

结合双流 3D 卷积和监控图像的降水临近预报

杨素慧¹, 林志玮^{1,3,4*}, 赖绍钧², 刘金福^{1,5,6**}

¹ 福建农林大学计算机与信息学院, 福建 福州 350002;

² 福州市气象局, 福建 福州 350014;

³ 福建农林大学林学院, 福建 福州 350002;

⁴ 福建农林大学林学博士后流动站, 福建 福州 350002;

⁵ 福建农林大学海峡自然保护区研究中心, 福建 福州 350002;

⁶ 生态与资源统计福建省高校重点实验室, 福建 福州 350002

摘要 针对大部分降水临近预报产品无法兼顾高覆盖率、高准确率及低成本的问题, 提出一种基于室外监控图像和深度神经网络能预报未来 1 h 降水强度的方法。设计双流 3D 卷积神经网络来提取图像降雨信息的高维特征。该网络在低计算代价下自适应产生局部信息, 并通过双损失函数从整体和局部统筹网络, 提取降雨信息的时间特性和空间特性。实验结果表明, 在降水强度预报领域, 基于双损失函数的神经网络优于单损失函数。所提网络的误警率、命中率、临界成功指数、准确率在多数情况下优于其他模型。在模型效果可视化方面, 所提网络能有效提取降水图像的特征信息。所提降水临近预报方法有能力进行精细且低成本的降水临近预报。

关键词 图像处理; 3D 卷积; 室外监控图像; 光学图像; 降水临近预报

中图分类号 P457.6

文献标志码 A

doi: 10.3788/LOP57.201011

Precipitation Nowcasting Based on Dual-Flow 3D Convolution and Monitoring Images

Yang Suhui¹, Lin Zhiwei^{1,3,4*}, Lai Shaojun², Liu Jinfu^{1,5,6**}

¹ College of Computer and Information Sciences, Fujian Agriculture and Forestry University,
Fuzhou, Fujian 350002, China;

² Fuzhou Meteorological Bureau, Fuzhou, Fujian 350014, China;

³ College of Forestry, Fujian Agriculture and Forestry University, Fuzhou, Fujian 350002, China;

⁴ Forestry Post-Doctoral Station, Fujian Agriculture and Forestry University, Fuzhou, Fujian 350002, China;

⁵ Cross-Strait Nature Reserve Research Center, Fujian Agriculture and Forestry University,
Fuzhou, Fujian 350002, China;

⁶ Key Laboratory of Fujian Universities for Ecology and Resource Statistics, Fuzhou, Fujian 350002, China

Abstract At present, most of the precipitation nowcasting production is unable to consider the problems of high coverage, high accuracy, and low cost. Therefore, we herein propose a method based on outdoor monitoring images and deep neural network to forecast the rainfall intensity in the next 1 h. We design a dual-flow 3D convolutional neural network to extract high-dimensional features of rainfall information in images. The local information is adaptively generated at a low computational cost, and the temporal and spatial characteristics of rainfall information are extracted by the proposed network which integrates the whole network and the local network using a double loss function. The experimental results show that the neural network based on the dual loss function is better than that based on the single loss function in precipitation intensity forecasting. Percent of doom, false alarm rat, critical

收稿日期: 2019-12-24; 修回日期: 2020-01-21; 录用日期: 2020-02-25

基金项目: 中国博士后科学基金面上项目(2018M632565)、海峡博士后交流资助计划、福州市科技局社会发展项目(2018-S-109)

* E-mail: cwlin@fafu.edu.cn; ** E-mail: fjljf@126.com

success index, and the accuracy of the proposed network are better than those of other models in most cases. In terms of visualization of the model effect, the proposed network can effectively extract the feature information of the precipitation images. Therefore, the proposed precipitation nowcasting method is capable of fine and low-cost precipitation prediction.

Key words image processing; 3D convolution; outdoor monitoring image; optical image; precipitation nowcasting

OCIS codes 100.4996; 170.2655; 110.2960

1 引言

降水是指一种液态、固态或混合态水凝(冻)物从空中下落到地面的过程。作为陆地内各种水体直接或间接的补给源,降水是水文循环的重要环节之一^[1]。及时准确地预报降水有助于合理利用水资源,减小降水造成的经济损失^[2]。世界气象组织(WMO)规定,对未来0~6 h的天气状况及其所伴随的灾害性天气的发生、发展、演变及消亡的预报称为临近预报^[3-4]。现代社会对降水预报的及时性要求与日俱增,使得临近预报成为一项研究热点。

传统的临近降水预报可分为3类,即基于地面气象观测站数据的降水预报、基于雷达回波的降水预报、基于卫星的降水预报^[5]。地面气象观测站通过翻斗雨量计、雨量筒等测量工具获得降水强度数值,将该数值代入描述大气运动的方程组,通过解方程来计算未来的降水情况^[6]。地面气象站数据是目前公认的最准确的数据^[5]。然而,水滴附着、水滴蒸发、人工读数偏差会使对雨量设备的读数产生系统误差和人工误差。且气象站需建立在高处空旷地带,导致降水事件收集数据在空间上不连续。相较于气象站,雷达观测覆盖面广,现有的雷达每6 min可以拍摄20 km半径的雷达图^[7]。由雷达图得到的雷达反射率因子可推算出雨强,再由回波外推法可计算出未来雨势^[8],但是,雷达波束容易受到地形、山区、建筑等遮挡物的影响^[9]。卫星利用可见光、水汽、中长波红外光等探测通道对降水云外在形态进行探测,我国的FY-2F静止卫星在汛期每0.5 h可提供一张半径为5 km的卫星图像^[10]。研究证明,云图属性如云顶温度、云顶高度和降水有关,因此,可通过对云图属性进行建模来估算出降水强度^[11]。

现有降水强度采集装置低成本和高覆盖率不可兼得。雨量计的测量精度最高,成本相对较低,但是需要安装在高处空旷地带,会导致降水事件采集数据在空间上不连续。雷达与卫星能扩大降水强度采集覆盖范围,但是成本巨大,同时降水强度值是通过回波或云顶温度间接估算得出的,雷达回波强度依

赖于探测距离并受地物遮挡等影响,容易产生误差;卫星传感器易受天气影响,无法同时得到具有高时间分辨率和高空间分辨率的图像^[12-13]。

近年来,机器学习在预测任务时发挥出色,有学者开始尝试将机器学习与计算机视觉结合用于降水预报^[14-18]。降水预报的进程包括两个阶段,一是对当下降水事件的描述和识别,即识别,二是对未来一段时间内降水事件进行粗略至详细的估计,即预报。在识别方面,2005年,Kurihata等^[15]对挡风玻璃上的雨滴进行侦测,判断当下是否存在降水事件。2008年,Roser等^[16]通过支持向量机(SVM)对车载视频进行分类,并判别出当时室外场景的天气,包括清晰、小雨、大雨3类。在预报方面,2015年,Shi等^[17]率先使用长短期记忆卷积(ConvLSTM)机器学习方法处理雷达回波数据,以降水量0.5 mm/h为阈值界定是否有雨,进行香港地区未来1 h的临近降水预报。2017年,Shi等^[18]进一步提出一种能刻画自然运动的轨迹门控递归单元(Traj-GRU)模型,该模型能实现5类降水等级的预报。以上研究说明,基于机器学习和图像的降水识别及预报任务是可行的。

为此,本文提出一种结合室外监控图像和深度神经网络技术进行降水临近预报的方法。针对现有降水强度采集装置低成本和高覆盖率不可兼得的问题,所提方法整合现有资源,强化统筹整合,将广泛分布的监控摄像头作为降水资料采集装置,收集室外监控图像用于未来1 h的降水临近预报。本文提出的双流3D卷积神经网络在全局和局部两种数据流下使用3D卷积同步提取降水信息中的时间特征和空间特征。降水强度的预报依赖于时间与空间两个维度,空间域上降水微粒的大小、形状、密度,和时间域上降水微粒的降落速度是预报降水强度的重要因素。针对现有预报方法数据获取不连续、获取昂贵、特征提取效果差的不足,将室外监控图像应用于降水强度的预报,利用大量的室外监控图像构建IM-RAIN2018(Image-Rain2018)数据库,并设计了以室外监控图片为输入数据的双流3D卷积神经网络用于临近降水预报。

2 双流 3D 卷积模型

设计的降水强度预报模型以收集到的 1 h 内 12 张图片为输入,以下 1 h 的预报降水强度为输出,并将此模型命名为双流 3D 卷积神经网络,结构如图 1 所示。箭头代表信息流向,黑色白边长方体表示卷

积操作,白色黑边长方体表示池化操作,长方形表示全连接(FC)操作。图形旁边的数字代表经过相应操作后所得的特征图尺寸,如“12,224@3”表示该特征图的时间维度值为 12,在空间维度上宽和高为 224,共有 3 个通道。




图 1 双流 3D 卷积神经网络

Fig. 1 Dual-flow 3D convolution neural network

双流 3D 卷积神经网络包含干流和支流两条通路,分别处理原图输入的原始信息和由原图提取的粗粒度信息。在干流上,原图信息分别经过 64, 128,256,512,512 个卷积核,令通道数逐渐增加,最终达到 512。由于每一次卷积后紧跟池化操作,此时特征图的时间维度由 12 降至 1,空间维度由 224 降至 7。其后,连接 3 个全连接层,其维度分别为 2048,2048,60,最终得到预测的降水强度值。在卷积、池化、全连接操作中,逐步提取出能够代表原图且能预测出下一时刻降水强度的高维信息。支流用于自主提取原图中的粗粒度信息,支流上的信息由对干流信息进行平均池化得到,平均池化操作对所覆盖到池化核大小范围内的输入图片像素取平均值,由此可以对图片的全局信息进行综合汇总。支流上的信息同样分别经过 64,128,256,512 个卷积核,与干流不同的是,由于提取了全局信息,支流信息在尺寸上是干流的 1/2,且支流少一次卷积操作。在全连接层上,支流设置三层全连接层,其维度分别为 1024,1024,60。具体卷积操作为

$$O_i^1 = f_{\text{C3D}}(X_i, W_i) = X_i \otimes W_i. \quad (1)$$

池化操作为

$$O_i^2 = f_{\text{P3D}}(x_i) = \{\max(x_i)\}. \quad (2)$$

全连接操作为

$$O_i^3 = f_{\text{FC}}(X_i, W_i') = X_i W_i', \quad (3)$$

式中: X_i 为第 i 层的输入; x_i 为第 i 层的输入子集; $f_{\text{C3D}}(\cdot)$ 为卷积操作; W_i 为第 i 层的卷积权重; \otimes 为卷积运算符; $f_{\text{P3D}}(\cdot)$ 为池化操作; $\max(\cdot)$ 为取极大值; $\{\cdot\}$ 为取集合; $f_{\text{FC}}(\cdot)$ 为全连接操作; W_i' 为与输入 X_i 进行乘法运算的权重。

卷积操作如图 2 所示,在 3D 卷积中,输入的特征图在每个通道下有时间、宽、高三个维度,采用的每一个卷积核也是三维的,且与输入的特征图有相等的通道数。进行卷积操作时,在各个通道下,卷积核遍历输入特征图的每一个像素点并进行局部的求积、求和运算,最终输出时,对各个通道下同一个像素点位置相加。因此,3D 卷积操作可以同时提取时间域和空间域信息,避免了 2D 卷积缺乏时间相对关系的不足。

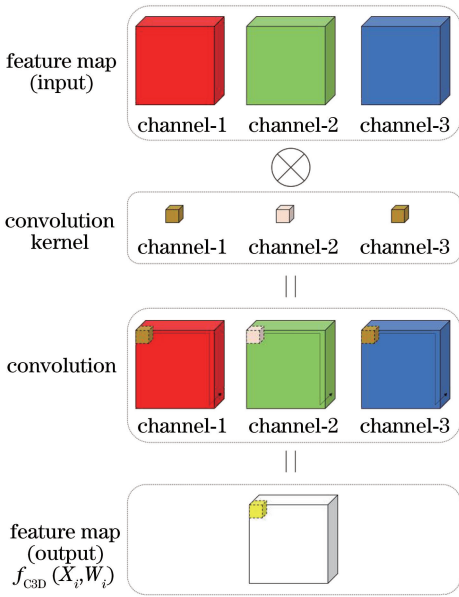


图 2 卷积操作

Fig. 2 Convolution operation

最大池化操作如图 3 所示,特征图的每个像素点具有像素值,经过最大池化操作,仅保留最大的像素值代表原有信息,特征图尺寸迅速减小。最大池化操作以无参数计算的方式提取出原有特征图的信息,能在低计算代价下自适应产生局部信息。

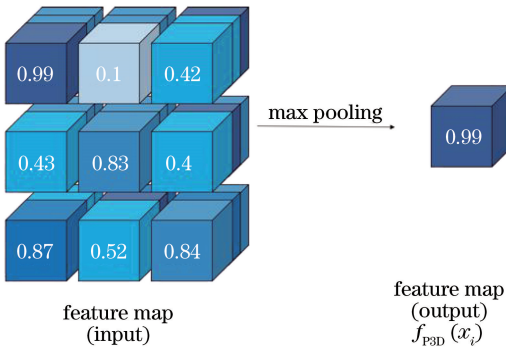


图 3 最大池化操作

Fig. 3 Max pooling operation

全连接操作如图 4 所示,此时输入特征图是一维的,输出特征图由输入特征图与权重经过线性运




图 4 全连接操作

Fig. 4 Fully connection operation

算得到。

在干流的基础上,以平均池化方式开辟出一条支流。首先,此设计能产生两个损失函数,即反映全局的干流损失函数和反映局部全局的支流损失函数,从整体和局部两方面同时调整损失函数,令最终的预测降水强度更接近真实的降水强度。其次,以机器学习的方式找到特征图中的有效信息,通过卷积神经网络自动学习到雨量图像的特征。在平均池化操作中,每一个局部的信息得以汇总,最终呈现在全局图上,此时的全局图相较上一个全局图,在分辨率上有所下降,但是在信息的概括能力上有所上升。最后,平均池化是强有力的信息提取方式,相较于神经网络中普遍使用的基于卷积提取信息的方式,池化操作不会产生参数,因此不会给神经网络的训练增加负担;相较于线性内插,池化操作以池化核遍历全图,计算每一个位置的局部平均值,概括能力更强。

3 试验雨量数据

以福建省福州市为降水临近预报的研究对象。福州是中国降水的主要城市之一,2018 年,福建省辖区内总降水强度为 1200~2000 mL,福州市部分地区降水强度超过 1600 mL,是中国东南部降水强度偏高的城市之一^[19]。福州市地处亚热带季风地区,东临太平洋,西部是戴云山脉,北部有武夷山脉,两大山脉抬升来自太平洋的暖湿气流,导致内陆降水强度大。其沿海地带受西太平洋副热带高压影响,常在夏季出现台风,导致暴雨出现^[20]。

为提高降水的监测能力,至 2019 年 9 月,福州共设立 8 个国家气象观测站,分别位于罗源、连江、长乐、福清、福州、闽侯、闽清、永泰^[21]。

使用的数据由福州的 8 个国家气象站采集,数据为包含降水事件的室外图片及其对应时点的降水强度,图片采集频率为每 5 min 1 张,分辨率为 1080 pixel×1920 pixel,数据采集时间为 2017 年 6 月至 2018 年 10 月,经过初步的图片筛选,共采集到 36048 张图片。

4 实验

实验分为三个部分,即模型架构的设计、所提模型与其他模型的评价指标对比、所提模型的效果可视化。首先,对所提框架进行消融实验,探究框架的有效部分;然后,对所提方法和现有的降水预报方法进行比较;最后,对所提网络在实验中产生的中间产物

绘制特征图,对最终预测的降水强度绘制克里金插值图,分别用于探究网络处理机制和网络最终效果。

4.1 评价指标

预测下一个时段的降水强度,有预测成功与预测失败两种结果,即预测值与观测值相等,预测值与观测值不相等,因此将预测认为是二分类问题。对于每一个降水强度的观测结果,若预测正确,定义为真阳性(TP),反之为假阴性(FN);对于每一个降水强度的预测结果,若观测一致,定义为假阳性(FP),反之为真阴性(TN)。由此,得到命中率(POD)、误警率(FAR)、临界成功指数(CSI)^[22]评价指标。另外,为综合表示所有降水预测结果,定义准确率(A),其中 n 表示使用模型预测的下 1 h 降水强度与地面观测站在下 1 h 观测到的降水强度相等的样本, N 表示模型测试的所有样本。

$$P_{\text{POD}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}}, \quad (4)$$

$$P_{\text{FAR}} = 1 - \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}}, \quad (5)$$

表 1 消融实验

Table 1 Ablation experiment

Model			A	B	C	D	E
Single-flow	Single loss	No pooling	✓				
	Single loss	Max pooling		✓			
Dual-flow		No pooling			✓		
	Dual loss	Max pooling				✓	
		average pooling					✓
A / %			82.19	81.00	84.23	84.20	84.46

为了提取神经网络中特征图的高维信息,提高网络的信息概括能力,在基础框架上加入分支,即每次卷积模块操作后,对所得特征图进行额外的特征抽取,在全连接层前将两条网络的特征图叠加在一起,得到具有单损失值的模型 B,此时准确率为 81.00%,较模型 A 稍有下降。因为此时模型添加了一条枝干,模型参数量增多,参数调整的难度超过了枝干带来的特征优化效果。

为降低参数调整的难度,在模型 B 的基础上,增加了一个损失值的计算,即不仅计算未来 1 h 的降水强度值,还计算当前 1 h 的降水强度值。可见,相较模型 A 和模型 B,双损失值下的双流 3D 卷积神经网络的准确率均有 2% 以上的提升。同时,根据模型 C、D、E,比较双流 3D 卷积神经网络中干流和支流不同的连接方式,发现平均池化法可得到最高的准确率,为 84.46%,即在测试集的 2600 个样本中,有 84.46% 的预测降水强度与地面观测站实

$$P_{\text{CSI}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}} + N_{\text{FP}}}, \quad (6)$$

$$A = \frac{n}{N}. \quad (7)$$

4.2 所提网络的形成过程

所提双流 3D 卷积神经网络历经以下过程:单路 3D 卷积神经网络(包括模型 A)→双流 3D 卷积神经网络(单损失值,包括模型 B)→双流 3D 卷积神经网络(双损失值,包括模型 C、D、E)。其中,单路 3D 卷积神经网络(模型 A)是双流 3D 卷积神经网络的干流,双流 3D 卷积神经网络(模型 C、D、E)的框架图与图 1 一致,仅干流与支流的连接方式有操作上的差别,该差别体现在对连接方式(最大池化、平均池化、无池化)的选择。模型 B 与模型 C、D、E 相比,仅有一个损失值。

表 1 表示双流 3D 卷积神经网络形成中不同时期的准确率。模型 A 为基础框架,整个网络没有用于精细处理特征图的分支,此时,由(7)式计算出的准确率达 82.19%。

际观测到的降水强度是一致的。

4.3 比较实验

目前,关于以深度神经网络方法结合室外监控降水图片进行降水临近预报的研究鲜有报道。因此扩大比较范围,选取以下方法作为比较对象:ConvLSTM 网络,该网络利用深度神经网络,基于雷达图像进行降水临近预报^[18];C3D 网络,该网络是 3D 卷积的经典框架之一,其中用到的 3D 卷积能够同时处理时间、空间中的宽、高共 3 个维度的信息,因此能够完成预测任务^[23];非对称 3D(Asy 3D)网络,该网络修改了 C3D 网络中卷积核的结构,能够减少参数量,且同样能进行预测^[24]。

表 2 为不同网络关于降水强度的测试结果。其中,“↑”说明值越大,框架效果越优秀,列属性为预测降水强度值(P_1)。本文对预测降水强度值的划分较为精细,共有 57 类,所用数据中降水强度值的极差为 56,降水强度的分度值为

1 mL · h⁻¹。由于并不是每一个降水强度值都出现在测试样本中,因此表 2 展示的是其中 32 种降水强度的预测效果。降水强度值越小,训练样本

越多,因为自然界中低降水强度的事件发生率更高,所以本研究收集到的样本集中于降水强度低的样本。

表 2 各个降水强度的测试结果比较

Table 2 Comparison of test results of each precipitation intensity

$P_1/(\text{mL} \cdot \text{h}^{-1})$	Proposed network			ConvLSTM			C3D			Asy 3D			Sample size
	$P_{\text{FAR}}/$	$P_{\text{POD}}/$	$P_{\text{CSI}}/$	$P_{\text{FAR}}/$	$P_{\text{POD}}/$	$P_{\text{CSI}}/$	$P_{\text{FAR}}/$	$P_{\text{POD}}/$	$P_{\text{CSI}}/$	$P_{\text{FAR}}/$	$P_{\text{POD}}/$	$P_{\text{CSI}}/$	
	% ↓	% ↑	% ↑	% ↓	% ↑	% ↑	% ↓	% ↑	% ↑	% ↓	% ↑	% ↑	
0	0.11	0.96	0.92	0.24	0.89	0.82	0.12	0.95	0.91	0.18	0.86	0.84	1227
1	0.19	0.78	0.79	0.42	0.61	0.59	0.18	0.74	0.78	0.31	0.67	0.68	501
2	0.22	0.72	0.75	0.35	0.47	0.55	0.29	0.72	0.72	0.43	0.62	0.60	261
3	0.22	0.76	0.77	0.35	0.61	0.63	0.29	0.73	0.72	0.36	0.69	0.67	193
4	0.24	0.76	0.76	0.37	0.57	0.60	0.27	0.72	0.73	0.32	0.51	0.59	103
5	0.17	0.70	0.76	0.30	0.51	0.59	0.26	0.70	0.72	0.36	0.43	0.52	69
6	0.03	0.69	0.81	0.32	0.40	0.51	0.13	0.62	0.72	0.38	0.60	0.61	42
7	0.23	0.59	0.67	0.27	0.28	0.41	0.29	0.56	0.63	0.39	0.44	0.51	39
8	0.24	0.62	0.68	0.11	0.38	0.53	0.36	0.67	0.65	0.54	0.52	0.49	21
9	0.26	0.56	0.64	0.10	0.36	0.51	0.18	0.56	0.67	0.47	0.40	0.45	25
10	0.21	0.55	0.65	0.14	0.30	0.44	0.17	0.50	0.62	0.33	0.90	0.77	20
11	0.21	0.81	0.80	0.11	0.30	0.44	0.16	0.78	0.81	0.27	0.41	0.52	27
12	0.20	0.80	0.80	0.00	0.20	0.33	0.00	0.80	0.89	0.33	0.40	0.50	5
13	0.00	0.71	0.83	0.00	0.43	0.60	0.00	0.57	0.73	0.00	0.71	0.83	7
14	0.33	0.89	0.76	0.33	0.44	0.53	0.25	0.67	0.71	0.33	0.44	0.53	9
15	0.00	0.33	0.50	0.00	0.33	0.50	0.00	0.33	0.50	0.25	0.50	0.60	6
16	1.00	0.00	0.00	1.00	0.00	0.00	1.00	0.00	0.00	0.00	1.00	1.00	1
17	0.00	0.80	0.89	0.00	0.40	0.57	0.00	0.80	0.89	1.00	0.00	0.00	5
18	0.00	0.75	0.86	0.00	0.50	0.67	0.00	0.75	0.86	0.00	0.50	0.67	4
19	0.00	0.43	0.60	0.00	0.29	0.44	0.25	0.43	0.55	0.00	0.86	0.92	7
2	0.25	0.86	0.80	0.38	0.71	0.67	0.33	0.86	0.75	0.00	0.43	0.60	7
21	0.00	1.00	1.00	0.33	0.33	0.44	0.29	0.83	0.77	0.20	0.67	0.73	6
22	0.00	1.00	1.00	0.00	1.00	1.00	0.00	1.00	1.00	0.00	1.00	1.00	2
24	0.00	0.50	0.67	0.00	0.50	0.67	0.00	0.50	0.67	0.00	1.00	1.00	2
25	0.50	1.00	0.67	0.00	1.00	1.00	0.00	1.00	1.00	0.00	1.00	1.00	1
27	0.00	1.00	1.00	0.00	0.33	0.50	0.25	1.00	0.86	0.00	0.67	0.80	3
29	1.00	0.00	0.00	1.00	0.00	0.00	1.00	0.00	0.00	1.00	0.00	0.00	1
32	0.00	1.00	1.00	0.00	1.00	1.00	0.00	1.00	1.00	0.00	1.00	1.00	1
34	1.00	0.00	0.00	1.00	0.00	0.00	1.00	0.00	0.00	1.00	0.00	0.00	1
38	1.00	0.00	0.00	1.00	0.00	0.00	1.00	0.00	0.00	0.00	1.00	1.00	1
46	1.00	0.00	0.00	1.00	0.00	0.00	1.00	0.00	0.00	0.00	1.00	1.00	1
56	0.00	1.00	1.00	1.00	0.00	0.00	0.00	1.00	1.00	0.00	0.50	0.67	2

表 2 中加粗的数字代表所提网络不及比较网络的情况。可见:在 8~12 mL/h 的降水强度下,即大雨等级下,所提网络表现较差,误警率高于 ConvLSTM 网络,即所提网络容易出现没有大雨但是预报将来 1 h 有大雨的错误预报,但是误警率仅能体现预报效果的一个方面,从临界成功指数上看,所提网络优于 ConvLSTM 网络;在降水强度为 25 mL/h 时,所提网络的误警率和临界成功指数均

劣于 ConvLSTM 网络,可能是因为该降水强度下的样本量仅为 1,网络参数训练不足;在 8~12 mL/h 和 25 mL/h 的降水强度下,所提网络劣于 C3D 网络,在 15~20 mL/h 的降水强度下,所提网络劣于 Asy 3D 网络,但注意到,在劣于其他网络的降水强度下,样本量均低于 20,不到测试样本的 1.2%;而在 0~7 mL/h 的降水强度下,样本量达到测试样本的 94%,所提网络的评价指标大部分优于其他

网络。

综合表示所有降水强度的预测结果,在 2600 个测试样本中,所提网络的准确率达 84.46%,ConvLSTM 网络的准确率为 70.27%,C3D 网络的准确率为 82.19%,而 Asy 3D 网络的准确率为 73.96%。从准确率比较可进一步说明,所提降水临近预报方法更能进行较为精确的降水临近预报。

通过混淆矩阵,比较双流 3D 卷积神经网络与其他网络的预报效果,如图 5 所示。在混淆矩阵中,横坐标为预测值,纵坐标为真实值,图例为准确率,每一个单元的颜色可体现识别效果,对角线上的单

元格越浅,代表正确预测的样本越多,预测效果越好。从图 5 可知,相较于其他网络的预测可视化图,所提双流 3D 卷积神经网络的对角线颜色更浅,表示预测正确的样本更多。而预测错误的样本更靠近对角线,即预测误差更小,且预测错误的样本多是将高降水强度预报为低降水强度,这可能是由于低降水强度的样本远远多于高降水强度样本,模型会将不常见到的高降水强度样本错认为是低降水强度样本。在图 5(c)的 C3D 网络混淆矩阵中出现了一条空白线,这是由于该网络预测出了不属于测试数据中的降水强度。

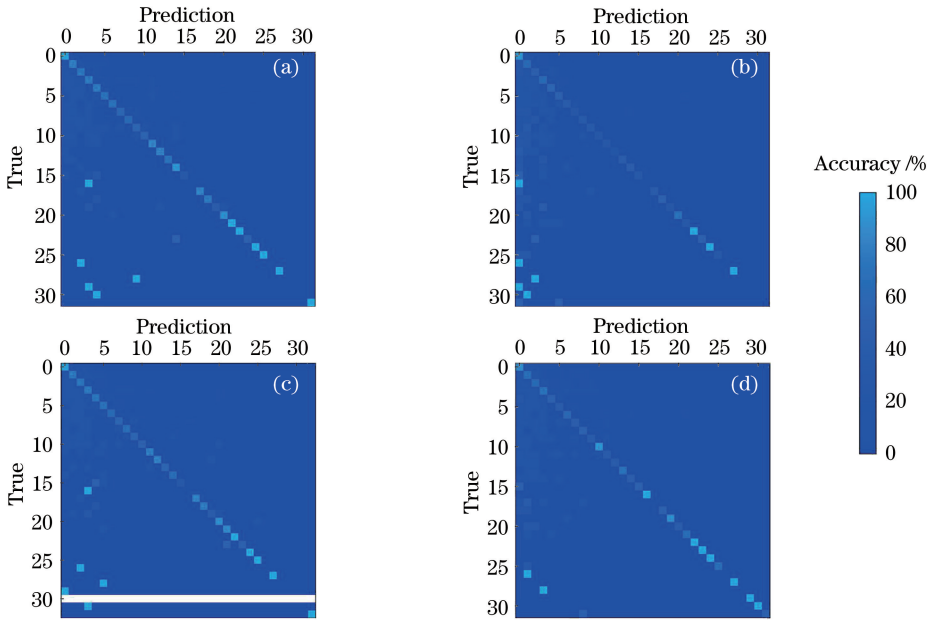


图 5 预报效果。(a)所提网络;(b) ConvLSTM 网络;(c) C3D 网络;(d) Asy 3D 网络

Fig. 5 Prediction effect. (a)Proposed network; (b)ConvLSTM network; (c)C3D network; (d) Asy 3D network

图 6 为在训练情况下,不同网络的准确率与损失值。图 7 为在测试情况下,不同网络的准确率与损失值。每张图中,横坐标代表处理整个数据集的序数,纵坐标代表准确率或损失值。可见:无论在测

试还是训练中,双流 3D 卷积神经网络的准确率曲线和损失值曲线都能更早地进入水平状态,代表网络参数训练更快;且在测试状态下,双流 3D 卷积神经网络有更高的准确率和更低的损失值,分别为

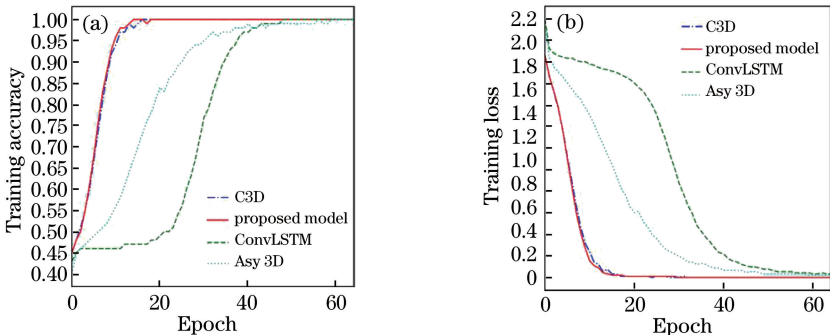


图 6 训练情况下的准确率和损失值。(a)准确率;(b)损失值

Fig. 6 Accuracy and loss value under training. (a) Accuracy; (b) loss value




图7 测试情况下的准确率和损失值。(a)准确率;(b)损失值

Fig. 7 Accuracy and loss value under test. (a) Accuracy; (b) loss value

84.46%和0.78。也就是说,对测试集中2600个室外监控样本进行降雨强度预测,有84.46%的样本预测降水量值与观测站实地观测到的降水量值是一致的。实验结果表明,所提双流3D卷积神经网络拥有更强的网络稳定性和预测准确性。

4.4 网络探究

以2018年10月16日21时到22时收集的室外照片及降水强度为输入,输出2018年10月16日22时到23时8个站点的降水强度预报值。为验证所提方法的准确性,除了对8个站点收集到的降水强度真实值进行比较外,以普通克里金插值方式,绘制2018年10月16日22时未来1h的预报图。通过与中央气象局发布的2018年10月16日22时至23时降水实况图比较,可以发现,本文提出的预报图和官方的降水实况图在数值上接近,在数据分布上相似。由于测量方式的不同,官方的降水数据常有差异,因此,本文忽略数值上的不同,仅从数据分布上看,认为插值的源数据,即本文预报的降水强度

是有实用价值的。

图8表现了不同深度卷积模块下的特征图,第1行由左至右分别为原始输入图、经过降噪的网络输入图、第1~5个卷积模块下的特征图。图8第1行为干流的特征图,第2行为支流的特征图,可见,虽然支流和干流有相同的拓扑结构,但支流提取的特征与干流提取的不同。原因大致分为3点:网络权重的初始化是随机的,因此干流和支流的权重不是一致的;网络通过最小化损失值调整参数,在调整时,会优先调整令损失值下降最快的参数,干流和支流虽然有相同的拓扑结构,但发挥不同的特征提取功能,因此参数的改变是不一致的;网络中存在随机删除神经元的策略,故干流和支流中各层的输入是不一样的。同样可以发现,支流特征的色彩区块更大,说明对于原始输入的特征,支流有比干流更强的概括能力。实验结果表明,干流和支流共同作用时提取了不同的特征信息,且支流能提取到有利于降水临近预报的高维度特征信息。




图8 不同深度卷积模块下的特征图

Fig. 8 Characteristic graphs under different depth convolution modules

5 结论

传统的人工观测区分不同降水强度方法误差大、自动化观测水平低。现代光学降水测量技术设备成本高、校准频繁复杂、寿命低。在中国天网工程

的背景下,摄像头分布广泛,将所得室外影像数据作为神经网络的输入进行端对端的降水强度识别,是一个鲜有涉足的领域。设计的双流3D卷积神经网络以干流率先提取输入影像的特征,以支流额外学习所提取特征的更深层信息,在低计算代价下能自

适应产生局部的概括信息。使用双损失函数,使干流和支流互相促进反馈,进行高精度的降水临近预报。所提方法的准确率达 84.46%,可以较好地用于农业灌溉系统、城市防洪排涝系统设计及管理 etc 社会生产活动中。

参 考 文 献

- [1] Song Z J, He J X, Li X H, et al. Review of research progress in new generation satellite-borne precipitation products[J]. *Meteorological Science and Technology*, 2018, 46(4): 631-637.
宋子珏, 何建新, 李学华, 等. 星载降水测量雷达降水产品研究进展[J]. *气象科技*, 2018, 46(4): 631-637.
- [2] Vu T M, Raghavan S V, Liong S Y, et al. Uncertainties of gridded precipitation observations in characterizing spatio-temporal drought and wetness over Vietnam [J]. *International Journal of Climatology*, 2018, 38(4): 2067-2081.
- [3] Hu R H. Research on application of parallel computing in nowcasting system [D]. Guangzhou: South China University of Technology, 2015.
胡荣华. 并行计算在临近天气预报系统中的应用研究[D]. 广州: 华南理工大学, 2015.
- [4] Wang Y C, Kong R, Chen M X. Operational application progress of convective weather proximity prediction technology [C] // The Fourth National Symposium on Disastrous Weather Forecast Technology, January 1, 2007, Beijing, China. Beijing: National Meteorological Center and Department of Prediction and Disaster Reduction, China Meteorological Administration, 2007: 35-37.
王迎春, 孔荣, 陈明轩. 对流天气临近预报技术的业务应用进展[C]//第四届全国灾害性天气预报技术研讨会, 1月1日, 2007, 北京, 中国. 北京: 中国气象局国家气象中心与预测减灾司, 2007: 35-37.
- [5] Zhang Y Y. Spatial downscaling of TRMM precipitation data in the red river basin [D]. Kunming: Yunnan University, 2018.
张月圆. 红河流域 TRMM 降水数据空间降尺度研究[D]. 昆明: 云南大学, 2018.
- [6] Clark P, Roberts N, Lean H, et al. Convection-permitting models: a step-change in rainfall forecasting [J]. *Meteorological Applications*, 2016, 23(2): 165-181.
- [7] Zhang Y, Wu S G, Zhang Y P, et al. Identification and effect verification of convective cloud precipitation in rainstorm processes based on SWAN mosaic products[J]. *Meteorological Monthly*, 2019, 45(2): 180-190.
张勇, 吴胜刚, 张亚萍, 等. 基于 SWAN 雷达拼图产品在暴雨过程中的对流云降水识别及效果检验[J]. *气象*, 2019, 45(2): 180-190.
- [8] Xu W J, Su D B, Jia L L, et al. Summer drop size distribution characteristics in Beijing from laser-based optical disdrometer [J]. *Laser & Optoelectronics Progress*, 2012, 49(12): 120103.
徐文静, 苏德斌, 伽丽丽, 等. 利用激光降水粒子谱仪观测北京夏季雨滴谱特征[J]. *激光与光电子学进展*, 2012, 49(12): 120103.
- [9] Gou Y B. The optimization and evaluation of quantitative precipitation estimation based on multi-radar mosaic [D]. Beijing: Chinese Academy of Meteorological Sciences, 2014: 7-9.
勾亚彬. 基于雷达组网拼图的定量降水估测算法优化及效果评估[D]. 北京: 中国气象科学研究院, 2014: 7-9.
- [10] Chen D D, Zhao J, Wang B L, et al. Comparison of cloud top height observation between FY-2F satellite and millimeter-wave cloud radar [J]. *Meteorological Science and Technology*, 2019, 47(3): 495-501.
陈冬冬, 赵静, 王柏林, 等. FY-2F 卫星和毫米波云雷达云高观测的个例对比分析[J]. *气象科技*, 2019, 47(3): 495-501.
- [11] Goyal S, Kumar A, Mohapatra M, et al. Satellite-based technique for nowcasting of thunderstorms over Indian region [J]. *Journal of Earth System Science*, 2017, 126(6): 79.
- [12] Cheng C L, Chen M, Chen M X, et al. Comparative experiments on two high spatiotemporal resolution blending algorithms for quantitative precipitation nowcasting [J]. *Acta Meteorologica Sinica*, 2019, 77(4): 701-714.
程丛兰, 陈敏, 陈明轩, 等. 临近预报的两种高时空分辨率定量降水预报融合算法的对比试验[J]. *气象学报*, 2019, 77(4): 701-714.
- [13] Fang T Z, Qin P Y, Wang L M, et al. High temporal and spatial resolution green vegetation coverage generation and its application in soil erosion monitoring [J]. *Acta Ecologica Sinica*, 2019, 39(15): 5679-5689.
方天纵, 秦朋遥, 王黎明, 等. 高时空分辨率植被覆盖获取方法及其在土壤侵蚀监测中的应用[J]. *生态学报*, 2019, 39(15): 5679-5689.
- [14] Guo L, Lin Y T, Zhang Z H, et al. Mechanism of laser coloration of stainless steel and color prediction based on neural network [J]. *Chinese Journal of*

- Lasers, 2016, 43(11): 1102008.
- 郭亮, 林远添, 张震华, 等. 不锈钢激光着色机理及基于神经网络的颜色预测[J]. 中国激光, 2016, 43(11): 1102008.
- [15] Kurihata H, Takahashi T, Ide I, et al. Rainy weather recognition from in-vehicle camera images for driver assistance[C]//IEEE Proceedings. Intelligent Vehicles Symposium, June 6-8, 2005, Las Vegas, NV, USA. New York: IEEE, 2005: 205-210.
- [16] Roser M, Moosmann F. Classification of weather situations on single color images [C] // 2008 IEEE Intelligent Vehicles Symposium, June 4-6, 2008, Eindhoven, Netherlands. New York: IEEE, 2008: 798-803.
- [17] Shi X J, Chen Z R, Wang H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting [EB/OL]. (2015-09-19) [2019-12-23]. <https://arxiv.org/abs/1506.04214>.
- [18] Shi X J, Gao Z H, Lausen L, et al. Deep learning for precipitation nowcasting: a benchmark and a new model [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, California, USA. New York: Curran Associates, 2017, 5622-5632.
- [19] China Meteorological Administration. China climate bulletin in 2018 [EB/OL]. (2019-03-18) [2019-11-12]. http://www.cma.gov.cn/root7/auto13139/201903/t20190319_517664.html.
中国气象局. 2018年中国气候公报[EB/OL], (2019-03-18)[2019-11-12]. [http://www.cma.gov.cn/root7/](http://www.cma.gov.cn/root7/auto13139/201903/t20190319_517664.html)
- [20] Lin Z C. Study on estimation of short duration PMP [D]. Nanjing: Nanjing University of Information Science & Technology, 2018: 16.
林智琛. 短历时可能最大降水估算研究[D]. 南京: 南京信息工程大学, 2018: 16.
- [21] Fuzhou Marine and Fishery Bureau. Fishery meteorological report of Fuzhou city in early September 2019 [EB/OL]. (2019-09-11) [2019-11-12]. http://hyj.fuzhou.gov.cn/zz/jsfwykp/yykp/201909/t20190911_3037804.htm.
福州市海洋与渔业局. 福州市2019年9月上旬水产气象旬报[EB/OL]. (2019-09-11) [2019-11-12]. http://hyj.fuzhou.gov.cn/zz/jsfwykp/yykp/201909/t20190911_3037804.htm.
- [22] Luo Y, Zhao W, Zhai J Q. Dichotomous weather forecasts score research and a new measure of score [J]. Quarterly Journal of Applied Meteorology, 2009, 20(2): 129-136.
罗阳, 赵伟, 翟景秋. 两类天气预报评分问题研究及一种新评分方法[J]. 应用气象学报, 2009, 20(2): 129-136.
- [23] Tran D, Bourdev L, Fergus R, et al. Learning spatiotemporal features with 3D convolutional networks[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 4489-4497.
- [24] Yang H, Yuan C F, Li B, et al. Asymmetric 3D convolutional neural networks for action recognition [J]. Pattern Recognition, 2019, 85: 1-12.