



# 人工智能在短临降水预报中应用研究综述

## 摘要

短临降水预报是一项重要且具有挑战性的世界性难题.研究人员曾尝试使用各种技术预报降水,但是由于降水本身具有高度非线性、随机性和复杂性的特性,使得降水预测精确度并不高.近年来,随着人工智能技术的迅猛发展,其日渐渗透到人们生活的方方面面,气象领域也因此得益.人工神经网络能够对非线性系统进行建模,因此相比于传统方法,如数值天气预报法和光流法等,人工智能方法使得降水预报的准确率大大提高.本文介绍了传统降水预报的方法,着重总结概括了用于短临降水预报的各种最新人工智能方法,并对各研究方向进行归纳分析,为各类研究人员研究提供有益参考和借鉴.

## 关键词

人工智能;短临降水预报;雷达回波图;神经网络;机器学习

中图分类号 TP183;P456.1

文献标志码 A

收稿日期 2020-03-16

资助项目 教育部天诚汇智创新促教科研创新基金(2018A03038),苏州大学江苏省计算机信息处理技术重点实验室开放课题(KJS1935)

## 作者简介

方巍,男,博士,副教授,硕士生导师,主要研究方向为气象信息处理、大数据挖掘和人工智能.hsfangwei@sina.com

1 南京信息工程大学 计算机与软件学院,南京,210044

2 苏州大学 江苏省计算机信息处理技术重点实验室,苏州,215006

3 陕西省气象台,西安,710014

## 0 引言

人工智能起源于19世纪50年代,它是研究、开发用于模拟、延伸人的智慧的理论、方法、技术及应用系统的一门新的技术科学.直到19世纪80年代机器学习出现之前,人们都不知道使用何种手段以达成人工智能这个目标.在众多研究人员的努力下机器学习逐渐系统化成为人工智能的核心研究领域之一.得益于数据量的爆发式增长,计算机计算能力的提升,促使了机器学习新算法——深度学习的出现,深度学习使得人工智能的应用领域更加广泛.图1展示了人工智能、机器学习、深度学习三者的关系.




图1 人工智能、机器学习、深度学习三者关系

Fig.1 Relationship between artificial intelligence, machine learning, and deep learning

近年来,人工智能的浪潮席卷了人类生活的方方面面,目前人工智能的技术方向总体可分为计算机视觉、自然语言处理、语音识别、规划决策系统和大数据分析等.表1中介绍了这5种热点方向的主要任务和应用领域.

将人工智能技术与气象研究相结合,能够从海量的气象数据中提取并解读有用的信息,从而发现新的气候特征和大气运动,并且实现对天气现象更精确的预测.深度学习的快速发展以及各个领域的研究表明,深度学习算法可以对复杂问题进行建模以复制人类经验,而天气这种高度非线性和复杂性的问题可以通过学习那些由传统方法得到的判断和雷达图数据来进行研究.虽然人工智能为气象研究带来了巨大贡献,但数据驱动的机器学习不会替代物理模型,只是会起到补充和丰富的作用,最终实现混合建模<sup>[1]</sup>.

表1 人工智能热点技术方向介绍

Table 1 Introduction of AI hotspot technology directions

方向	概述	任务	应用领域
计算机视觉	用计算机代替人眼对目标进行识别、描述、跟踪和处理	计算机视觉的任务主要有图像分类、对象检测、目标追踪、语义分割和实例分割	广泛应用在安全领域身份验证如人脸识别和虹膜识别、医疗领域的智能影像诊断、电商领域的拍照搜索和无人驾驶领域
自然语言处理(NLP)	指计算机拥有如人类般处理自然语言的能力,其目标是让计算机能够确切地理解人类的语言,并自然地与人进行交互.NLP大致可以分为自然语言理解(NLU)和自然语言生成(NLG)两种,NLU侧重于如何理解文本,NLG则侧重于理解文本后如何生成自然文本	NLP主要任务有文本检索、机器翻译、情感分析、信息抽取、序列标注、文本摘要、问答系统、对话系统和知识图谱	自然语言处理广泛地应用在社会学领域如关系网络挖掘和社交媒体计算、法律领域处理海量的文书、医疗领域诊断报告数据和教育领域的智能阅卷和机器阅读等
语音识别技术	让智能设备听懂人类的语音,主要是关注自动且准确的识别、转录人类的语音.一个完整的语音处理系统主要包含特征提取、声学模型、语言模型以及字典与解码4大部分	语音识别的主要任务为语音转文字、语音翻译、智能对话系统	语音识别的主要应用包括医疗听写、语音书写、电脑系统声控、电话客服等
规划决策系统	强化学习的出现促使了人工智能规划决策系统的发展.强化学习的决策能力和深度学习感知能力相融合,创造出了AlphaGo战胜人类围棋冠军李世石、Master对战顶级围棋选手取得60连胜的佳绩	主要应用在决策任务中,可以与其他技术结合,如深度强化学习	主要应用在机器人和无人车领域
大数据分析	指对规模巨大的数据进行分析	主要任务是个性化服务、智能推荐	如在金融领域对股市进行预测,气象领域通过雷达回波外推实现天气的更精准预测

本文将气象领域中的短临降水预报的传统方法和人工智能方法进行总结,以方便进一步提高降水预报准确率、灾害天气预报准确率和灾害天气智能风险预警技术的研究和发展。

我们知道,无论是在市区交通中还是在农业系统中,甚至是在水资源规划、防洪预警中,降水预报都扮演着重要的角色.当前,利用气象数据实现对短临降水的预测是国内防灾减灾的热点和难点,提供短临降水预报成为中国气象局公共气象服务中心、墨迹天气公司等机构的服务重心,将提供未来2 h内的,空间分辨率为1 km×1 km,时间分辨率为6 min的定量预报,对提高降水预测精确度的研究是极具社会价值的。

短临降雨量预报的目标是在未来短期(0~6 h)内,对当地区域的降雨强度进行预测,具有准确性、实时性、大规模的特性.由于天气事件本身是一个随机事件,加上降水受气候带、大气环流、地理高度、季节等多重因素的影响,所以短临降水具有高度非线性的复杂的变化趋势,因此需要高时空分辨率和高时效性的数据来训练预测模型.而实时的多普勒雷达回波外推图6 min更新的时间分辨率和1 km的空间分辨率可以满足这一需求.雷达图以其测量范围较广,时空分辨率较高,能及时获取大面积降水数据的优点<sup>[2]</sup>,无论是在传统的光流法中还是在基于人工智能的模型中都扮演着重要的角色。

使用雷达图进行短临降水预测主要是通过雷达回波外推实现的.雷达回波外推就是根据当前时刻雷达观测结果,推测雷达回波未来的位置和强度,以实现强对流系统的跟踪预报.传统的雷达回波外推法如Rinehart等提出的交叉相关法(Tracking Radar Echoes by Correlation, TREC)<sup>[3]</sup>,这种传统方法的数据利用率较低且假设回波是线性演变的,而实际上雷达回波是位置变化的.而使用深度学习的方法进行雷达回波外推不仅可以充分利用采集的数据,还可以学习回波图位置变化的特征,实现更加精确有效的雷达外推预报。

现代短临降水预报的方法可分为传统方法和人工智能方法,前者又主要可以分为数学模型方法和基于雷达图的方法,后者主要是机器学习和深度学习.无论是传统方法还是人工智能方法,基于天气雷达资料的雷达回波外推技术都扮演着重要的角色.雷达回波外推图既包含了时序信息又包含了空间信息<sup>[4]</sup>,从而使用雷达数据进行降水预测可以看作是时空序列预测问题<sup>[5]</sup>.采用深度学习方法进行短临降水预报提出了一种端到端的解决这种非线性复杂问题的方案.它通过多层的网络结构和非线性变换来提取低层的特征,形成抽象的高层表示,以发现数据的概率分布特征,进而对未来的降水情况进行预测.由于人工神经网络能够对非线性系统进行建模,所以使用深度神经网络进行短临降水预测具

有巨大的潜力。

本文的第1部分概述了降水预报中的主要传统方法;第2部分重点讨论了机器学习方法在降水预测上的应用;第3部分总结了人工智能中最热点的深度学习给降水预测带来的贡献;第4部分介绍了人工智能在短临降水预报中的研究方向。

## 1 传统方法

### 1.1 统计方法

#### 1.1.1 物理统计模型法

该方法通过收集与降水相关的多种关联因子,并利用数据建立物理统计模型,从而对长期的降水量进行预测。所选择的因子具有一定的物理意义,利用前兆信息因子和后期信息的遥相关原理,对降水的轻重程度进行划分<sup>[6]</sup>。

陈菊英等<sup>[7]</sup>提出了一种海河流域全区和9个水文分区汛期降水量的气候分布特征和长期预测的多级预报物理模型。根据多年降水量时空变化特征,采用了多种可靠实用的前兆敏感信息因子,并挑选水文站的信息进行综合分析。该模型在海河汛期旱涝预报中取得了高精度的预报结果。马振峰等<sup>[8]</sup>分析了汛期降水分布型的前期信号,提出了四川盆地三类降水分布型特征,并得到了川渝地区主汛期降水和预测中强信号的关联,建立了针对川渝地区主汛期降水的物理统计模型。

#### 1.1.2 马尔可夫链预测模型

Markov过程是研究某一事件的状态及状态之间转移规律的随机过程,状态转移概率只与上一步转移后的状态有关,而与之前所有状态无关,即上一步的状态保存了之前所有的状态信息。马尔可夫链是时间和状态都离散的Markov过程,可以根据 $n$ 时刻的状态预测 $n+1$ 时刻的状态,概率最大的值即为预测结果。

冉景江等<sup>[9]</sup>认为基于绝对分布的马尔可夫链预测方法和叠加马尔可夫链预测法都具有一定的局限性,所以提出了加权马尔可夫链预测方法。该方法首先计算指标的分级标准,确定马尔可夫链的状态空间;其次根据之前时段的各指标值的对应状态得到不同步长马尔可夫链的转移概率矩阵;再次对各阶自相关系数规范化,作为各种步长的马尔可夫链的权重;最后将同一状态的各自预测概率加权和作为指标值处于该状态的预测概率。该方法充分地利用了信息,且预测的可靠性得到了提高。

夏乐天等<sup>[10]</sup>完善了加权马尔可夫链预测理论,讨论了各种马尔可夫链预测方法,并比较分析了各种因素对马尔可夫链预测精度的影响。实验结果表明:加权马尔可夫链预测方法的预测精度最高;样本容量的增大会提高预测的精度;指标值分级的不同对预测精度会产生显著的影响。

### 1.2 基于数值天气预报的方法

数值天气预报(numerical weather prediction)是根据大气实际情况,在一定初值和边值条件下,通过用数值方法求解支配大气运动的流体动力学和热力学方程组,来预报未来的大气环流形势和天气的。它具有数字化和定量客观的特点。1956年,瑞典首先开始数值预报业务实验,1969年,Epstein<sup>[11]</sup>首次提出了集合预报的思想,此后,各国纷纷建立了各自的集合数值预报业务系统。

刘瑞霞<sup>[12]</sup>为了解决云和降水在模式预报的初期阶段显著的延迟现象问题,在数值模型的基础上开展了中国风云气象卫星资料改变模式初值的研究,从而改进了短临预报精度。程丛兰等<sup>[13]</sup>研究了一种基于“外推”临近预报技术和中尺度数值模式的定量降水预报(QPE)融合技术方案。该方案首先分析数值预报和观测的偏差,导出一个附加的数值预报校正场;其次,根据数值预报校正场调整相应时段的数值预报降水区域和强度;最后,利用函数对校正后的数值模式定量降水预报和基于临近预报技术的定量降水预报进行融合。该研究弥补了基于“外推”的临近预报技术在2h以上定量降水预报能力方面的缺陷。实验结果表明融合后的0~6h定量降水预报结果改进较为明显,总体优于单独的临近预报技术或者中尺度数值预报模式的结果。2017年,Wu等<sup>[14]</sup>研究分析了基于数值天气预报系统(TAPEX),该系统的整体预测来自物理和动态数值天气预报模型,被用于对台湾地区提供短期降水的有效预报。他们分析了该集成数值天气预报系统对小时雨量的集成预报,对其性能进行了评价。首先计算了TAPEX中单个成员的集成预测性能,它低于传统的集成测试平均值,所以得出结论,与使用单个集成成员的预测相比,使用所有集成成员的集成均值预测具有更强的鲁棒性,从而获得更好的预测性能。在此基础上,他们提出了一种基于模拟预报原理的集成预报方法,并在一个山区流域对台风期间的短临1~6h的降水预报进行实际应用,发现该方法可以改善非常短期的雨量预测,特别是1~2h的。

### 1.3 基于雷达图的预测方法

#### 1.3.1 Z-R 关系式法

通过雷达回波强度和雨强二者之间建立的关系式来估算,即天气雷达反射率因子( $Z$ )和雨强( $R$ )的  $Z$ - $R$  的关系式  $Z=aR^b$ ,  $a$  和  $b$  为经验系数<sup>[2]</sup>.

方鸿斌等<sup>[15]</sup>提出将  $Z$ - $R$  关系本地化.由于我国新一代天气雷达的定量估测降水算法沿用的美国夏季对流云统计得到的  $Z$ - $R$  关系式,但已经不符合荆州市本地的降水模式.他们对 2014 年与 2015 年两年主汛期 5—8 月共 8 个月的降水过程进行了统计分析,并根据最优化算法得到了适合荆州雷达汛期定量估测降水的  $Z$ - $R$  关系.

#### 1.3.2 降水云团外推技术

首先获取雷达反射率图像,然后根据云团外推算法进行云团外推.云团的外推指的是根据相邻时刻同一云团形成的两幅反射率因子图,计算它们之间的变化,并依此得到未来短期时刻的云团形态.

张蓉<sup>[16]</sup>从降水云团的识别和跟踪两个方面展开研究,提出了一种灰度阈值结合纹理方法识别降水云团的算法,更加准确快速地识别出降水云团区域.此外,还提出了一种全面的降水云团跟踪算法,对于位移较大的降水云团也能够正确跟踪,并且适用于降水云团发生合并和分裂的情形.实验结果表明,该识别算法的降水云团总体识别率达 69%.

#### 1.3.3 光流法

1950 年, Gibson 首次提出光流的概念<sup>[17]</sup>.光流法是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的一种方法.使用光流法有着 3 个前提假设:1)亮度恒定不变,即同一目标在不同帧间运动时,亮度不会发生变化;2)时间连续或运动是微小的,即时间的变化不会引起目标位置的剧烈变化,相邻帧间位移小;3)同一子图像中像素点具有相同的运动.

光流法善于观察图像的变化,并利用相邻图像间的相关性获取运动信息,对其实现追踪.这与利用雷达数据对云团进行识别追踪进而完成降水预测的思想相一致.光流基本方程是由 Horn 等<sup>[18]</sup>在 1981 年通过将二维矢量场和图像灰度联系在一起得到的.在此基础上, Lucas 等<sup>[19]</sup>提出了利用局部计算光流的 L-K 光流法:首先对整幅雷达图进行分块处理,接着对每一块区域使用加权最小二乘法估算光流,进一步提高了稳定性.2017 年,香港的研究员 Woo

等<sup>[20]</sup>研究了香港天文台的涡流临近降水预报系统采用的用来跟踪雷达回波运动的变分光流技术,同时对比分析了 3 种雷达回波跟踪算法.在漩涡的第 1 个版本中,用于跟踪定位雷达回波的方法是 Tracking Radar Echoes by Correlation (TREC),但是 TREC 虽能成功地跟踪个别雷达回波的运动,但在实际运动中通常只能捕捉个别降雨云团的运动方向而不能捕捉整个天气系统的大尺度运动.为解决这个问题,出现几种方法<sup>[21-22]</sup>,最终漩涡选择了在 2009 年由 Wong 等<sup>[23]</sup>提出的变分光流技术(MOVA),于 2010 年投入使用.结果表明,MOVA 性能在整体上要比 TREC 有较大提高,但 MOVA 也存在着在大规模时倾向于低估回波运动矢量的速度来最优检索最小化回波运动过程的问题,这会造成过多的预报降水,因此 ROVER(Real-time Optical flow by Variational methods for Echoes of Radar)被提出来解决上述问题,相比于 MOVA,它有着 3 个方面的增强:1)具有预处理步骤,使雷达反射率图像在空间上更平滑;2)采用变型光流技术;3)采用文献[24-25]中提出的算法代替了变分回声跟踪 VET(Variational Echo Tracking)<sup>[26]</sup>,将 Horn 等<sup>[18]</sup>提出的光流方程和 L-K 光流法相结合,既利用了前者的密集流畅,又利用了后者的噪声鲁棒性.该算法通过采用先进的数值方法,进一步加快了计算速度,可用于实时计算.由于参数的选择会影响运动场的质量,变分光流算法的性能自然取决于所采用的参数.虽然可以为特定的地理设置推导出最佳参数,但这样的工作需要丰富的数据存档和巨大的计算能力来试验和探索所有的维度空间,这使参数的优化变得困难,但在漩涡系统工作的 4 年时间里,这组参数在大多数情况下工作得相当好.通过对比实验研究,ROVER 在总体上要优于 TREC 算法和已知的光流算法 MOVA.

## 2 机器学习方法

短临降水预报的关键在于对定量降水的估计(Quantitative Precipitation Estimation, QPE),QPE 的精度越高,结合时间序列外推技术,就越可以实现对短临降水的精准预报.气象卫星和气象雷达可以实现通过对云的观测间接实现对降雨的估计,气象雷达由于它的高时空分辨率的优势,被广泛应用于短临降水的预报中,成为 QPE 的最佳间接测量方式.气象雷达一般在 6 min 内完成对空域的扫描,1 km 的空间分辨率,通过观察发现,扫描得到的空中降水粒

子产生的雷达回波,其相对应的雷达反射率和降水具有显著相关性。

对提高雷达 QPE 精度的研究开始于 1979 年 Wilson 等<sup>[27]</sup>的一篇关于雷达 QPE 在实际应用中存在的误差种类的综述.其中研究的一个主流做法是基于气象知识校正不同的 Z-R 关系.然而 Z-R 关系模型由于自身的局限性及对气候背景的强烈依赖性,使得模型的泛化能力弱,这就导致了不能大规模地在不同情况的实际应用中推广.随着机器学习理论知识的完善与发展,从机器学习角度出发的新的 QPE 模型应运而生.最早的机器学习 QPE 模型是 Xiao 等<sup>[28]</sup>利用近地面 CAPPI 反射率训练神经网络得到的,且其结果精度优于包括 Z-R 关系在内的几种技术,这也间接说明使用机器学习实现对短临降水的预测是具有可行性和可靠性的.基于神经网络的雨量估计成为解决雨量估计问题的新方法,在实际的气象雷达系统中易于实现.首次将神经网络应用于降水预测的是在 1992 年, French 等<sup>[29]</sup>提出了一种基于神经网络的降雨强度时空预报方法,神经网络的结构很简单,是一个 3 层的学习网络,包括了输入层、隐藏层及输出层.通过反向传播进行训练,将输入和输出的降水信息作为一系列的数据集呈现给神经网络,结果表明神经网络可以学习描述降雨时空演化的复杂关系.2000 年, Luk 的研究团队利用人工神经网络(ANNs)具有模拟人类神经系统的并行分布式处理能力,解决了降雨过程的复杂性和降雨在空间和时间上的变异性难题<sup>[30]</sup>,研究表明当一个最佳的空间输入数量输入到 ANNs 后,神经网络可以提供最准确的预测,并且延迟越小的网络性能越好.研究还发现,时间和空间的输入超过一定阈值会对结果产生影响,如 15 min 多站点降雨时间序列不具备长期记忆特性,在空间域上,过多或过少的空间信息被引入可能会导致性能的下降,同时他们表示时间和空间信息间可能存在一种平衡. Valverde 等<sup>[31]</sup>也在 2005 年将人工神经网络技术应用在对巴西圣保罗地区的降雨预测中,利用前馈神经网络和弹性传播学习算法,将 ETA 模型<sup>[32]</sup>中的气象变量(温位、风的垂直分量、比湿度、气温、可降水量、相对涡量和水汽散度通量)作为输入数据输入到训练好的网络中,生成下一个时间步的降雨预报,并将实验结果同多元线性回归模型的预测结果做比较,发现人工神经网络的结果全面优于线性回归模型,说明人工神经网络具有很大应用潜力,虽不能取

代预报员的经验,但可以用额外的信息(除了输出模型、卫星云图等)来补充,从而减少预报员的工作强度.为了提高人工神经网络的预测能力,模型需要吸收更多的数据,如更长的预测降雨时间序列,在此情况下,数据预处理可以应用于这些数据集,如小波分析,这将减少神经网络输入数据的规模。

在此之后, Hong<sup>[33]</sup>于 2008 年以台湾北部台风期间的降雨量为例,提出了一种混合预测模型 RS-VRCPSO,阐明了 RNNs 和支持向量机(RSVR)混合模型预测降水量的可行性,同时采取混沌粒子群优化算法(CPSO)来选择 SVR 模型的参数.实验结果表明,该模型相较于 ANN 和回归模型具有非线性映射能力,因此更容易捕获电力负荷数据模式,同时 SVR 模型中参数的不恰当选择会导致模型的过拟合或欠拟合,而 CPSO 能很好地解决这个问题.与神经网络和回归模型相比,RSVRCPSO 模型采取的是结构风险最小化策略而不是最小化训练误差策略,最小化泛化误差的上界有助于改善泛化能力.因此 RS-VRCPSO 模型具有可靠的预测能力,为雨量估计提供了一种新的方法.2012 年,韩国光云大学的研究员 Seo 等<sup>[34]</sup>利用如支持向量机和基于稳态遗传算法的 KNN,研究了基于包装器的遗传特征选择方法,用于对朝鲜半岛南部非常短期的暴雨进行预报.实验结果表明,结合归一化的 SVM 分类器效果最好,一个新的数据预处理可能会带来更加精确的研究结果.在今后的工作中,可能采用多样化预测时间(1~6 h),也会使用其他的进化算法或分类算法.2013 年,爱荷华大学的 Kusiak 等<sup>[35]</sup>基于雷达波反射率和 TB 级数据将数据挖掘的技术应用于对牛津流域的降水预测,对比了采用神经网络、随机森林、分类和回归树、支持向量机和 K 临近这 5 种常用于雨量估计的机器学习算法的精度,并选择精度最高的一种算法进行研究,从而进一步肯定了机器学习算法对雨量估计的重要性.2017 年, Yu 等<sup>[36]</sup>比较了随机森林方法(RF)和支持向量机(SVM)这 2 种经典的机器学习技术在雷达实时短临降水预报中的应用,建立并比较了 2 种预测模型:单模预测模型(SMFM)和基于 RF 和 SVM 的多模预测模型(MMFM),SMFM 使用相同的模型进行 1~3 h 的降水预报,MMFM 使用 3 种不同的模型进行 1~3 h 的预报,根据预测性能,发现 SMFM 相比于 MMFM 能提供更好的性能,同时 SVM-based 和 RF-based SMFM 都能完美地对 1 h 的降水进行预测,但 2~3 h 预测存在时滞,预测能力



下降.在 2 h 和 3 h 的预报中,他们还发现基于 RF 的 SMFM 在大多数情况下低估了观测到的雷达降水,而基于 SVM 的 SMFM 比基于 RF 的 SMFM 具有更好的性能.他们使用的预测模型形式简单,仅使用了 4 个输入变量(前一个网格雷达获得的降雨量、经纬度和网格的高度),今后可能会考虑加入台风特性和相邻网格的降雨作为输入变量来改善预测性能.同年, Huang 等<sup>[37]</sup>提出了一种改进的 KNN 算法,使得其对不同领域大小  $k$  的选择具有鲁棒性,尤其是在降水数据集呈现非规则类分布特点时,基于改进的 KNN 算法,提出一种新的降水预报方案,通过大量的测试表明所提出的模型具有较好的预报效果.同样是在 2017 年,印度学者 Solanki 等<sup>[38]</sup>发明了一种混合智能系统数组挖掘技术,由人工神经网络和适当的遗传算法组成,遗传算法主要利用了输入的类型、输入层和输出层之间的连接结构,从而使神经网络的训练更加有效.人工神经网络中,多层感知机(MLP)是执行预测任务的中心数据挖掘引擎,遗传算法使得分类器训练阶段更加高效,且计算开销更小.

2018 年,Sharma 等<sup>[39]</sup>提出了一种基于数据挖掘机器学习算法的监督学习模型来进行降水预测,该方法将降雨量分为低、中、高 3 个级别,对数据集的归一化、均值化和阈值化等功能进行了优化设计,阈值用于对降雨数据集进行分类,并用 MLP 分类器、朴素贝叶斯、随机森林和 SMO 比较了它的准确性,能在实验所选取的所有的降水数据集上取得 99% 的精度,具有较好的监督精度来训练数据,未来的工作将基于无监督学习查找更好的模式识别系统,具有更多的特征,如温度、湿度和地质研究等.2019 年,张晨阳等<sup>[40]</sup>提出了一种基于地形的加权随机森林方法 TWRF 来解决雨量估计问题,该方法是随机森林方法 RF 的一种推广,用加权的随机森林代替普通的随机森林从而刻画反射率因子垂直廓线(VPR)的不同局部特征对于减少雨量估计误差的重要性,挖掘由 CAPPI 反射率表示的雷达数据到降水率之间的映射关系.同时考虑到了 VPR 对雨量估计精度的重要作用以及复杂地形区域降水的山岳抬升效应的影响,并对中国杭州湾地区 2014 年的降水过程进行了实验验证,结果表明 TWRF 要优于传统的气象方法和随机森林方法,且利用整个 VPR 和基于地形的建模有利于提高雨量估计的精度.机器学习在学习建模时往往会忽略掉气象因素对结果的影响,因此将气象的先验知识与机器学习相结合的研究

势必将成为今后的研究热点.

### 3 深度学习方法

1964 年, Hu<sup>[41]</sup>首次将人工神经网络应用于天气预测中.1994 年,李滨<sup>[42]</sup>引入 BP 神经网络来提高月平均降水预报的准确性,实验结果表明对降水场的直接预报需要考虑多种环境因素的影响,且使用 K-L 变换进行预处理是不恰当的,该项工作为发现预测因子和提高准确率的研究打下了基础.1997 年, Kalogirou 等<sup>[43]</sup>使用了多个隐藏层的网络架构,同年 Venkatesan 等<sup>[44]</sup>采用不同的气象参数作为人工神经网络模型的输入来预测印度全夏季的季风雨量,并使用误差反向传播(EBP)算法训练多层网络.1998 年, Lee 等<sup>[45]</sup>将整个区域划分为 4 个子区域,对 2 个较大的区域使用径向基函数(RBF)网络进行降雨预测,另外 2 个较小的子区域使用简单的线性回归模型预测,实验结果表明 RBF 网络产生了更好的预测结果.1999 年,吴涛等<sup>[46]</sup>提出了一种基于神经网络的外推预测垂直对撞流干燥过程降水率的方法,并给出了一种基于目标函数的一阶和二阶导数同时优化学习率和确定动量系数的方法来解决 BP 算法学习参数难以确定的缺点.2000 年, Toth 等<sup>[47]</sup>应用了 3 个时间序列模型,即自回归移动平均(ARMA)、ANN 和 K 近邻(KNN)方法来预测降雨,结果表明人工神经网络的效果最好.

#### 3.1 浅层神经网络

##### 3.1.1 多层感知机(MLP)

郭尚瓚等<sup>[48]</sup>利用多层感知机(MLP)与光流矢量结合的模型通过多普勒雷达图组成的帧序列来实现短时降水预测.训练时该单点 MLP 模型的输入层为一个预测坐标点四周的  $(N-2) \sim N$  帧的像素值,输出层为一个  $0 \sim 1$  的实数代表未来 36 min 的降雨概率.他们还采用了用于多点预测的卷积神经网络模型.最后,将 MLP 与光流矢量融合,即在最后的输出层增加一个 LR 层,这个 LR 层输入 MLP 模型的预测结果和光流矢量的预测结果,通过最小化两者误差来优化整个模型.

Deshpande 等<sup>[49]</sup>提出了多层感知机神经网络来预测降雨时间序列.他们从印度马哈拉施特拉邦 Yavatmal 收集样本数据,并用多层感知机神经网络对该降雨数据序列进行了多步提前预测.实验结果表明,与其他网络相比,测试中的均方误差、归一化均方误差以及短期预测训练数据集等性能指标是最

佳的.

Hernández 等<sup>[50]</sup>提出了一种基于深度学习的架构,用于预测第 2 天的每日累积降水量.该模型包括用于减少和捕获属性之间的非线性关系的自动编码器,以及用于预测任务的多层感知器.他们通过实验证明了在预测第 2 天的累积日降水量方面有了改进.

### 3.1.2 BP 神经网络

Wong 等<sup>[51]</sup>建立了使用人工神经网络和模糊逻辑的降雨预测模型.首先使用 SOM 将数据划分为子种群,将整个数据空间的复杂性降低到更均匀的水平;然后使用 BPNN 从每个聚类的数据中学习泛化特征.他们为每个聚类提取模糊规则,然后将模糊规则库用于降雨预测.实验结果表明,该方法与使用径向基函数网络和地形效应的既定方法取得了相似的结果.该方法的优势在于允许分析人员使用模糊规则来理解模型并与之交互.

张继学等<sup>[52]</sup>建立了逐日降水量的 3 层 BP 神经网络预测模型,主要利用 BP 神经网络的线性函数逼近功能.根据影响降水的 18 个气象因素作为模型的输入因子,以预测第 2 天的降水量.实验降水的预报准确率达到 83.3%,表明人工神经网络在短期降水预报方面具有良好的应用前景.

邵月红等<sup>[2]</sup>利用 BP 神经网络估测降水量,采用 BFGS 算法对常规的 BP 算法进行了改进,有效地克服了常规 BP 算法收敛速度慢、易陷入局部最小点等缺点.训练样本中去除使用通用  $Z-R$  关系式计算出相对误差较大的样本,模型输入为不同高度上的反射率因子.实验结果表明,BP 神经网络估测精度要明显优于以改进的最佳窗概率配对法建立的  $Z-R$  关系式.

### 3.1.3 径向基神经网络 (RBFN)

季刚等<sup>[53]</sup>建立了一种基于径向基函数的神经网络预测模型,并将该网络应用于月降水量的预测.实验结果表明,RBF 神经网络模型无论是在训练的时间上,还是预测结果上都明显好于传统 BP 神经网络.

Liu 等<sup>[54]</sup>提出了一种基于经验模式分解 (EMD) 和 RBF 神经网络的降雨预测新模型.经过实验得出该方法在降噪和预测降雨序列方面具有很高的准确性.

## 3.2 深度学习

浅层神经网络对复杂函数的表示能力有限,针

对复杂分类问题其泛化能力受到一定制约,且浅层神经网络在训练时容易陷入局部最小值,在测试时容易造成过拟合.而深度学习可通过学习一种深层非线性网络结构,可以用较少的参数表示复杂的函数,且具有较强的特征学习能力,对解决降水这种影响因素众多的复杂的非线性随机问题具有很大的潜力.

### 3.2.1 卷积神经网络

施恩等<sup>[55]</sup>考虑到雷达回波外推问题的输入与输出之间存在较强相关性,提出了一种基于输入的动态卷积神经网络结构 (DCNN-I) 实现雷达回波图像的预测和外推,从而解决了传统交叉相关法预测雷达外推图只利用前几个时刻数据的缺点.该网络相比传统 CNN 增加了动态子网络 (Dynamic Sub-network, DSN) 和概率预测层 (Probability Prediction Layer, PPL).其中 DSN 即为传统 CNN,用于根据输入图像序列的不同动态调整卷积核,其输出作为 PPL 的卷积核;PPL 将输入图像序列与得到的卷积核进行一系列卷积操作得到最终外推图像.实验表明该网络有效提高了数据利用率,且准确率更高.

Zhuang 等<sup>[56]</sup>设计了一种新颖的时空卷积神经网络 (ST-CNN) 来学习气象变量对时空邻域的依赖性,从而进行可靠的极端降水长期预报.该模型共有 6 层,包括 2 个卷积层、2 个池化层和 2 个全连接层.他们使用多个时空张量数据作为输入,该时空数据为在  $m \times n$  区域上的  $k$  个时间间隔的  $m \times n \times k$  长方体,输出为未来  $x$  时间内的降水量分类.实验结果表明,该模型可以充分利用时空信息,且精确度高于 OSFS 方法.

Zhang 等<sup>[57]</sup>提出了多通道 3D 立方体连续卷积神经网络 (3D-SCN) 使用多源气象数据来进行对流风暴开始 (CI) 和增长的预测,网络堆叠连续的卷积层而不进行池化.在这项研究中,他们将降雨检测作为一个雷达回波是否大于 35 dBz 的分类问题,模型输入为包括原始 3D 雷达和重新分析气象数据的六通道数据,每个通道都为由 20 层 2D 数据形成的 3D 数据,并通过跨通道 3D 卷积进行卷积.

Klein 等<sup>[58]</sup>提出了一种动态卷积神经网络,在卷积神经网络中加入一个新的动态卷积层,与一般卷积层不同的是该层的卷积核是通过一个任意深度的子网络得到的.由于卷积核是输入的函数,所以卷积核在测试时也是随着输入样本的不同而变化的.该网络使用 4 个连续的 2D 雷达反射率图像来生成

下一个 10 min 的雷达图像.实验表明,通过使用新层,与包括常规 CNN 在内的其他基准相比,可以提高性能.

Agrawal 等<sup>[59]</sup>将降水预测问题看作是一个图像的转换问题并且使用 U-Net 卷积神经网络来处理.模型虽然提供了瞬时预测,但 HRRR 中使用的数值模型可以做出更好的长期预测.因此将 HRRR 和机器学习模型这两种方法结合起来可能会实现准确、快速短期以及长期预测.该模型比光流法和 HRRR 数值预测法的结果更优.

Ayzel 等<sup>[60]</sup>使用全卷积神经网络基于雷达图进行降雨预测,对于数据预处理采用了 4 种不同的转换技术,该全卷积神经网络包括 6 个顺序的 2D 卷积层,为了保留空间分辨率网络没有使用跨步并且始终使用零填充.最终得到的 2 个雷达图像( $t-2, t-1$ )作为模型的输入,输出为第  $t$  个时间步的雷达图像.对于提前 1 h 的预测将会每 12 个时间步进行一次预报,并将前一次输出作为下一次输入.最后,他们使用不同的卷积核大小和损失函数进行实验,选择出了最优的组合作为基准.结果表明,该方法可与最先进的光流法匹敌.

Lebedev 等<sup>[61]</sup>分析了俄罗斯偏远地区没有雷达设施覆盖的情况,并结合 NWP 产品和雷达外推的优缺点开发了一种基于全天候卫星影像和雷达图的 NWP 模型的降水预报方法.数据的来源有 3 个,一个是雷达每 10 min 扫描一次的  $2\text{ km}\times 2\text{ km}$  的重构区域,一个是 10 个低轨地球卫星上的雷达和传感器以 3 h 的时间分辨率扫描全球表面 10 个纬度的带状区域,一个是与地球旋转同步的卫星在整个可见地球范围内不间断地观察得到云图.他们的目标是使用卫星数据重建从雷达获得的降水场,然后使用相同或相似的模型在更大的领土上进行预测.该项研究为全球预报服务铺平了道路.

### 3.2.2 递归神经网络

张帅等<sup>[62]</sup>构建了长短记忆网络 LSTM 模型,并通过时间反向传播 BPTT 算法更新网络权重,选用榆林市的旬降雨量数据训练网络,解决降水量的预测问题.他们通过实验比较了递归神经网络、前馈神经网络、小波神经网络、ARIMA 在训练集和测试集上的表现,发现该模型较传统方法预测精度高,能够更好地描述降雨量的动态、非线性变化规律.

### 3.2.3 深度信念网络

张鹏程等<sup>[6]</sup>提出了一种深度信念网络模型对区

域的降水量做回归预测.该模型分为多层受限玻尔兹曼机和 BP 网络两大部分,多层 RBM 层联结起来对数据进行无监督学习.他们采用了快速逐层训练的方法训练模型,模型的输入向量为与日降水量相关的 7 个环境因子,输出为次日 24 h 降水.与径向基神经网络、SVM、自回归滑动平均模型和 ELM 方法的对比结果表明,该模型具有更好的预测效果.

### 3.2.4 复合模型

Wu 等<sup>[63]</sup>提出了一种基于 3D 卷积神经网络与 LSTM 融合的模型来对短临降水进行数值分类预测.该模型分为 3D-CNN 模块和 LSTM 模块,首先将前 4 h 的数据按时序输入到卷积神经网络中进行特征提取,然后将提取的高阶特征信息输入 LSTM 模块进行降水量预测.采用的数据集来自气象站观测的区域上空不同高度的多普勒雷达回波外推图,将未来降水量作为数据的标签来训练模型.最后他们进行大量实验优化网络参数,解决了过拟合和特征学习不充分的问题.

Gope 等<sup>[64]</sup>提出了一种结合 CNN 和 LSTM 的混合方法.该模型使用 CNN 的输出作为 LSTM 的输入,其中,CNN 和 LSTM 被视为独立步骤.他们没有考虑雷达数据,而是采用了大气变量,例如温度和海平面压力.

### 3.2.5 短临降水问题的新方法新思路

Shi 等<sup>[4]</sup>创新性地提出了卷积 LSTM 的概念,并将短临降雨预测建模为一个可以用 Seq2Seq 学习框架解决的时空序列预测问题.他们将降水预测的地区划分为网格,每个格子里的数据代表某个时间间隔的降雨量,这样就形成了一个时空三维数据.通过堆叠多层 ConvLSTM 构建端到端的可训练模型,并形成编码器-解码器结构,模型结构如图 2 所示.传统的 LSTM 的输入层状态转换使用的是全连接层,没有考虑到空间上的相关性,包含了大量冗余的空间数据,而使用他们提出的卷积 LSTM,不仅可以像 LSTM 一样建立时序关系,而且可以像 CNN 一样通过提取特征来刻画局部空间特征.在综合移动 MNIST 数据集和雷达回波图象数据集上的实验结果表明,该模型的表现优于 FC-LSTM 和当前最先进的 ROVER 算法.

Shi 等<sup>[5]</sup>发现之前的工作所提出的 ConvLSTM 在状态转换中使用位置不变过滤器进行卷积潜在地使数据变成了时空恒定的结构,但自然界中大部分结构是会随着时间变化的,如旋转.所以他们提出了






图2 Encoding-forecasting ConvLSTM 网络<sup>[4]</sup>  
Fig. 2 Encoding-forecasting ConvLSTM network<sup>[4]</sup>

新模型轨迹 GRU (TrajGRU), 可以主动学习位置变化的结构, 该模型构建了一个 encoder-forecaster 结构, 与 ConvLSTM 所不同的是预测器反向输出, 这样可以先学习全局运动趋势再对更多局部邻域的运动细节进行预测, 该模型结构如图 3 所示. 他们还提出了新基准 HKO-7. 通过对比 ConvGRU、不使用/使用加权损失函数训练、Conv2d、Conv3d 等几种方法, 实验结果表明 TrajGRU 取得了比 ConvGRU、Conv3d、光流法等方法更好的结果.

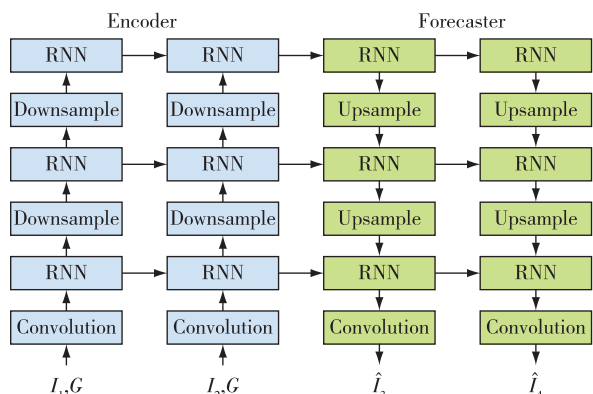


图3 根据输入序列外推输出序列的 encoder-forecaster 结构, 该模型中的 RNN 可以是 ConvGRU 或 TrajGRU<sup>[5]</sup>  
Fig. 3 The encoder-forecaster structure of the output sequence is extrapolated based on the input sequence. The RNN in this model can be ConvGRU or TrajGRU<sup>[5]</sup>

Kim 等<sup>[65]</sup> 提出了一种名为 DeepRain 的数据驱动的降水预测模型, 结构如图 4 所示, 该模型使用卷积 LSTM (ConvLSTM) 利用天气雷达数据来预测降雨量. Shi 等<sup>[4]</sup> 使用了三维单通道数据, 而 Kim 等<sup>[65]</sup> 使用 ConvLSTM 来处理三维 (宽、高和深度) 四通道 (4 个不同的海拔) 数据. 另一点不同之处在于 Shi 等<sup>[4]</sup> 采用多对多的输出, 而 Kim 等<sup>[65]</sup> 使用多对一的方法. 数据集中每行数据由雷达反射率和地面真值组成, 雷达反射率为距 101 km×101 km 地面的 4 个高

度的 15 个时间间隔 (间隔 6 min) 共 101×101×4×15 个数字值; 地面真值为网格中心 50×50 范围内 1~2 h 的降雨量. 完整的数据集包括在 2 年期间随机选择的 10 000 行数据. 模型按时间序列依次输入 15 个三维四通道数据, 输出是预测的降雨量信息. 实验结果表明, 卷积运算可以有效地从数据中提取潜在特征, 并可以进行快速训练. 与线性回归相比, 2 层 ConvLSTM 将 RMSE 降低了 23.0%.

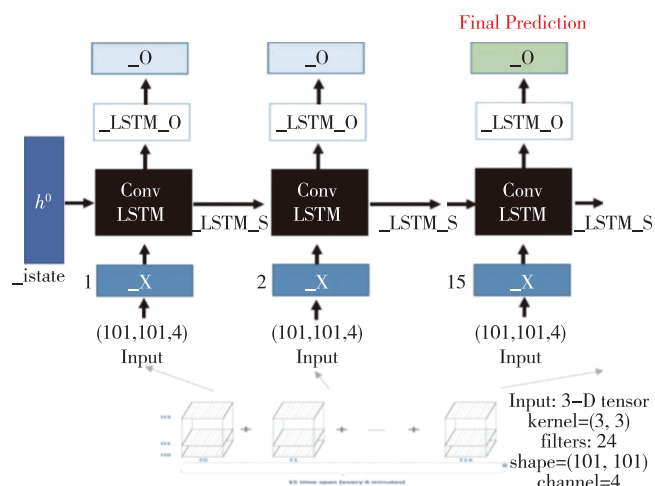


图4 使用 ConvLSTM 的 DeepRain 模型结构<sup>[65]</sup>  
Fig. 4 DeepRain model structure using ConvLSTM<sup>[65]</sup>

以上论述了短临降水预测所提出的新技术新方法. 由于雷达回波外推进行降水预测可以看作是一个时空序列问题, 因此, 这些创新性方法<sup>[4-5, 55, 58, 60]</sup> 同样可以应用在视频序列预测、交通流量管理、空气污染物的扩散预测和台风预警系统<sup>[66]</sup> 中. 表 2 对比了近年来用于短临降水预报的各种深度学习方法.

#### 4 人工智能在短临降水预报中的研究方向

从第 2、第 3 部分的介绍中可以看出, 人工智能在短临降水预测方面被证明是有效的, 且在进一步提高预报精确度上有巨大潜力. 通过人工智能和气

表2 深度学习各降水预测模型的概述与对比

Table 2 Overview and comparison of precipitation prediction models in deep learning

模型	实验结果	优缺点
<p>文献[4]提出了 ConvLSTM 来保留雷达图的时空相关性,并采用了 seq2seq 结构即 encoder-decoder 模型,该模型堆叠了 2 层 ConvLSTM.将 2D 雷达图序列作为模型输入,并输出未来预测出的雷达图序列</p>	<p>该模型的表现优于 FC-LSTM 和当前最先进的 ROVER 算法</p>	<p>优点:1) 创新性地提出了 ConvLSTM,保留了数据的时空相关性; 2) 端到端的模型直接输出雷达图序列预测未来降雨量. 缺点:卷积操作是时空恒定的结构</p>
<p>文献[58]提出了一种动态卷积神经网络.该网络学习映射 4 帧的输入序列并产生概率矢量以预测最后一张图像的转换后的图像.具体为,将 4 帧序列输入 3 层卷积 3 层池化中,然后通过一个全连接层转换为一维垂直向量 <math>h_1</math> 和水平向量 <math>v_1</math>,再通过 softmax 操作得到的概率向量 SV1 作为输入序列最后一张图片的卷积核,也就是它的创新点所在.卷积核为输入的函数.将得到的特征图与卷积核(概率向量 SH1)进行卷积,输出的特征图由 CROP 修剪出中心补丁与下一个 10 min 的雷达图像计算欧几里得损失以训练网络</p>	<p>实验结果表明,通过使用新层,与包括常规 CNN 在内的其他基准相比,可以提高性能</p>	<p>优点:针对卷积核位置不变的结构设计了动态卷积核,随着输入的不同卷积核是动态变化的. 缺点:1) 只在输出的前两层使用了动态卷积,整体还是使用了位置不变的卷积核; 2) 将整个网络前半部分的输出,一维概率向量,作为卷积核,不但一维的卷积核无法提取到复杂的运动特征,而且使用本身的输出作为卷积核限制了卷积核的多样性</p>
<p>文献[56]设计了一种新颖的时空卷积神经网络(ST-CNN).该模型共有 6 层,包括 2 个卷积层,2 个池化层和 2 个全连接层.他们使用多个时空张量数据作为输入,该时空数据为在 <math>m \times n</math> 区域上的 <math>k</math> 个时间间隔的 <math>m \times n \times k</math> 长方体,输出为未来 <math>x</math> 时间内的降水量分类</p>	<p>实验结果表明模型可以充分利用时空信息,且精确度高于 OSFS 方法</p>	<p>优点:该网络可以学习气象变量对时空邻域的依赖性从而进行可靠的极端降水长期预报</p>
<p>文献[57]使用多通道 3D 立方体连续卷积网络(3D-SCN)使用多源气象数据来进行对流风暴开始(CI)和增长的预测,网络堆叠连续的卷积层而不进行池化.在这项研究中,他们将降雨检测作为一个雷达回波是否大于 35 dBz 的分类问题,模型输入为包括原始 3D 雷达和重新分析气象数据的六通道数据,每个通道都由 20 层 2D 数据形成的 3D 数据,并通过跨通道 3D 卷积进行卷积</p>	<p>3D-SCN 实现了比 TITAN 更高的 POD 值和相似的 FAR 值,从而获得更好的 CSI 值,这意味着 3D-SCN 具有更好的整体性能</p>	<p>优点:1) 采用了 3D 立体数据,考虑了高度信息对于结果的影响; 2) 除了使用雷达图像数据作为输入外,还使用了 2 个传统数值预测模型的输出作为模型输入</p>
<p>文献[65]使用 ConvLSTM 顺序输入 3D 雷达图像序列,即 4 个高度的四通道 2D 图像,时间作为第四维度.直接使用输入雷达图像序列的未来 1~2 h 降雨量作为数据标签训练模型</p>	<p>与线性回归相比,两层 ConvLSTM 将 RMSE 降低了 23.0%</p>	<p>缺点:1) 直接将降雨量作为标签训练模型,无从得知模型是否学习到了有用信息,结果具有较强的不可解释性; 2) 同样使用位置不变的卷积结构</p>
<p>文献[5]提出了 TrajGRU 来解决时空恒定的问题,可以自主学习变化的结构.同样使用了 encoder-decoder 模型,不同之处在于预测器反向输出,encoder 模型部分先卷积操作提取雷达图像特征,然后输入堆叠的 3 层 TrajGRU 中,每层 RNN 间都进行了下采样,以学习雷达图序列的全局运动特征;decoder 模型部分同样堆叠 3 层 TrajGRU,每层间进行下采样,逐步从全局补充运动细节.同样输入输出 2D 雷达图序列</p>	<p>对比了 ConvGRU,不使用/使用加权损失函数训练,Conv2d、Conv3d 等几种方法,实验结果表明 TrajGRU 取得了比 ConvGRU、Conv3d、光流法等方法更好的结果</p>	<p>优点:1) 创新性地提出了 TrajGRU,可以自主学习雷达序列间变化的结构; 2) 提出了 HKO-7 基准,可以 online-setting,利用新数据动态地训练模型. 缺点:模型较为复杂</p>
<p>文献[55]提出了基于输入的动态卷积神经网络结构(DCNN-I)实现雷达回波图像的预测和外推.该网络相比传统 CNN 增加了动态子网络(Dynamic Sub-Network, DSN)和概率预测层(Probability Prediction Layer, PPL).其中 DSN 即为传统 CNN,用于根据输入图像序列的不同动态调整卷积核,其输出作为 PPL 的卷积核;PPL 将输入图像序列与得到的卷积核进行一系列卷积操作得到最终外推图像.可以将动态卷积操作视为垂直方向和水平方向的预测</p>	<p>与 COTREC 算法和 DITREC 算法相比,采用 DCNN-I 的雷达回波外推方法能够得到更好的预测结果,预测结果也较为稳定,预测准确率(MSE)约有 10%的提升</p>	<p>优点:1) 解决了传统交叉相关法预测雷达外推图只利用前几个时刻数据的缺点; 2) 动态卷积的卷积核利用了概率向量元素均为正且和为 1 的特征,可以得到最后一张图像的垂直方向和水平方向的预测</p>
<p>文献[59]将降水预测问题看作是一个图像的转换问题并且使用 U-Net 卷积神经网络来处理.模型虽然提供了瞬时预测,但 HRRR 中使用的数值模型可以做出更好的长期预测.因此将 HRRR 和机器学习模型这两种方法结合起来可能会实现准确、快速短期以及长期预测</p>	<p>该模型比光流法和 HRRR 数值预测法的结果更优</p>	<p>优点:预测结果是实时有效的,可以基于实时的新数据</p>
<p>文献[60]使用全卷积神经网络基于雷达图进行预报,模型共有 6 层顺序连接的卷积层 DozhdyNet,所有卷积层都没有采用跨步操作.模型输入为最近的 2 张雷达图,输出下一步雷达图</p>	<p>该模型明显优于欧拉持久性模型,且可与当前最先进的光流法匹敌</p>	<p>优点:1) 深度学习模型可以直接考虑降雨强度演变的增长和衰减过程; 2) 每次输出下一个时间步的雷达图,模型简单. 缺点:1) 输入数据仅为前两张图片,没有充分利用数据,很可能导致结果泛化能力差; 2) 卷积结构的位置不变性使每个雷达图像具有相同的降雨场转换</p>

象科学相结合,科学家们发现了从前不知道的气候特征和大气运动,同时还能够对气象模型做出排序和选择.现在研究气候的学者们面临着数以万计的数据需要进行处理,其中,就有人在寻求 AI 的帮助,以便从海量的数据里找到有用的信息,方便更好地预测天气情况.

降水预报任务与人工智能技术相结合还处于初级阶段,虽然已经优于传统模型,但在许多方面仍需要进一步研究与发展.为此,我们归纳总结了人工智能在短临降水预报中的研究方向,主要分为提高降水预报、灾害天气预报准确率和灾害天气智能风险预警技术.

首先,进一步提升短期降水预报准确率可以考虑 2 个研究方向:1)将人工智能技术与传统数值预报模型结合,理论驱动与数据驱动互为补充<sup>[1]</sup>,联合开展人工智能技术,利用多种数值预报产品及实况观测资料,针对不同季节,开展人工智能技术在中短期降水预报中的偏差订正研究,建立分时效降水偏差订正预报模型,生成中短期降水预报产品,提升中短期降水预报准确率;2)将降水预测问题看作是一个图像的转换问题,开展 2~6 h 雷达外推与模式融合降水预报等技术应用研究,使用人工智能技术提高雷达外推的准确率和及时性.

其次,需要加强灾害性天气短期预报技术研究.开展基于机理分析的灾害性天气短期客观预报技术,提高灾害预报的短期预报的准确性和精细性;研究大数据、机器学习等新技术在灾害天气短期预报方面的应用.

最后,在准确率提升的前提下除了开展 0~2 h 智能降水预报,强天气对人类影响更为严重,所以还需开展强天气监测预报预警业务核心技术研究应用以及气象灾害风险预警技术研究.对于强天气预警技术,采用基于大数据和人工智能的强降水、雷暴大风、冰雹、龙卷风、雷电等强对流天气系统监测识别、分类强对流天气智能识别和智能报警技术,建立强天气智慧预报预警业务;对于气象灾害风险预警技术,联合开展基于动态阈值和基于物理机理的多灾种气象风险预警技术研究应用,强化中小河流山洪地质灾害气象风险预警能力,开展大数据、机器学习等新技术在灾害性天气智能监测报警等方面的应用研究.

## 5 总结

降水问题与人们的日常生活息息相关,提高降

水预报的精确性仍是研究人员需要努力的方向.本文对短临降雨预报的相关方法进行了较为全面的综述,表 3 和表 4 对各种降水方法进行了概述并对比了各个方法的优缺点.

雷达图为近代短临降水预测提供了重要的数据支持.多普勒雷达回波外推根据当前时刻雷达观测结果,运用相关技术,推测雷达回波未来的位置和强度,如传统方法中的光流法就是一个被广泛运用的使用雷达回波外推技术进行的短临降水预测方法,大多人工智能方法也是运用雷达图外推实现的.本文将人工智能方法分为机器学习方法和深度学习方法进行介绍.机器学习部分对支持向量机、基于稳态遗传算法的 KNN、随机森林、分类回归树和 K 临近等主要方法的扩展进行了综述.在深度学习部分中,我们总结了卷积神经网络、递归神经网络、深度信念网络和复合模型的方法,并着重介绍了在短临降水预测上提出的新思路新方法.最后,我们分析了人工智能在短临降水预报中的研究方向,以供未来研究人员参考与进一步发展.

## 参考文献

### References

- [ 1 ] Reichstein M, Camps-Valls G, Stevens B, et al. Deep learning and process understanding for data-driven Earth system science[J]. Nature, 2019, 566( 7743 ): 195-204
- [ 2 ] 邵月红,张万昌,刘永和,等. BP 神经网络在多普勒雷达降水量的估测中的应用[J]. 高原气象, 2009, 28( 4 ): 846-853  
SHAO Yuehong, ZHANG Wanchang, LIU Yonghe, et al. Application of back-propagation neural network in precipitation estimation with Doppler radar[J]. Plateau Meteorology, 2009, 28( 4 ): 846-853
- [ 3 ] Rinehart R E, Garvey E T. Three-dimensional storm motion detection by conventional weather radar [ J ]. Nature, 1978, 273( 5660 ): 287-289
- [ 4 ] Shi X J, Chen Z R, Wang H, et al. Convolutional LSTM network: a machine learning approach for precipitation nowcasting[ J ]. e-print, 2015. arXiv: 1506. 04214
- [ 5 ] Shi X, Gao Z, Lausen L, et al. Deep learning for precipitation nowcasting: a benchmark and a new model[ C ] // Advances in Neural Information Processing Systems, 2017: 5617-5627
- [ 6 ] 张鹏程,张雷,王继民.一种基于深度网络的多环境因素降水量预报模型[J]. 计算机应用与软件, 2017, 34( 9 ): 240-245, 261  
ZHANG Pengcheng, ZHANG Lei, WANG Jimin. A model for precipitation forecasting of multiple environmental factors based on deep network[J]. Computer Applications and Software, 2017, 34( 9 ): 240-245, 261

表3 传统方法中各种降水预测方法概括及对比

Table 3 Summary and comparison of various precipitation prediction methods in traditional methods

方法	概括	优缺点
物理统计模型法	该方法通过收集与降水相关的多种具有物理意义的关联因子,利用前兆信息因子和后期信息的遥相关原理建立物理统计模型,从而对长期的降水量进行预测	缺点:1)需要结合对大气如何工作的先验知识; 2)需要收集大量的降水相关数据,并且对数据的质量要求较高; 3)只能对洪涝灾害进行宏观的预测
统计方法	马尔可夫链预测法	将数据按降水量划分状态,计算状态概率转移矩阵,根据 $n$ 时刻的状态预测 $n+1$ 时刻的状态,概率最大的值即为预测结果 优点:可以进行长时间的预测. 缺点:1)对大气降水量进行预测时,状态界限是不确定的; 2)仅仅使用了前一步的状态转移概率,并且忽略了降水的时空相关性
	基于数值天气预测方法	数值天气预报是根据大气实际情况,在一定初值和边值条件下,通过用数值方法求解支配大气运动的流体动力学和热力学方程组,来预报未来的大气环流形势和天气 优点:在一定程度上实现更长时间的较为精确的预测. 缺点:1)需要具备气候动力学、热力学相关知识,模型复杂; 2)无法提供确切的降雨区域,特定的位置和特定的时间限制了降水事件的预报强度; 3)提供的信息是小时分辨率的,导致在短时强降雨的情况下很难区分无雨的时间隔
基于雷达图的方法	Z-R 关系式法	通过雷达回波强度和雨强二者之间建立的关系式来估算,即天气雷达反射率因子( $Z$ )和雨强( $R$ )的 $Z-R$ 的关系式 $Z=aR^b$ , $a$ 和 $b$ 为经验系数 缺点:具有自身的局限性且对特点气候背景的强烈依赖性,从而模型的泛化能力弱,需要进行本地化,即基于气象知识,校正不同的 $Z-R$ 关系
	云团外推技术	根据相邻时刻同一云团形成的两幅反射率因子图,计算它们之间的变化,并依此得到未来短期时刻的云团形态 缺点:1)没有充分利用雷达序列数据; 2)预报准确率较低
	光流法	光流法是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的一种方法 优点:可以实现短临降水预测. 缺点:1)先估算光流矢量再进行外推会存在累积误差; 2)没有充分利用雷达回波序列数据

表4 人工智能方法中各种降水预测方法概括及对比

Table 4 Summary and comparison of various precipitation prediction methods in artificial intelligence methods

方法	概括	优缺点
机器学习	人工神经网络、支持向量机、K-近邻算法、随机森林等方法进行短临降水预测	缺点:1)没有考虑数据的时空相关性,存在空间冗余; 2)神经网络层数较少导致泛化能力较差,提高层数导致参数过多且优化效果并不好
深度学习	通过获取的大量雷达图像,使用深度学习方法,如卷积神经网络、递归神经网络和深度信念网络,或者复合模型的方法来对雷达图像序列进行精确的外推	优点:1)可以使用神经网络强大的学习能力来建模具有高度非线性、复杂性、随机性的降雨问题; 2)可以充分利用雷达图像序列数据实现前1~2 h的短临降水预测; 3)预报准确率高,且对新生雨带有一定的预测能力. 缺点:开始几个小时预测精度较高,却很难预测更长时间的降水事件

[ 7 ] 陈菊英,齐晶,杨鹏,等.海河流域分区汛期降水量的多级预报物理模型的应用前景[C]//全国水文学术讨论会,2004:246-251

[ 8 ] 马振锋,谭友邦.预测川渝地区汛期降水量的一种物理统计模型[J].大气科学,2004,28(1):138-145  
MA Zhenfeng, TAN Youbang. A physical statistic model for predicting the rainfall during flood season in Sichuan-Chongqing region [J]. Chinese Journal of Atmospheric Sciences, 2004, 28(1): 138-145

[ 9 ] 冉景江,赵燮京,梁川.基于加权马尔可夫链的降水预测应用研究[J].人民黄河,2006,28(4):32-34  
RAN Jingjiang, ZHAO Xiejing, LIANG Chuan. Application research of precipitation forecasting based on weighted Markov chain[J]. Yellow River, 2006, 28(4): 32-34

[ 10 ] 夏乐天,朱元胜.马尔可夫链预测方法的统计试验研究[J].水利学报,2007,38(增刊1):372-378  
XIA Letian, ZHU Yuanshen. Study on statistical experiments of Markov chain prediction methods[J]. Journal of Hydraulic Engineering, 2007, 38(sup1): 372-378

[ 11 ] Epstein E S. Stochastic dynamic prediction [J]. Tellus, 1969, 21(6): 739-759

[ 12 ] 刘瑞霞.风云卫星资料在 LAPS 中的应用及对短临降水预报的影响研究[C]//第33届中国气象学会年会论文集.西安,2016:33-36

[ 13 ] 程丛兰,陈明轩,王建捷,等.基于雷达外推临近预报和中尺度数值预报融合技术的短时定量降水预报试验[J].气象学报,2013,71(3):397-415



- CHENG Conglan, CHEN Mingxuan, WANG Jianjie, et al. Short-term quantitative precipitation forecast experiments based on blending of nowcasting with numerical weather prediction[J]. *Acta Meteorologica Sinica*, 2013, 71(3): 397-415
- [14] Wu M C, Lin G F. The very short-term rainfall forecasting for a mountainous watershed by means of an ensemble numerical weather prediction system in Taiwan [J]. *Journal of Hydrology*, 2017, 546: 60-70
- [15] 方鸿斌, 鲁礼炳, 谭江红. 荆州新一代天气雷达汛期 Z-R 关系本地化研究[C] // 第 34 届中国气象学会年会 S18 气象雷达探测新技术与数据质控的业务应用论文集, 2017
- [16] 张蓉. 基于卫星遥感图像的降水云团跟踪技术研究 [D]. 南京: 南京信息工程大学, 2013  
ZHANG Rong. Research on the tracking technology of the precipitation cloud based on satellite remote sensing images [D]. Nanjing: Nanjing University of Information Science and Technology, 2013
- [17] Gibson J J. The perception of the visual world [M]. Boston: Houghton Mifflin Co., 1950
- [18] Horn B K P, Schunck B G. Determining optical flow [J]. *Artificial Intelligence*, 1981, 17(1/2/3): 185-203
- [19] Lucas B D, Kanade T. An iterative image registration technique with an application to stereo vision [C] // Proceedings DARPA Image Understanding Workshop, 1981: 121-130
- [20] Woo W, Wong W. Operational application of optical flow techniques to radar-based rainfall nowcasting [J]. *Atmosphere*, 2017, 8(3): 48
- [21] Novak P. The Czech Hydrometeorological Institute's severe storm nowcasting system [J]. *Atmospheric Research*, 2007, 83(2/3/4): 450-457
- [22] Wang G L, Wong W, Liu L P, et al. Application of multi-scale tracking radar echoes scheme in quantitative precipitation nowcasting [J]. *Advances in Atmospheric Sciences*, 2013, 30(2): 448-460
- [23] Wong W K, Yeung L H Y, Wang Y C, et al. Towards the blending of NWP with nowcast: operation experience in B08FDP [C] // WMO Symposium on Nowcasting, 2009
- [24] Bruhn A, Weickert J, Feddern C, et al. Real-time optical flow computation with variational methods [C] // International Conference on Computer Analysis of Images and Patterns, 2003: 222-229
- [25] Bruhn A, Weickert J, Feddern C, et al. Variational optical flow computation in real time [J]. *IEEE Transactions on Image Processing*, 2005, 14(5): 608-615
- [26] Bellon A, Zawadzki I, Kilambi A, et al. McGill algorithm for precipitation nowcasting by lagrangian extrapolation (MAPLE) applied to the South Korean radar network. part I: sensitivity studies of the Variational Echo Tracking (VET) technique [J]. *Asia-Pacific Journal of Atmospheric Sciences*, 2010, 46(3): 369-381
- [27] Wilson J W, Brandes E A. Radar measurement of rainfall: a summary [J]. *Bulletin of the American Meteorological Society*, 1979, 60(9): 1048-1058
- [28] Xiao R R, Chandrasekar V. Development of a neural network based algorithm for rainfall estimation from radar observations [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1997, 35(1): 160-171
- [29] French M N, Krajewski W F, Cuykendall R R. Rainfall forecasting in space and time using a neural network [J]. *Journal of Hydrology*, 1992, 137(1/2/3/4): 1-31
- [30] Luk K C, Ball J E, Sharma A. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting [J]. *Journal of Hydrology*, 2000, 227(1/2/3/4): 56-65
- [31] Valverde Ramírez M C, de Campos Velho H F, Ferreira N J. Artificial neural network technique for rainfall forecasting applied to the São Paulo region [J]. *Journal of Hydrology*, 2005, 301(1/2/3/4): 146-162
- [32] Mesinger F, Black T L, Plummer D W, et al. Eta model precipitation forecasts for a period including tropical storm allison [J]. *Weather and Forecasting*, 1990, 5(3): 483-493
- [33] Hong W C. Rainfall forecasting by technological machine learning models [J]. *Applied Mathematics and Computation*, 2008, 200(1): 41-57
- [34] Seo J H, Kim Y H. Genetic feature selection for very short-term heavy rainfall prediction [C] // 6th International Conference on Convergence and Hybrid Information Technology, 2012: 312-322
- [35] Kusiak A, Wei X P, Verma A P, et al. Modeling and prediction of rainfall using radar reflectivity data: a data-mining approach [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(4): 2337-2342
- [36] Yu P S, Yang T C, Chen S Y, et al. Comparison of random forests and support vector machine for real-time radar-derived rainfall forecasting [J]. *Journal of Hydrology*, 2017, 552: 92-104
- [37] Huang M M, Lin R S, Huang S, et al. A novel approach for precipitation forecast via improved K-nearest neighbor algorithm [J]. *Advanced Engineering Informatics*, 2017, 33: 89-95
- [38] Solanki N, Panchal G. A novel machine learning based approach for rainfall prediction [C] // International Conference on Information and Communication Technology for Intelligent Systems, 2017: 314-319
- [39] Sharma A K, Chaurasia S, Srivastava D K. Supervised rainfall learning model using machine learning algorithms [C] // International Conference on Advanced Machine Learning Technologies and Applications, 2018: 275-283
- [40] 张晨阳, 杨雪冰, 张文生. 气象大数据超短临精准降水机器学习与典型应用 [J]. *农业大数据学报*, 2019(1): 78-87  
ZHANG Chenyang, YANG Xuebing, ZHANG Wensheng. Accurate precipitation nowcasting with meteorological big data: machine learning method and application [J]. *Journal of Agricultural Big Data*, 2019(1): 78-87
- [41] Hu M J C. Application of ADALINE system to weather forecasting [R]. Stanford Electron Technical Report, 1964
- [42] 李滨. 人工神经网络在气候预测中的应用研究 [D]. 北京: 中国科学院自动化研究所, 1994
- [43] Kalogirou S, Neocleous C, Michaelides S, et al. A time series reconstruction of precipitation records using artificial neural networks [J]. *Proceedings of EUFIT*, 1997, 97:



- 2409-2413
- [44] Venkatesan C, Raskar S D, Tambe S S, et al. Prediction of all India summer monsoon rainfall using error-back-propagation neural networks[J]. *Meteorology and Atmospheric Physics*, 1997, 62(3/4): 225-240
- [45] Lee S, Cho S, Wong P M. Rainfall prediction using artificial neural networks[J]. *Journal of Geographic Information and Decision Analysis*, 1998, 2(2): 233-242
- [46] 吴涛, 刘登瀛, 许晓鸣, 等. 利用神经网络外推预测干燥过程降水率[J]. *上海交通大学学报*, 1999, 33(5): 596-599  
WU Tao, LIU Dengying, XU Xiaoming, et al. Predicting water content of drying process using neural network model[J]. *Journal of Shanghai Jiao Tong University*, 1999, 33(5): 596-599
- [47] Toth E, Brath A, Montanari A. Comparison of short-term rainfall prediction models for real-time flood forecasting[J]. *Journal of Hydrology*, 2000, 239(1/2/3/4): 132-147
- [48] 郭尚瓚, 肖达, 袁行远. 基于神经网络和模型集成的短时降雨预测方法[J]. *气象科技进展*, 2017, 7(1): 107-113  
GUO Shangzan, XIAO Da, YUAN Xingyuan. A short-term rainfall prediction method based on neural networks and model ensemble[J]. *Advances in Meteorological Science and Technology*, 2017, 7(1): 107-113
- [49] Deshpande, Rohit R. On the rainfall time series prediction using multilayer perceptron artificial neural network[J]. *International Journal of Emerging Technology and Advanced Engineering*, 2012, 2(1): 2250-2459
- [50] Hernández E, Sanchez-Anguix V, Julian V, et al. Rainfall prediction: a deep learning approach[C]// *International Conference on Hybrid Artificial Intelligence Systems*, 2016: 151-162
- [51] Wong K W, Wong P M, Gedeon T D, et al. Rainfall prediction model using soft computing technique[J]. *Soft Computing-A Fusion of Foundations, Methodologies and Applications*, 2003, 7(6): 434-438
- [52] 张继学, 王鹏, 张琳, 等. 人工神经网络在短期降水预测方面的应用研究[J]. *科技风*, 2016(17): 123-124  
ZHANG Jixue, WANG Peng, ZHANG Lin, et al. Application of artificial neural network in short-term precipitation prediction[J]. *Technology Wind*, 2016(17): 123-124
- [53] 季刚, 姚艳, 江双五. 基于径向基神经网络的月降水量预测模型研究[J]. *计算机技术与发展*, 2013, 23(12): 186-189  
JI Gang, YAO Yan, JIANG Shuangwu. Research on monthly rainfall forecast model based on RBF neural network[J]. *Computer Technology and Development*, 2013, 23(12): 186-189
- [54] Liu X, Zhang A, Shi C, et al. Filtering and multi-scale RBF prediction model of rainfall based on EMD method [C] // *IEEE First International Conference on Information Science and Engineering*, 2009: 3785-3788
- [55] 施恩, 李骞, 顾大权, 等. 基于卷积神经网络的雷达回波外推方法[J]. *计算机应用*, 2018, 38(3): 661-665, 676  
SHI En, LI Qian, GU Daquan, et al. Weather radar echo extrapolation method based on convolutional neural networks[J]. *Journal of Computer Applications*, 2018, 38(3): 661-665, 676
- [56] Zhuang W Y, Ding W. Long-lead prediction of extreme precipitation cluster via a spatiotemporal convolutional neural network[C]// *Proceedings of the 6th International Workshop on Climate Informatics*, 2016
- [57] Zhang W, Han L, Sun J Z, et al. Application of multi-channel 3D-cube successive convolution network for convective storm nowcasting[C]// *IEEE International Conference on Big Data*, 2019. DOI: 10.1109/BigData47090.2019.9005568
- [58] Klein B, Wolf L, Afek Y. A Dynamic Convolutional Layer for short rangeweather prediction[C]// *IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 4840-4848
- [59] Agrawal S, Barrington L, Bromberg C, et al. Machine learning for precipitation nowcasting from radar images[J]. *arXiv preprint*, 2019, arXiv:1912.12132
- [60] Ayzel G, Heistermann M, Sorokin A, et al. All convolutional neural networks for radar-based precipitation nowcasting[J]. *Procedia Computer Science*, 2019, 150: 186-192
- [61] Lebedev V, Ivashkin V, Rudenko I, et al. Precipitation nowcasting with satellite imagery[C]// *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2019: 2680-2688
- [62] 张帅, 魏正英, 张育斌. 递归神经网络在降雨量预测中的应用研究[J]. *节水灌溉*, 2017(5): 63-66, 71  
ZHANG Shuai, WEI Zhengying, ZHANG Yubin. Forecasting rainfall with recurrent neural network[J]. *Water Saving Irrigation*, 2017(5): 63-66, 71
- [63] Wu K, Shen Y, Wang S. 3D convolutional neural network for regional precipitation nowcasting[J]. *Journal of Image and Signal Processing*, 2018, 7(4): 200-212
- [64] Gope P M S, Sarkar S, Mitra P. Prediction of extreme rainfall using hybrid convolutional long short term memory networks[C]// *Proceedings of the 6th International Workshop on Climate Informatics*, 2016. DOI: 10.5065/D6K072N6
- [65] Kim S, Hong S, Joh M S, et al. DeepRain: ConvLSTM network for precipitation prediction using multichannel radar data[J]. *e-print*, 2017. arXiv:1711.02316
- [66] Shi X J, Yeung D Y. Machine learning for spatiotemporal sequence forecasting: a survey [J]. *e-print*, 2018. arXiv:1808.06865

## Survey on the application of artificial intelligence in precipitation nowcasting

FANG Wei<sup>1,2</sup> PANG Lin<sup>1</sup> WANG Nan<sup>3</sup> YI Weinan<sup>1</sup>

1 School of Computer and Software, Nanjing University of Information Science and Technology, Nanjing 210044

2 Provincial Key Laboratory for Computer Information Processing Technology, Soochow University, Suzhou 215006

3 Shaanxi Meteorological Observatory, Xi'an 710014

**Abstract** Precipitation nowcasting is an important and challenging worldwide problem. Various techniques have been used to predict precipitation, but the accuracy of precipitation nowcasting is not high due to the highly nonlinear, random, and complex nature of precipitation. In recent years, with the rapid development of artificial intelligence technology, it has gradually penetrated into all aspects of people's lives, and the meteorological fields are no exception. Compared to traditional methods, such as numerical weather forecasting and optical flow methods, artificial neural networks can model non-linear systems, which makes the accuracy of precipitation nowcasting being greatly improved. In this article, we review the traditional methods and summarize the latest artificial intelligence methods used for short-term precipitation forecasting, and analyze the research directions to provide useful references for various types of researchers.

**Key words** artificial intelligence; precipitation nowcasting; radar echo; neural networks; machine learning