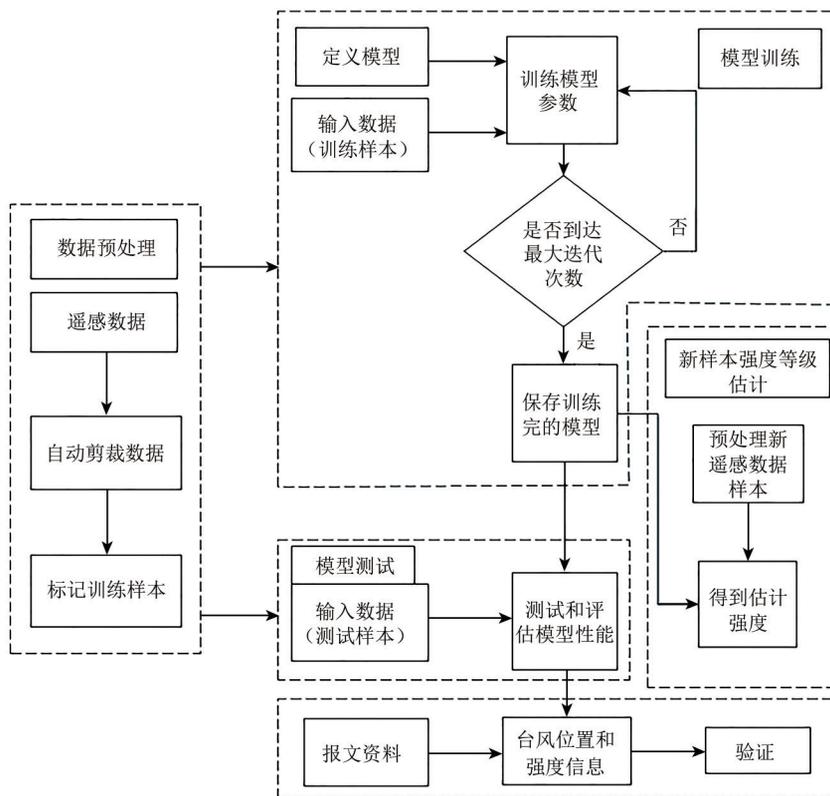


图2 基于CNN分类模型的台风定强流程

Fig. 2 The flow of typhoon intensity determination based on CNN classification model

## 5 结论分析与讨论

### 5.1 台风等级分类精度评价

混淆矩阵是评判模型结果的重要指标，可以对不同台风等级的分类可靠性进行分析，表4是CNN对不同台风强度等级识别的混淆矩阵，可以看出CNN对热带风暴、强热带风暴、台风和强台风具有很好的分类效果，分类精度均超过95%，相比而言热带低压和超强台风的识别效果较差，分类精度均在80%左右，通过表3可以看出两者主要与热带风暴之间存在不同程度的混淆，热带低压和热带风暴级别的台风强度都较弱，结构松散，形态多样，两者之间发生错判的可能性很大，而超强台风的训练较少可能是造成本次试验误差发生的主要原因。

为了更好地评估文中提出的方法，采用相同的数据集和特征，分别利用最近邻法KNN (k-Nearest Neighbor)、负反馈神经网络BPNN (Error Back Propagation Neural Network)、多元线性回归MLR (Multiple Linear Regression)、支持向量机SVM (Support Vector Machine) 等经典分类算法进行了分类试验，结果见表5。其中Overall (OA) 代表

总体分类精度、OA1代表白天总体分类精度，OA2代表夜间总体分类精度。从表5中可以看出CNN算法在台风强度等级分类上精度均在95%以上，比其他模式识别算法高出7—16个百分点，而且无论是整体分类精度还是白天和夜间分类精度，CNN均优于经典算法。

表4 CNN分类结果的混淆矩阵

Table 4 The confusion matrix of classification results produced by CNN

台风等级	热带 低压	热带 风暴	强热带 风暴	台风	强台风	超强 台风	总数
热带低压	19	0	0	0	1	0	20
热带风暴	4	438	1	1	2	6	452
强热带风暴	0	3	24	1	0	0	28
台风	0	0	0	58	1	0	59
强台风	0	5	0	1	103	2	111
超强台风	0	0	0	0	0	32	32
总数	23	446	25	61	107	40	702
分类精度	0.83	0.98	0.96	0.95	0.96	0.80	0.96

### 5.2 台风风速估计精度评价

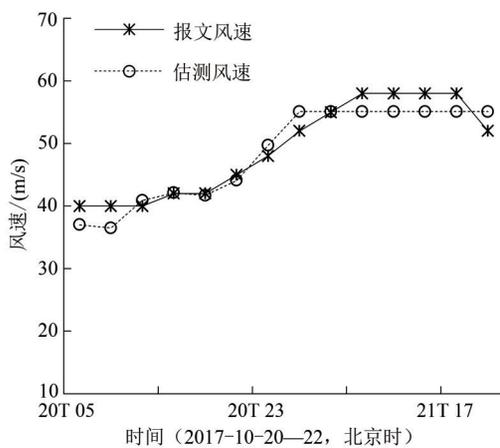
台风强度估计定量化评价是气象中台风强度

估计业务的基础, 选取2017年—2018年台风个例利用文中方法进行最大风速估算试验, 并开展逐次台风报文资料和CNN风速估计结果的时序匹配(图3)和精度分析(表6)验证, 可以看出, CNN预计风速与报文风速具有很好的一致性, 其中测试风速平均绝对误差MAE (Mean Absolute Error) 为1.75 m/s, 均方根误差RMSE (Root Mean Square Error) 为2.04 m/s。

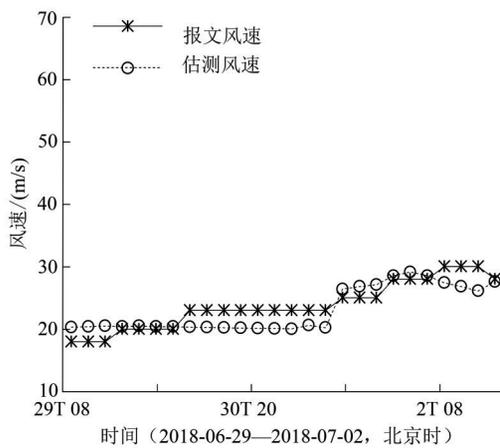
表5 CNN与经典算法分类精度对比

Table 5 Comparison of classification accuracy between CNN and classical algorithm

算法	CNN	BPNN	SVM	MLR	KNN
OA	0.96	0.73	0.78	0.89	0.70
OA1	0.95	0.62	0.87	0.88	0.66
OA2	0.97	0.87	0.67	0.91	0.74



(a) 1721号超强台风兰恩  
(a) Super Typhoon Lan(1721)



(b) 1807号派比安台风  
(b) Typhoon Prapiroon(1807)

图3 基于CNN的台风强度估计与报文风速时序图  
Fig.3 The time series of typhoon intensity based on CNN and typhoon message

表6 CNN与DAVT算法定强精度对比

Table 6 Comparison of intensity estimation between CNN and classical algorithm

算法名称	RMSE/(m/s)	MAE/(m/s)
CNN	2.04	1.75
DAVT	14.29	11.19

另外, 基于相同的样本集, 采用近年来倍受气象界关注(Ritchie等, 2014; Wood等, 2016; 袁猛等, 2018)的偏差角方差拟合法DAVT (Deviation Angle Variance Technique) 进行台风定强试验。结果表明, DAVT方法的MAE和RMSE分别为11.19 m/s和14.29 m/s, 这与Ritchie等(2014)研究精度相近, 由此可见, 基于CNN的台风客观强度估计方法优于DAVT, 在台风强度业务实践中具有很好的研究价值和应用前景。

### 5.3 影响台风强度识别的因素分析

#### 5.3.1 CNN输入层输出的卷积特征个数对分类精度的影响

在输入层, 为了对卷积函数进行合理设置, 通过改变输入层输出的卷积特征个数分别对模型进行训练, 得到测试集的分类精度如图4所示。可以看出, 输入层输出的卷积特征数为8时, 模型达到的总体分类精度最高, 故将8设为缺省参数值(表2)。

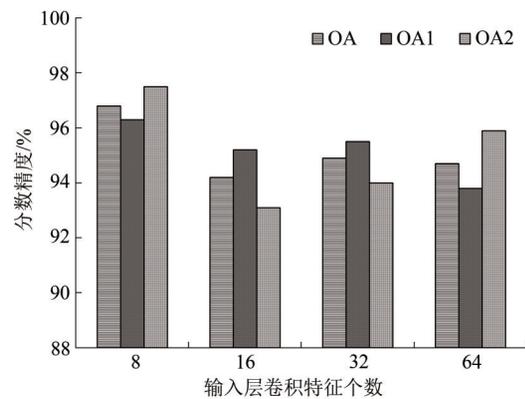


图4 输入层不同卷积特征个数的分类精度  
Fig.4 Classification accuracy of different number of convolution features in input layer

#### 5.3.2 不同波段对分类精度的影响

为了分析各波段对定强效果的影响, 选取台风强度样本测试集分别依次去掉第1—14个波段后

再输入模型,统计分类精度得到图5。

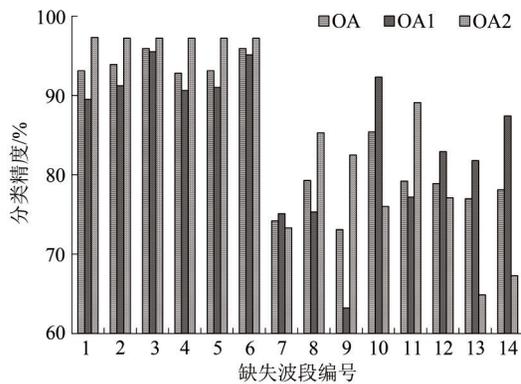


图5 逐波段去除后的台风强度分类精度

Fig.5 Classification accuracy of typhoon intensity level after band-by-band removal

可以看出, FY-4A 前6个通道的数据对分类精度的影响较小,后8个通道的数据对分类精度的影响较大。由表1可知,前6个通道波长范围小于 $3\ \mu\text{m}$ ,主要为可见光和近红外通道,观测到的能量主要来自云和大气反射的太阳能量;而后8个通道波长范围小于 $3.5\text{--}14\ \mu\text{m}$ ,为中红外和热红外通道,卫星观测的信息主要来自云体发射的热辐射信息。由此可见,本次试验中对台风强度识别精度的主要特征来自于台风云顶亮温发射,而云顶反射信息可能因 $4\ \text{km}$ 的分辨率较低而表现不佳。

## 6 结论

本文基于新一代静止气象卫星FY-4A多通道扫描成像辐射(FY-4A/AGRI)资料,建立台风强度识别深度卷积神经网络(CNN)模型,从台风强度分类识别和台风强度(中心最大风速)量化估计两个方面探讨了CNN模型在台风强度客观估计中的适用性。得出以下主要结论:

(1) 充分利用FY-4A多通道遥感图像的数据特点、深层神经网络的优势以及CNN灵活的结构特性,设计出契合FY-4A数据的CNN模型,可有效挖掘卫星台风形态的深层信息,实现高精度的台风强度估计;

(2) 利用CNN模型将台风强度识别转化为卫星云图模式识别,可对台风级别进行分类识别,试验发现无论是整体分类精度还是白天、夜间分别统计,台风强度识别精度均在95%以上,比KNN、BPNN、MLR及SVM等经典算法高7—16个百分点;

(3) CNN模型基础上利用最大概率线性估计的方法实现了台风风速的量化估计,其中风速MAE为 $1.75\ \text{m/s}$ ,RMSE为 $2.04\ \text{m/s}$ ,比DAVT分别下降了85.70%和84.38%,即CNN算法对台风强度的量化估计具有较高的研究价值和应用前景;

(4) FY-4A是第二代静止气象卫星首发星,装载的14个通道的扫描成像辐射计与国际水平相当,通过试验可知影响CNN台风强度识别精度的特征主要来自云的发射辐射,而云顶在可见光通道的反射信息可能受分辨率影响而被低估。

本文算法目前主要从理论实践角度进行可行性研究,但气象业务预报对算法要求的精度和时效性均较高,因此,后续研究将考虑结合实际业务需求进一步优算法流程,同时利用实际台风监测个例,对算法适应性开展长期的、连续的检验分析,对模型适应性进一步的修正和优化,如优化数据通道集,调整网络连接方式以及调整卷积核大小等。

**志 谢** 感谢FY-4A科研试验卫星地面应用系统工程天气示范分系统—东南沿海台风监测及预警服务示范应用子系统建设项目对本文工作的支持!

## 参考文献(References)

- Bankert R L and Tag P M. 2002. An automated method to estimate tropical cyclone intensity using SSM/I imagery. *Journal of Applied Meteorology*, 41(5): 461-472 [DOI: 10.1175/1520-0450(2002)041<0461:AAMTET>2.0.CO;2]
- Dai L J, Zhang C J, Xue L C, Ma L M and Lu X Q. 2018. Eyed tropical cyclone intensity objective estimation model based on infrared satellite image and relevance vector machine. *Journal of Remote Sensing*, 22(4): 581-590 (戴李杰, 张长江, 薛利成, 马雷鸣, 鲁小琴. 2018. 红外卫星云图和相关向量机的有眼热带气旋客观定强模型. *遥感学报*, 22(4): 581-590) [DOI: 10.11834/jrs.20187234]
- Deng L, Yu D and Dahl G E. 2015. Deep belief network for large vocabulary continuous speech recognition. *U.S.*, 20120065976A1
- Dvorak V F. 1975. Tropical cyclone intensity analysis and forecasting from satellite imagery. *Monthly Weather Review*, 103(5): 420-430 [DOI: 10.1175/1520-0493(1975)103<0420:TCIAAF>2.0.CO;2]
- Dvorak V F. 1984. Tropical Cyclone Intensity Analysis Using Satellite Data. NOAA Technical Report NESDIS 11, NOAA, 1-47
- Dvorak V F. 1995. Tropical Clouds and Cloud Systems Observed in Satellite Imagery: Tropical Cyclones. Workbook Volume 2. Available from NOAA/NESDIS, 5200 Auth Rd., NOAA

- Fetanat G, Homaifar A and Knapp K R. 2013. Objective tropical cyclone intensity estimation using analogs of spatial features in satellite data. *Weather and Forecasting*, 28(6): 1446-1459 [DOI: 10.1175/WAF-D-13-00006.1]
- Girshick R, Donahue J, Darrell T and Malik J. 2014. Rich feature hierarchies for accurate object detection and semantic segmentation// *Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE: 580-587 [DOI: 10.1109/CVPR.2014.81]
- Kidder S Q, Goldberg M D, Zehr R M, DeMaria M, Purdom J F W, Velden C S, Grody N C and Kusselson S J. 2000. Satellite analysis of tropical cyclones using the Advanced Microwave Sounding Unit (AMSU). *Bulletin of the American Meteorological Society*, 81(6): 1241-1260 [DOI: 10.1175/1520-0477(2000)081<1241:SAOTCU>2.3.CO;2]
- Knaff J A, Longmore S P, Demaria R T and Molenar D A. 2015. Improved tropical-cyclone flight-level wind estimates using routine infrared satellite reconnaissance. *Journal of Applied Meteorology and Climatology*, 54(2): 463-478 [DOI: 10.1175/JAMC-D-14-0112.1]
- Krizhevsky A, Sutskever I and Hinton G E. 2012. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6): 84-90 [DOI:10.1145/3065386]
- Lu X Q, Lei X T, Yu H and Zhao B K. 2014. An objective TC intensity estimation method based on satellite data. *Journal of Applied Meteorological Science*, 25(1): 52-58 (鲁小琴, 雷小途, 余晖, 赵兵科. 2014. 基于卫星资料进行热带气旋强度客观估算. *应用气象学报*, 25(1): 52-58)
- Olander T L and Velden C S. 2007. The advanced Dvorak technique: continued development of an objective scheme to estimate tropical cyclone intensity using geostationary infrared satellite imagery. *Weather and Forecasting*, 22(2): 287-298 [DOI: 10.1175/WAF975.1]
- Piñeros M F, Ritchie E A and Tyo J S. 2008. Objective measures of tropical cyclone structure and intensity change from remotely sensed infrared image data. *IEEE Transactions on Geoscience and Remote Sensing*, 46(11): 3574-3580 [DOI: 10.1109/tgrs. 2008.2000819]
- Piñeros M F, Ritchie E A and Tyo J S. 2011. Estimating tropical cyclone intensity from infrared image data. *Weather and Forecasting*, 26(5):690-698 [DOI: 10.1175/WAF-D-10-05062.1]
- Qian J F, Zhang C J, Yang B and Ma L M. 2015. Typhoon inner core wind speed modeling method by RBFNN and PDE based on infrared cloud image. *Infrared and Laser Engineering*, 44(2): 438-444 (钱金芳, 张长江, 杨波, 马雷鸣. 2015. 红外云图的台风内核风速建模的RBFNN和PDE方法. *红外与激光工程*, 44(2): 438-444) [DOI: 10.3969/j.issn.1007-2276.2015.02.007]
- Ritchie E A, Wood K M, Rodríguez-Herrera O G, Piñeros M and Tyo J S. 2014. Satellite-derived tropical cyclone intensity in the North Pacific Ocean using the deviation-angle variance technique. *Weather and Forecasting*, 29(3): 505-516 [DOI: 10.1175/WAF-D-13-00133.1]
- Rodríguez-Herrera O G, Wood K M, Dolling K P, Black WT, Ritchie E A and Tyo J S. 2015. Automatic tracking of Pregenesis tropical disturbances within the deviation angle variance system. *IEEE Geoscience and Remote Sensing Letters*, 12(2):254-258 [DOI: 10.1109/LGRS.2014.2334561]
- Velden C S, Olander T L and Zehr R M. 1998. Development of an objective scheme to estimate tropical cyclone intensity from digital geostationary satellite infrared imagery. *Weather and Forecasting*, 13(1): 172-186 [DOI: 10.1175/1520-0434(1998)013<0172:doast>2.0.co;2]
- Wang J and Jiang J X. 2005. An objective technique for estimating tropical cyclone intensity from geostationary meteorological satellite observation. *Journal of Applied Meteorological Science*, 16(3): 283-292 (王瑾, 江吉喜. 2005. 热带气旋强度的卫星探测客观估计方法研究. *应用气象学报*, 16(3): 283-292) [DOI: 10.3969/j.issn.1001-7313.2005.03.002]
- Wang X and Guo Q. 2014. Performance evaluation of objective tropical cyclone intensity determination with FY-2E/CIBLE results. *Journal of Infrared and Millimeter Waves*, 33(4): 442-449 (王新, 郭强. 2014. 基于FY-2E卫星CIBLE定标结果的台风客观定强效果评估. *红外与毫米波学报*, 33(4): 442-449) [DOI: 10.3724/SP.J.1010.2014.00442]
- Wood K M, Rodríguez-Herrera O S, Ritchie E A, Piñeros M F, Hernández I and Tyo J S. 2016. Tropical cyclogenesis detection in the north Pacific using the deviation angle variance technique. *Weather and Forecasting*, 30(6):1663-1672 [DOI: 10.1175/WAF-D-14-00113.1]
- Xu Y L, Zhang L and Xiang C Y. 2015. Typhoon intensity estimation technique and its operational application: with example of Dvorak technique. *Advances in Meteorological Science and Technology*, 5(4): 22-34 (许映龙, 张玲, 向纯怡. 2015. 台风定强技术及业务应用—以Dvorak技术为例. *气象科技进展*, 5(4): 22-34) [DOI: 10.3969/j.issn.2095-1973.2015.04.003]
- Yu H, Chan J C L and Duan Y H. 2006. Intensity estimation of tropical cyclones over the Western North Pacific with AMSU-A temperature data. *Journal of the Meteorological Society of Japan. Ser. II*, 84(3): 519-527 [DOI: 10.2151/jmsj.84.519]
- Yuan M, Zhong W, Wu Sand Tian L T. 2018. Detecting the intensity evolutions of northwest Pacific super typhoons in 2015 using deviation angle variance technique. *Climate Change Research Letters*, 7(6): 430-441 (袁猛, 钟玮, 武帅, 田路通. 2018. 利用偏角方差技术分析2015年西北太平洋超强台风全生命史过程演变特征. *气候变化研究快报*, 7(6): 430-441) [DOI: 10.12677/CCRL.2018.76047]
- Zhao Y, Zhao C F, Sun R Y and Wang Z X. 2016. A multiple linear regression model for tropical cyclone intensity estimation from satellite infrared images. *Atmosphere*, 7(3): 40 [DOI: 10.3390/atmos7030040]
- Zheng Y P, Li G Y and Li Y. 2019. Survey of application of deep learning in image recognition. *Computer Engineering and Applications*, 55(12): 20-36 (郑远攀, 李广阳, 李晔. 2019. 深度学习在图像识别中的应用研究综述. *计算机工程与应用*, 55(12): 20-36)

[DOI: 10.3778/j.issn.1002-8331.1903-0031]

Zheng F, Zeng Z H, Lei X T and Chen L S. 2016. A statistical study of rapid intensification of typhoons over coastal water of China. *Plateau Meteorology*, 35(1): 198-210 (郑峰, 曾智华, 雷小途, 陈联寿. 2016. 中国近海突然增强台风统计分析. *高原气象*, 35(1): 198-210) [DOI: 10.7522/j.issn.1000-0534.2014.00148]

Zhong P, Gong Z Q, Li S and Schönlieb C B. 2017. Learning to diver-

sify deep belief networks for Hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(6): 3516-3530 [DOI: 10.1109/TGRS.2017.2675902]

Zhou F Y, Jin L P and Dong J. 2017. Review of convolutional neural network. *Chinese Journal of Computers*, 40(6): 1229-1251 (周飞燕, 金林鹏, 董军. 2017. 卷积神经网络研究综述. *计算机学报*, 40(6): 1229-1251) [DOI: 10.11897/SP.J.1016.2017.01229]

## Deep learning estimation of tropical cyclone intensity along the southeast coast of China using FY-4A satellite

CUI Linli<sup>1</sup>, CHEN Zhao<sup>2</sup>, YU Xingxing<sup>2</sup>, CHEN Guangchen<sup>2</sup>, WANG Xiaofeng<sup>1</sup>, LU Yiwen<sup>1</sup>, GUO Wei<sup>1</sup>

1. Shanghai Ecological Forecasting and Remote Sensing Center, Shanghai Meteorological Service, Shanghai 200030, China;

2. College of Computer Science and Technology, Donghua University, Shanghai 201620, China

**Abstract:** A Tropical Cyclone (TC) is one of the most destructive meteorological disasters. The strong winds and heavy precipitation have significant effect on people's lives, property, and social and economic development. Therefore, the accuracy of the path and intensity prediction of TCs is always an important consideration in meteorological research. However, considering the complexity and variability of typhoon cloud patterns, the existing objective methods are usually based on statistical linear regression. Moreover, they still have deficiencies in expressing the dynamic changes of the complex characteristics of TC cloud patterns. The deep learning algorithm performs well in high-dimensional nonlinear modeling and accurately identifies the input mode with displacement and slight deformation. This algorithm finds significance in Tropical Cyclone (TC) monitoring with dynamic changes over time. To develop TC intensity estimation technology further in the field of satellite remote sensing, this study applied a new machine-learning technology to analyze and to study the TC intensity of FY-4A/AGRI data from China's second-generation stationary meteorological satellite.

First, a deep Convolution Neural Network (CNN) model was used to distinguish effectively and estimate quantitatively the TC intensity level and center wind speed. The images of day and night were placed into the convolution sampling channel of the CNN to obtain and combine same-size spectral features. Then, multilayer convolution, pooling, nonlinear mapping, and other operations were used to mine the input characteristics deeply. Finally, the TC intensity was estimated. The experiment was divided into the TC intensity classification test and the quantitative estimation test of the TC center maximum wind speed. The CNN model was used to convert the recognition of the TC intensity into the pattern recognition of satellite cloud images, which could classify and identify the TC level.

The experiment found that the recognition accuracy of the TC intensity was all above 95% regardless of the overall classification accuracy or the respective accuracy of day and night statistics. Compared with k-nearest neighbor, error back-propagation neural network, multiple linear regression, support vector machine, and other classical classification algorithms, it improves by 7-16 percentage points. Moreover, the CNN is also superior to the classical algorithm in terms of classification accuracy. The CNN model comprises two fully connected network layers (each layer has three neurons). The TC wind speed can be quantitatively estimated by prior training samples of the network parameters. Compared with the data of Tropical Cyclone 2017 Yearbook, the mean absolute error of the wind speed was 1.75 m/s, and the root mean square error of the wind speed was 2.04 m/s, which were lower than the corresponding errors of Deviation Angle Variance Technique (DAVT) by 85.70% and 84.38%. Thus, the CNN algorithm has a high application prospect in the quantitative estimation of typhoon intensity.

As the first second-generation Chinese geostationary meteorological satellite to be launched, FY-4A has its advantages of multichannel structure and high spatial and temporal resolution. On the basis of these features, the advantages of the techniques of the deep neural network, and the flexible structure of CNN, this study proposes an improved CNN model that is tailor-made for FY-4A data. The model has the capacity to mine the morphological characteristic of typhoons deeply and effectively and achieve high-precision typhoon intensity estimation. This model has positive research value and application prospect for the quantitative estimation of typhoon intensity.

**Key words:** remote sensing, tropical cyclone, FY-4/AGRI satellite image, CNN, objective intensity estimation

**Supported by** Natural Science Foundation of Shanghai, China (No. 18ZR1434100); Cooperation Fund Project of Shanghai Joint Meteorological Science and Technology Center (No. LHZX201601)