

基于神经网络和模型集成的短时降雨预测方法

郭尚瓚¹ 肖达¹ 袁行远²

(1 北京邮电大学计算机学院, 北京 100876; 2 北京彩彻区明科技有限公司, 北京 100083)

摘要: 为了得到更精准的短时降雨预测结果, 提出了一个基于神经网络的预测模型, 可通过多普勒雷达图像序列预测某区域36min内的降雨概率。通过对神经网络和传统光流法的对比分析, 还提出了一种结合了两种方法各自优点的集成预测模型。集成模型学习到了更丰富的降雨带变化模式。在一个包含多地、多月真实雷达数据的大规模数据集上的实验表明, 神经网络模型实现了具有较高精度的短时降雨预测, 且集成模型在整体的预测性能上有明显改进。

关键词: 短时降雨预测, 神经网络, 多层感知器, 光流, 雷达图像

DOI: 10.3969/j.issn.2095-1973.2017.01.013

A Short-Term Rainfall Prediction Method Based on Neural Networks and Model Ensemble

Guo Shangzan¹, Xiao Da¹, Yuan Xingyuan²

(1 School of Computer Science, Beijing University of Posts and Telecommunications, Beijing 100876

2 Beijing Colorful Clouds Technology Co.Ltd, Beijing, 100083)

Abstract: In order to obtain higher accurate in short-term rainfall prediction, a neural network-based prediction model is proposed. It can predict the rainfall probability in 36 minutes using Doppler radar image sequence. By comparatively analyzing the neural network-based method and the traditional optical flow-based method, an ensemble prediction model, which combines the advantages of both methods, is also developed. The ensemble model learns more diverse rainfall changing patterns. The methods are evaluated on a large dataset that contains real radar data spanning across multiple radar stations and for months. Experimental results show that the neural network model achieves prediction with high accuracy and that the ensemble model obtains obvious improvement in overall prediction performances.

Keywords: short-term rainfall prediction, neural network, multilayer perceptron, optical flow, radar image

0 引言

通过多普勒气象雷达来进行短时降雨预测已经成为一个越来越受关注的问题, 在防汛和暴雨预警等应用中扮演着重要角色。“短时”降雨预报可以针对快速发生的严重气象事件给出及时准确的警报。由于天气变化发生有时非常快速, 因此我们需要一个高时空分辨率的数据源, 而多普勒雷达图6min更新的时间分辨率和1km²的空间分辨率刚好可以满足这一需求。

在过去十几年中, 通过雷达影像进行短时降雨预报已经发展出了许多技术手段^[1], 但是这些方法表现出的性能取决于所考虑的区域的天天气条件, 并不是十分稳定, 因此还没有一种在所有可能条件下都能展现良好性能的方法。而神经网络相比于传统的统计技术手段来说, 展示出了更多的优点。神经网络的主要特

点是可将输入的数据通过任意程度的非线性映射到输出数据, 它具有很强的学习能力和拟合高度非线性函数的能力是众所周知的^[2]。通过逐层的特征变换, 将样本在原空间的特征表示变换到一个新的特征空间, 从而提升分类或预测的准确性。这种方法区别于人工规则构造特征的方法, 利用大数据来学习特征, 更能够刻画数据丰富的内在信息。

本文的主要工作包括两点: 第一, 区别于传统技术手段, 利用深度神经网络中的多层感知器模型(MLP)方法, 根据实时的多普勒雷达图像, 对未来36min内的降雨进行了预测, 取得了优于传统手段的结果。同时, 将单点MLP模型映射成了具有相同逻辑结构的卷积网络模型, 提高了实际应用中预测多目标点的时间性能。第二, 通过将神经网络与传统技术手段结合组成集成模型, 进一步改进了预测结果的误报率与漏报率。

1 相关研究

多普勒天气雷达是基于多普勒效应进行工作

收稿日期: 2016年10月12日; 修回日期: 2016年12月7日

第一作者: 郭尚瓚(1990—), Email: buptgszqq@163.com

资助信息: 国家自然科学基金(61202082); 国家“二四二”信息安全计划基金项目(2014A120, 2015A071)

的^[3-4]，工作原理如下：雷达先向空中发射脉冲式电磁波，电磁波以近似于直线的路径在大气中传播，当遇到云雨等降水粒子就会向四面八方散射，其中后向散射波返回并被雷达接收，也就是回波信号，对这种回波信号的监测可以确定降水粒子的空间位置。对降雨区而言，雨滴的直径越大，该降雨区所产生的雷达回波强度越强。因此，雷达图像上每个像素点的像素值即为回波信号的强度（基本反射率），可以根据该值判定该点对应区域的降雨强度。

在国内外的研究中，基于雷达图像的短时降雨预测技术已发展出了一些技术手段^[1]。1) 基于持续性的预测方法。该方法假设在预测帧中每个像素均与前一帧对应位置的像素值相等，因此只能完全依赖于实时更新的雷达图像，并且预测有延迟性。2) 基于线性计算的方法。这种方法通过线性映射进行预测，帧 $N+1$ 的各像素值是根据帧 $N-1$ 和 N 相同位置的像素值进行线性插值得到的。3) 稳态方法。这种方法假定在雷达图像中的降雨结构相较于前一帧虽然被移动了，但是尺寸和强度维持不变。帧 $N+1$ 被假定为帧 N 通过适当的运动矢量得到的图像，而该运动矢量被假定与帧 $N-1$ 与帧 N 之间的运动矢量相同。后者是通过将帧 $N-1$ 沿一些固定方向进行最大范围为8像素的移动，并计算移动结果与帧 N 之间的交叉相关指数而选择出来的。但是，由于降雨带的形状变化以及生长和消散，传统的位移矢量计算方法对于降雨带的位移判断并不是很准确，这也导致该方法在降雨预测领域的性能较不稳定。

近年来，一种基于光流的方法也被用于短时降雨预测问题中^[5-6, 10-11]。光流是指特定运动物体的局部位移矢量。光流图像中，所有像素点构成了一个二维瞬时速度场，该二维速度矢量是景物中可见点的三维速度矢量在成像表面的投影，所以光流可以较准确地反映被观察物体各部分的运动信息^[7]。基于光流的预测法与稳态方法原理类似，通过计算两帧间的运动矢量，完成帧 $N-1$ 对帧 N 的降雨结构的映射。但不同的是，稳态方法中同一帧所有像素的运动矢量均相同，而光流使用多项式扩展技术，可以针对每个像素计算出它们各自的运动矢量。因此，利用光流方法得到的预测结果中，降雨带的结构形状不再完全与帧 $N-1$ 相同，从而令光流法具有较好的健壮性。但由于降雨带自身的特性，使之很容易生长或消散，光流法对于这些情况的预测有一定的局限性。另外，由于光流对于快速运动物体的捕捉性较差，若要预测未来一段时间内的降雨，需利用光流逐帧推算，从而使得算法的时间复杂度较高。

2 应用于短时降雨预测的多层感知器模型

2.1 多层感知器模型

本文提出的新的用于短时降雨预测的神经网络模型是利用多层感知器（Multilayer Perceptron, MLP）实现的。MLP是单层感知器的推广，克服了单层感知器不能对线性不可分数据进行识别的弱点。由Kolmogorov定理可以推出，给定足够节点个数，一个双隐层感知器能够逼近任意复杂的非线性函数^[8]。MLP是一种前向结构的人工神经网络，由多个节点层所组成，其中第一层为输入层，最后一层为输出层，中间部分为一个或多个隐含层。图1给出了一个包含一个隐含层的MLP的网络结构。除输入节点外，每个节点都是一个带有非线性激活函数的多输入单输出神经元。




图1 多层感知器网络结构示意图

Fig. 1 Architecture of multilayer perceptron

MLP可以使用多种形式的激活函数，但为了训练过程使用的反向传播算法能够进行有效学习，激活函数必须限制为可微的。假设一个神经元的输入为 $x_i (i=1, 2, \dots, n)$ ，使用sigmoid函数作为激活函数，则该神经元输出为：
$$o = \sigma \left(\sum_{i=1}^n w_i \cdot x_i \right)$$
其中， σ 是sigmoid函数， w_i 是第 i 个输入对应的权重系数。假设MLP只有一个隐层，则隐层神经元的输出为 $h^{(1)} = \sigma(W^{(1)}x + b^{(1)})$ ，输出层神经元的输出为 $h^{(2)} = \text{softmax}(W^{(2)}h^{(1)} + b^{(2)})$ ，总模型为：
$$h_{w,b}(x) = \text{softmax} \left(W^{(2)} \left(\sigma(W^{(1)}x + b^{(1)}) \right) + b^{(2)} \right)$$
，其中 $W = (W^1, W^2), b = (b^1, b^2)$ 为通过训练确定的模型参数。MLP通过误差反向传播算法（BP算法）进行训练，从而达到误差的最小化。BP算法是一个有监督学习算法，对于一个输入样本，经过网络的正向传播得出一个输出，并根据损失函数计算输出与真实值之间的误差。在 K 分类问题中一般采用交叉熵损失函数。得到网络的输出后，可根据损失函数用反向传播（BP）算法对网络参数进行优化。

2.2 利用 MLP 进行短时降雨预测的方法

2.2.1 数据预处理

在所有的机器学习算法中，预处理工作均对模

型的性能有很大影响。本文中，预测使用的原始数据是多普勒雷达图。它是由雷达图像组成的帧序列，每相邻两帧间的时间间隔为6min。每一帧分辨率为480×480，其中每个像素值代表空间维度1km×1km的方形区域的基本反射率，范围处于0~70，值越高代表对应区域降雨的可能性越大。

在MLP的训练过程中，一个最大的问题是过拟合现象。过拟合反映的是在模型训练过程中，MLP对学习样本达到非常高的逼近精度，但对非学习样本（如测试样本）的逼近误差随着MLP的训练次数而呈现先下降后上升的奇异现象。而在降雨预报问题中，噪声干扰是原始雷达数据的一大特点。当神经网络结构较为复杂，而训练数据量不够丰富的情况下，噪声的存在会导致MLP的严重过拟合。为了防止过拟合、减小噪声对模型训练的影响，采用了两种技术手段对数据进行预处理。1) 高斯平滑。高斯滤波是一种线性平滑滤波器，适用于消除符合高斯分布的噪声，广泛应用于图像处理的减噪过程。像素值由自身以及其周围的像素值加权决定，客观上减小了和周围像素的差异。高斯滤波一般有两种实现方式，一是用离散化窗口滑窗进行卷积，另一种是傅里叶变换。本实验采用第一种方法，卷积核的大小为5×5。2) 数据下采样。本文对原始输入数据进行了时间维度和空间维度的平均下采样，从而减小了网络输入层的节点个数，简化了模型的结构，并减小了噪声点对输出的影响。其中，时间维度的下采样间隔为2，空间维度的下采样间隔为4。采样后，数据帧间隔时间变为12min，帧内像素代表的空间区域变为4km×4km。在实际上线应用的系统中，在高斯平滑和数据下采样之前，还使用一个基于人工规则的去噪声系统，综合利用同一雷达站近期历史雷达图中统计出的重复模式、实时用户反馈等信息尽可能去除原始雷达资料中的噪声。受篇幅限制，本文对此不再赘述。

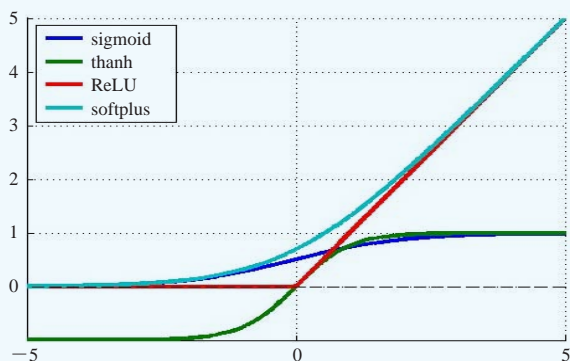


图2 四种非线性映射函数的函数曲线
Fig. 2 Curves of 4 nonlinear activation functions

另一方面，由于短时降雨预测问题要求结果具有可读性，因此本文的研究目标设定为目标像素点未来36min内是否有降雨，即二分类问题。假设当前帧为第N帧，根据目标像素点在(N+1)~(N+3)帧的值中是否包含超过阈值的点，将该样本显式的标记为“降雨”和“不降雨”这两个类别。阈值的设定依照气象学常用标准，多普勒雷达图中基本反射率大于15dBz的像素点即代表降雨区域，否则代表非降雨区域。需要指出，之所以选取一个固定大小的雷达反射率(15dBz)作为判定是否降雨的阈值，主要是方便将预测定义为二分类问题从而训练分类器模型，该假设和实际感知的降雨情况可能存在不一致的情况。实验表明，如果训练直接预测雷达反射率大小的回归模型效果不好。

2.2.2 MLP 模型结构

MLP模型可分为3部分，即输入层、隐含层和输出层。假设预测对象位置为(x, y)，预测目标为第N+1帧到第N+3帧中该位置的像素点是否有大于阈值的值出现（即对应该位置在半小时之内是否有降雨）。抽取下采样后大小为3×15×15的数据块，代表在第N-2到第N帧连续的3帧中，以(x, y)为中心点抽取的长宽为15×15像素的矩形图像。每个像素值对应于输入层的一个节点，将该3×15×15的数据块展开成一维向量作为模型的输入，因此输入层的节点个数共为675。输出层的节点个数为1，其输出值是0~1的实数，代表预测目标位置半小时内降雨的概率。输入层与输出层之间为K个隐含层(K≥1)。

在网络中，输入层直接为原始像素值，无非线性映射。而隐含层使用Rectified Linear Function (ReLU) 作为非线性激活函数，输出层使用sigmoid函数作为非线性激活函数。图2给出了几个常用非线性函数的函数曲线。可以看到，ReLU能够实现非线性映射，同时由于被激活部分是线性的，因此大大减




图3 使用MLP模型进行降雨预测的网络结构
Fig. 3 Network architecture of MLP model for rainfall prediction

少了计算开销，更加适用于参数较多的神经网络层。图3给出了本文使用的MLP模型的结构。

2.2.3 用于多点预测的卷积 MLP 模型

由于MLP模型的处理单位为单一像素点，因此若需要预测多点，则需逐一对每个像素点应用MLP模型从而得到全部结果。考虑到模型的时间性能，在实际的降雨预测问题中，可将上述MLP模型转换为卷积神经网络模型，来进行多像素点的同时预测。图4、图5分别为单点MLP模型结构和转换后的用于短时降雨预测的卷积神经网络模型结构。




图4 降雨预测问题中的单点MLP模型结构

Fig. 4 Single point MLP architecture for rainfall prediction




图5 降雨预测问题中的卷积神经网络模型结构

Fig. 5 Convolutional neural network architecture for rainfall prediction

在单点MLP模型中，对于输入的3帧图像，取每一个预测坐标点四周的 $3 \times 15 \times 15$ 输入数据块，采用MLP模型先映射为多个隐含层结点，再将隐含层结点映射为该点的预测类别值。而在卷积模型中，对于输入的3帧图像，先用200个 $3 \times 15 \times 15$ 的卷积核进行卷积，得到200个特征图，再对其使用1个 $200 \times 1 \times 1$ 的卷积核进行卷积，从而得到预测类别。转换后的卷积模型与逐一对单点使用MLP模型的逻辑结构相同，也等价于文献[9]中的一个mlpconv层，但由于卷积模型的时间性能较高，因此在实际的应用中可以更快速地

得到大量结果。

3 结合光流法的集成预测模型

在用MLP进行短时降雨预测的研究中，由于对运动物体的观察窗口设置较小，从而有时只能观察到局部边缘的移动，而无法观察到能够准确代表运动方向的角点位置，即孔径问题。适当增大模型的输入矩形区域的大小是解决孔径问题的一个方法，但输入结点个数的增多会增加模型的复杂程度，容易导致模型的过拟合。而在利用光流法进行预测时，光流计算过程的一个默认假设使局部像素的运动趋势具有一致性^[7]，每个像素点的光流值会根据周围区域的其他光流值进行调整，因此对观察目标的移动趋势掌握较为准确。因此，本文还尝试了将光流法模型与MLP模型进行集成，利用光流预测结果提供更丰富的有效信息，提升原始MLP模型的准确率。

3.1 光流法预测介绍

光流的概念是Gibson在1950年首先提出来的^[10]，它是空间运动物体在观察成像平面上的像素运动的瞬时速度。光流利用图像序列中像素在时间域上的变化以及相邻帧之间的相关性来找到上一帧跟当前帧之间存在的对应关系，从而计算出相邻帧之间物体的运动信息。光流法有3个前提假设：相邻帧之间的亮度恒定；相邻帧之间物体的运动比较微小；空间一致，即邻近点的光流速度一致。

基于光流的短时降雨预测方案基于以下假设：降雨带在短时间内的移动趋势是不变的。因此，光流法先利用帧 N （当前帧）与帧 $N-1$ 两幅图像来计算帧 N 中每个像素点的光流。需要注意的是，由于雷达图中空白区域（无反射率）的无参照性，初步的光流计算结果中空白区域的位移矢量均为0，但实际上无降水因子的区域也是有气流存在的，因此需要对计算所得的光流场进行规范化处理，使之更加准确。具体的处理方法是，计算有位移区域的平均位移矢量，并将空白区域的位移设定为该平均值。得到每一个点的位移矢量之后，将降雨量强度矩阵中的每一个点都按照位移矢量平移（平移后如果多个点到了同一位置则降雨量叠加），会得到一个新的降雨量矩阵。光流预测法假定，目标点在帧 $N+1$ （即6min后）的像素值即为相同坐标在新降雨量矩阵的像素值。因此，若要预测30min后目标点的像素值，只需迭代重复上述步骤5次，得到的坐标点像素值即为预测目标。

3.2 模型集成

考虑到MLP模型与光流法求得降雨预测结果的

过程是两种完全不同的手段，因此改进的集成模型主要在结果输出层将两个模型进行了融合。具体方法是：在原始MLP模型的输出层后新增了一个逻辑回归（Logistic Regression, LR）层。LR是一种分类算法，它的主要思想是根据训练样本对分类边界线建立回归公式，从而可以根据新的样本点落在回归线的哪一侧来判断新样本点的类别。假设输入特征为 n 维，逻辑回归中输入到输出的映射可由公式（1）表示，

$$h(x) = \frac{1}{1 + e^{-\left(\sum_{i=1}^n x_i \cdot w_i\right)}}, \quad (1)$$

其中， x_i 为第 i 个特征， $h(x)$ 为正样本概率。得到LR的输出后，根据损失函数，使用优化算法对参数进行调优，以达到损失函数值最小化。LR的损失函数如公式（2）所示，

$$J(w) = -\frac{1}{m} \left\{ \sum_{i=1}^m y_i \log h(x) + (1 - y_i) \log [1 - h(x)] \right\}, \quad (2)$$

其中， m 代表训练集中样本点的总数， y 代表该样本的真实类别。这个优化问题的目的是为输入特征找到最佳拟合参数集，LR算法中常用的优化算法为梯度下降法。

在集成模型中，LR层有两部分输入：一部分是原MLP模型的预测结果，由一个0~1的实数表示，代表预测的目标像素点在未来36min内降雨的概率；另一部分是光流法的预测结果，由一个0~36的整数表示，代表预测的目标像素点在未来36min内降雨的分钟数。两个输入数据均经过归一化处理。LR层的输出代表改进后MLP模型的预测结果，也是一个0~1的实数。本实验中，该实数值 >0.5 即可认为模型判断的结果为正类，反之为负类。图6给出了集成模型的结构。




图6 集成模型网络结构

Fig. 6 Architecture of the ensemble model

4 实验

4.1 数据集和工具

本文使用的数据集来源是北京、广州、成都三个雷达站2014年雨季（6—9月）的多普勒雷达图。选取这三个城雷达站的数据是因为它们涵盖了温带季风、亚热带沿海、内陆盆地等我国最重要的几种典型降雨模式。从总雷达站个数（3个）和总时长（12个月）衡量，该数据集是已发表的短时降雨预报方法的文献中所用的最大数据集。每地、每月的数据集由

7200帧组成，并被分为训练集、验证集和测试集三部分。以北京6月的数据为例，按顺序逐个抽取每100帧中的前50帧作为训练集，50~70帧作为验证集，后30帧作为测试集。因此，3个子集的数据间隔分布在整月之中，使它们的样本数据在不重叠的情况下，尽可能的达到随机均匀分布。在每个子集中抽取训练样本时，训练集和验证集采取随机抽样的方式，每一帧抽取100个训练样本，分别约140万和56万训练样本。同时，为了消除随机抽样对训练结果造成的不确定性影响，训练过程中每个训练轮次（epoch）后，均重新随机抽样，形成一个新的训练集来进行下一次迭代。测试集采取间隔抽样的方式，沿 x 轴和 y 轴方向每隔10像素抽取一个样本，共约130万测试样本。

实验使用的MLP模型是基于Pylearn2搭建的。Pylearn2是建立在Python语言之上，基于Theano封装的灵活和扩展的深度程序包。它支持GPU运算，并集成了一些常见的深度学习模型和训练算法。所使用的光流算法为目前一种主流的稠密光流算法Gunner Farneback光流法，算法的原理和详细描述见文献[11]，具体实现利用了OpenCV函数库中的稠密光流计算函数。将算法得到的稠密光流场进行规范化处理（见3.1节），用于光流模型的预测。实现并测试了Lucas-Kanade稀疏光流和未经规范化处理的Gunner Farneback光流。实验表明它们的预测精度相比规范化Farneback光流均有较明显下降。因此对照实验中的光流模型以及改进的集成模型中使用的光流算法均为经过规范化处理的Farneback光流。并用NVIDIA GTX 780 GPU加速MLP模型的训练过程。

4.2 实验结果

实验采用误报率和漏报率作为评测指标。图7给出了几种模型预测结果的ROC曲线。ROC曲线代表在选取的分类阈值逐步增大的情况下，模型对于真实的正样本正确分类的比例（True Positive Rate, TPR）和将负样本错误地判定为正样本的比例（False Positive Rate, FPR）相应的变化，其中横轴代表FPR，纵轴代表TPR。一般地，模型的ROC曲线越接近左上方，代表模型的性能越好。图7中，OF代表光流法模型，NN代表本文提出的原始MLP模型，NEW_NN代表集成模型。可以看到，光流法的准确率最高只能达到80%左右（图7中B点），这可能是由于光流法的预测结果完全依赖于当前帧与前一帧的光流，因此对降雨结构的形成与消散过程识别能力较差。从图7中A点至B点这一部分可以看出，原始MLP模型相较于光流




图7 光流法与本文提出的两种MLP模型的ROC曲线
(横轴为模型的误报率,即预测有雨的样本中预测错误的样本比例;纵轴为模型的准确率,即真实有雨的样本中预测正确的样本比例)

Fig. 7 ROC curves of optical flow method and two proposed MLP models

(horizontal axis is the false alarm rate of the model, i.e., proportion of samples with wrong predictions when predicting to rain; vertical axis is the precision of the model, i.e., proportion of samples with right predictions when it rains)

法,模型的整体性能略有提高;而集成模型的整体结果均明显优于光流法与原始MLP模型。由于光流法的自身方案,在B点至C点之间无统计数据,但在图中可看出集成模型性能依旧优于原始MLP模型。表1给出了3种模型达到最高F1得分时相应的漏报率和误报率。F-Measure又称为F-Score,综合了准确率与召回率的整体效果,是信息检索领域的常用的一个评价标准,其计算公式见式(3),

$$F-Score = \frac{(\beta^2 + 1)PR}{\beta^2 P + R}, \quad (3)$$

其中, P 为准确率, R 为召回率(即 $1 - \text{误报率}$), β 为权重因子,当 $\beta=1$ 时即为F1得分。

表1 三种模型的最高F1得分及对应的漏报率和误报率

Table 1 F1 scores, false negative rates and false alarm rates resulted from the three models

模型	漏报率/误报率	F1得分
光流模型	12.0%/23.2%	0.820
原始MLP模型	15.1%/18.4%	0.832
集成模型	13.6%/16.6%	0.849

图8a给出了一幅光流法与原始MLP模型的预测结果对比的示例。图中3幅图依次为真实值、MLP模型预测结果、光流法预测结果。红色、绿色区域分别代表两种方法的漏报点与误报点,深浅程度代表模型预测的该点降雨概率值大小。可以看出,MLP模型与光

流法中错误像素点的分布区域具有较明显的不同。另外,MLP模型的误报点较少,同时部分漏报点的降雨概率接近0.5;而光流法中几乎全部漏报点的降雨概率都接近0。由此可知,MLP模型与光流法的错误模式区别较明显。图8b和8c分别给出了几组错误样本。其中图8b中的几组样本在MLP模型中预测错误而光流法预测正确,这些样本共有的特点是在选取的窗口中降雨带前后的移动趋势不明显或变化比较不均匀,这种情形下光流法对于运动趋势的把握较好。图8c中的样本在光流法中预测错误而MLP模型预测正确,可以看出,对于降雨带的一些平缓的形成、消散过程以及边界点,光流法的预测准确率较低,而MLP模型可以捕捉到这些形成、消散模式。以上分析及结果表明,基于光流法的预测结果对MLP模型进行改进从而提高模型准确率的假设是合理的。

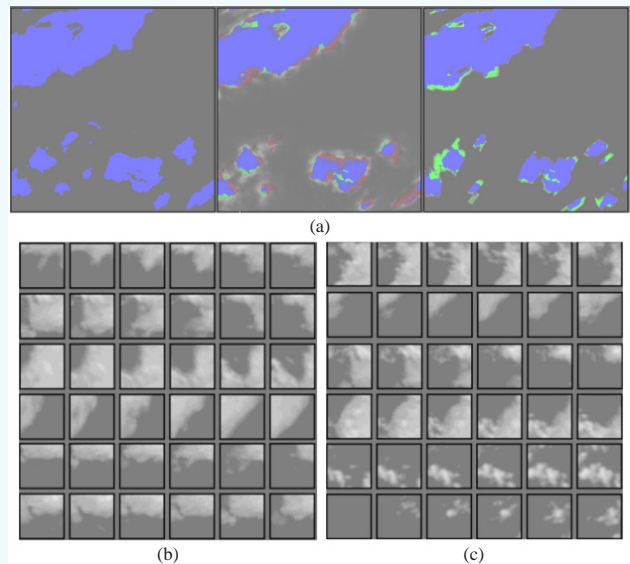


图8 光流法与原始MLP模型中错误样本示例

(a) 某一帧的预测结果对比示例; (b) MLP预测错误而光流法正确的一组样本; (c) 光流法错误而MLP正确的一组样本((b)和(c)每一行为一个样本,前3幅图片代表模型的输入,其中第3幅图片代表当前帧;第4、5幅图片代表当前帧与预测帧之间的间隔帧;第6幅图片代表预测的目标帧中心点,即为预测的目标点)

Fig. 8 Samples of wrong prediction with the optical flow method and primitive MLP model

(a) Comparison of prediction results of a sample frame; (b) Samples with wrong MLP prediction and right optical flow prediction; (c) Samples with wrong optical flow prediction and right MLP prediction

(In (b) and (c) every row represents a sample. The first three figures are the input of the model, of which the third is the current frame; The fourth and fifth figures are frames between the current frame and the frame to predict; The sixth figure is the frame to predict, the center of which is the target point to predict)

同时, 本文还比较了几种不同的MLP模型结构。表2给出了不同模型对应的预测结果。MLP675_200_50_1模型中, 675代表模型的输入为 $3 \times 15 \times 15$ 的像素数据块, 共有两个隐含层, 第一个隐含层节点为200, 第二个隐含层节点为50, 输出层只有一个节点, 代表预测有雨的概率。其他模型表示方法均与此相同。可以看到, 模型结构的变化对于降雨预测的准确率没有较大影响。其原因可能是由于随着模型层数与每层节点个数的增多, 虽然其表示复杂非线性函数的能力增强了, 但由于训练样本数目是一定的, 过拟合现象也随之变得严重, 因此模型整体的性能并没有突出的改善。

表2 不同MLP模型结构的漏报率与误报率
Table 2 False negative rates and false alarm rates resulted from different MLP network architectures

模型结构	漏报率/误报率
MLP675_200_50_1	24.5%/11.2%
MLP675_100_20_1	25.2%/10.3%
MLP675_50_10_1	25.8%/10.1%
MLP675_50_1	26.5%/10.2%

5 总结

本文提出了一个应用于短时降雨预测问题的深度神经网络模型, 可以通过多普勒雷达图像较准确地预测短时间内某区域的降雨概率, 并通过与现有的Gunner Farneback稠密光流预测方法的结果对比, 证明了MLP模型在预测降雨生成和消散时的优势。同时, 考虑到模型在降雨预测问题中的实际应用性能, 本文将提出的MLP模型进行了简单转换, 给出了一种逻辑结构相同的卷积神经网络模型, 从而能够快速地对多目标点进行预测。最后, 根据两种不同的预测方法, 提出了一种集成预测模型。集成模型结合了两种方法各自的优点, 学习到了更丰富的降雨带层变化模式, 从而在整体的预测性能上有了较明显的改进。

本文还通过比较不同MLP网络结构对于相同验证集的预测结果, 证明了深度神经网络的模型结构对于整体准确率的影响较为微弱。其中, 四层模型稍优于三层模型, 其原因可能是多层模型虽然可拟合更复杂

的数据映射函数, 但是由于数据输入维数较小, 训练样本数目有限, 因此模型表达能力的提高对于结果的影响不明显。而模型层数结构一定时, 隐含层节点数目在一定范围内的变化对于模型的结果没有影响。

本文只研究了深度神经网络中的多层感知器模型, 未来的工作可以将模型结构延伸至深度卷积神经网络。由于卷积网络的权值共享特性, 使得网络可以接受更多输入特征而不至于导致模型结构过于复杂。本文的神经网络预测结果和传统光流法相比并未体现出显著优势, 分析其主要原因是由于本文所用的大型数据集中, 不同地区、不同时间段的降雨带移动速度和方向差异很大, 导致很难选定一个对所有情况均合适的固定输入窗口大小。当降雨带移动速度过快时, 准确预测所需的全部降雨带雷达回波无法全部包含在输入雷达图中, 导致预测失败。未来计划采用可学习的门限(gating)机制动态生成神经网络的输入窗口, 以提高神经网络的预测精度。

参考文献

- [1] Reyniers M. Quantitative Precipitation Forecasts Based on Radar Observations: Principles, Algorithms and Operational Systems. Institut Royal Météorologique de Belgique, 2008.
- [2] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 1989, 2(5): 359-366.
- [3] 秦琰琰. 降水的雷达反射率因子与大气相对湿度的相关关系研究. 南京: 南京信息工程大学, 2005, doi: 10.7666/d.y712718.
- [4] 王敏. 基于多普勒雷达图像的风暴运动分析. 青岛: 中国海洋大学, 2008, doi: 10.7666/d.y1337511.
- [5] Li L, Schmid W, Joss J. Nowcasting of motion and growth of precipitation with radar over a complex orography. *J Appl Meteor*, 1995, 34: 1286-1300.
- [6] Li P W, Lai E S. Short-range quantitative precipitation forecasting in Hong Kong. *J Hydro*, 2004, 288: 189-209.
- [7] Beauchemin S S, Barron J L. The computation of optical flow. *ACM Computing Surveys (CSUR)*, 1995, 27(3): 433-466.
- [8] Kůrková V. Kolmogorov's theorem and multilayer neural networks. *Neural Networks*, 1992, 5(3): 501-506.
- [9] Lin M, Chen Q, Yan S. Network in network. *Proc 2nd International Conference on Learning Representations (ICLR)*, Banff, Canada, April 14-16, 2014.
- [10] Gibson J J. *The Perception of the Visual World*. Boston: Houghton Mifflin, 1950.
- [11] Farneback G. Two-frame motion estimation based on polynomial expansion//Scandinavian conference on Image analysis. Springer Berlin Heidelberg, 2003: 363-370.