

# 深度学习网络在降水相态判识和预报中的应用

黄驊文<sup>1,2</sup>, 蔡荣辉<sup>1,2</sup>, 姚蓉<sup>1,2</sup>, 王胜春<sup>3</sup>, 滕志伟<sup>1,2</sup>

1 湖南省气象台, 长沙 410118

2 气象防灾减灾湖南省重点实验室, 长沙 410118

3 湖南师范大学信息科学与工程学院, 长沙 410081

**摘要:** 本文利用 1996-2015 年中国的高空探测资料和地面观测数据, 挑选发生降水的数十万个样本分为降雨和降雪两类事件, 抽象为二分类问题, 采用深度学习网络技术构建降水相态判识模型, 并用 2016-2017 年的数据进行测试检验, 针对 2018 年 1 月下旬中国一次大范围雨雪天气过程进行个例检验, 在此基础上探讨了深度学习网络在降水相态判识和预报中的应用。主要结论如下: 基于深度学习网络判识模型的判识准确率为 98.2%, 雨、雪的 TS 评分分别为 97.4% 和 94.4%, 空报率为 1.7% 和 2.0%, 漏报率为 1.0% 和 3.7%, 较传统指标阈值法的判识准确率有较大提高; 2018 年 1 月下旬中国一次大范围的雨雪天气个例检验显示, 基于实况探空数据的模型判识结果与降水相态实况在全国基本保持一致, 欧洲中期数值预报中心 (ECMWF) 的降水相态预报产品和模型的预报结果对全国的降水相态都表现出较好的预报能力, 而对雨雪分界线的预报, 模型的预报结果较 ECMWF 总体上更接近实况。测试结果表明, 模型较好地提取了雨、雪降水相态的结构特征, 深度学习网络在降水相态判识和预报中的应用具有可行性和一定的优势, 可为降水相态的客观判识和预报提供重要技术支撑。

**关键词:** 降水相态; 深度学习; 雨雪分界线; 检验

**中图分类号:** P456

## The Application of Deep Learning Method to Discrimination and Forecasting of Precipitation Type

Huang Jiowen<sup>1,2</sup>, Cai Rong-hui<sup>1,2</sup>, Yao Rong<sup>1,2</sup>, Wang Shenchun<sup>3</sup>, Teng Zhiwei<sup>1,2</sup>

1 Hunan Meteorological Observatory, Changsha 410118

2 Key Laboratory of Preventing and Reducing Meteorological Disaster in Hunan Province, Changsha 410118

3 College of Information Science and Engineering, Hunan Normal University, Changsha 410081

**Abstract:** This paper try to apply deep learning method on establishing a model to discriminate the precipitation type. Hundreds of thousands of precipitation samples obtained from sounding and observation data of China from 1996 to 2015 was treated to be rain and snow. Data from 2016 to 2017 were tested, and a case test was conducted for a rain and snow weather process over China in late January 2018.

**资助项目:** 湖南省气象局第三期业务能力建设项目 (NLJS01)、湖南省气象局重点项目 (XQKJ17A004)、湖南省水利重点科技项目 (XSKJ2018179-07) 和湖南省重点领域研发计划项目 (2019SK2161) 共同资助

**第一作者:** 黄驊文, 主要从事短中期天气预报工作和研究, E-mail: hjwen2010@126.com

**通讯作者:** 蔡荣辉, 主要从事天气预报技术业务和研究工作, E-mail: mitas@163.com

Furthermore, the application of deep learning method to discrimination and forecasting of precipitation type are discussed. The main conclusions are as follows. Discrimination accuracy of the model is 98.2%, which is significantly improved the traditional index threshold method. Moreover, TS scores of rain and snow are 97.4% and 94.4%, false discriminate rates are 1.7% and 2.0%, omission rates are 1.0% and 3.7%, respectively. The model discrimination results based on the real data are basically consistent with the real data, analyzed by the rain and snow weather process over China in late January 2018. The results also have a good forecast performance of precipitation type over China, which based on ECMWF precipitation type products and the model results based on the forecast data in next 24 hours. Compared with ECMWF, the forecast of the model to rain and snow separating line are more consistent with observations generally. The test results show that the discrimination model established in this paper can extract the key features of precipitation type of rain and snow. The application of deep learning method to discrimination and forecasting of precipitation type is feasible and advantageous. This method can provide important technical support for the objective identification and prediction of precipitation type.

**Key words:** precipitation type, deep learning, rain and snow separating line, verification

## 引言

随着社会的发展，冬季降水对人们的生产生活造成的影响愈发严重（马宗晋，2009）。一次冬季降水过程中可能同时包含多种降水相态或不同降水相态之间的转换，而不同降水相态的致灾性是不一样的。例如 24 h 累计降水量达到 5mm 时，如果降水相态是雨，则只是小雨天气，对城市运行和社会生产生活的影 响不大；如果降水相态是雪，天气表现为大雪，致灾性会大大提升；而如果降水相态是冻雨或者冰粒时，这种冰冻天气带来的影响则可能是致命的。即使是很弱的降雪过程，如果降水相态预报出错，也会给城市运行带来严重的不利影响（孙继松等，2003；蒋建莹等，2005）。因此，冬季降水相态的判识和预报问题非常关键，这对满足精细化天气预报需求，进一步提升防灾减灾能力具有重大意义。

我国冬季降水相态主要包括雨、雪、雨夹雪、冻雨、冰粒等。近几十年来，国内外学者开展了很多关于降水相态方面的研究，得到了不少有益的成果。早在 1974 年，Lownde et al (1974) 提出用 1000~850 hPa 的位势厚度值来区分雨雪。Heppner (1992) 在此基础上，增加 850~700 hPa 的位势厚度值来识别雨、雪、冻雨和冰粒。国内外很多学者（Bernstein, 2000；李江波等，2009；漆梁波和张瑛，2012；张琳娜等，2013；孙燕等，2013；余金龙等，2017）通过个例研究给出了一些降水相态的判识指标和阈值，其中多是包括近地面气温，位势厚度等单个指标或多个指标的组合，较好

的指标对降雪的判识准确率在 80%左右。但是,在前人的研究中,降水相态判识的指标阈值在不同区域存在差异,不具有普适性。降水相态的形成与整个大气层结中的温、湿度及其平流变化等有关(杨舒楠等,2017),简单的指标阈值法往往表征某些方面的特性,不能很好地体现整层大气之间复杂的关系,并且不同指标判识结果不一致时,也无法取舍。

近些年来,计算机运算的能力得到不断提升,神经网络的应用也得到推广。气象部门积累有海量实况数据,因而神经网络在气象上的应用拥有广泛的发展空间(Ortiz-García et al, 2014; Young et al, 2017; 李文娟等, 2018)。董全等(2013)通过对比神经网络法和线性回归法发现,神经网络法对降水相态的预报效果更优。彭霞云等(2018)利用决策树和随机森林算法对浙江省冬季降水个例进行研究,发现随机森林算法可使降雪的判识准确率得到明显提高。陈双等(2019)基于云顶温度、中层融化参数、低层湿球温度构建的决策树判别模型,可较好的提升临界气温下雨、雪的判别准确率。随着深度学习技术的发展,深度学习网络模型采用分层无监督训练方法,模型学习能力大大增加,可在大量的数据中自动提取相应的特征(韩丰等, 2019; 黄小玉等, 2019; 郭瀚阳等, 2019)。相比于传统的机器学习手动提取特征,深度学习有着更强的特征学习能力,能提取到更加丰富准确的信息,分类和预报效果获得极大的提升。因此,本文拟采用深度学习网络,研究其在我国冬季降水相态判识和预报中的应用。

## 1 数据

### 1.1 数据说明

本文采用(1)1996-2018年共23年逐日08时和20时(北京时,下同)的高空探空数据和地面观测填图资料,其中1996-2015年共20年高空探空数据和地面观测资料作为模型的训练集,以此建立基于深度学习网络的降水相态判识模型,2016-2017年冬季(12月至次年2月)数据作为降水相态判识模型的统计学检验样本集,2018年数据集作为该模型的天气学个例检验样本集,高空探空数据为中国120个探空站数据,站点分布如图1所示;(2)2018年逐日08时和20时起报的欧洲中期数值预报中心(ECMWF)的降水相态预报产品,空间分辨率为 $0.125^{\circ} \times 0.125^{\circ}$ ,用来在天气学个例预报检验中与模型的预报结果进行对比检验。文中所涉及的地图是基于审图号为GS(2017)3320号的中国地图制作,底图无修改

降水相态的预报包含了晴雨预报和发生降水后的相态预报两个问题,晴雨预报的偏差会影响到降水相态的预报偏差,为了简化问题,本文降水相态判识模型的构建和检验只针对出现降水的站点和地区。

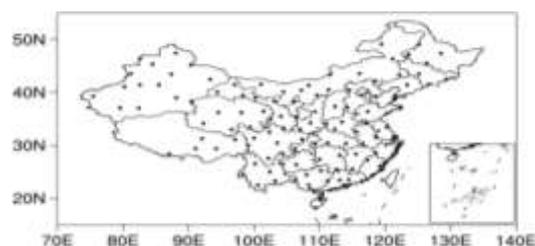


图1 中国120个探空站的分布图

Fig. 1 Distribution of 120 sounding stations in China

## 1.2 数据预处理

在将数据集输入到深度学习网络模型中进行训练前，需要对数据集进行预处理。首先，挑选出中国探空站和对应地面观测数据，将同一时间的探空数据与地面填图资料进行一一匹配。随后，将高空所有探空特性层的气象要素自下向上按层编排，与该对应时次站点的地面填图要素进行合并，最后拼接成一条长序列数据条，作为训练模型标准的输入数据条。

由于高空和地面的气温和露点温度是影响降水相态变化的关键因子，为了避免选取多个气象因子带来的样本损失，突出关键气象因子的作用，因此本文模型训练集采用的气象要素只包括地面气温、露点温度，和高空的气压、气温和露点温度。根据地面观测资料中的天气现象编码，将降水相态分为雨（包括降雨和冻雨）和雪（包括纯雪和雨夹雪）两类，其中雨、雪降水相态的对应的天气现象编码如表 1 所示。

表 1 雨、雪降水相态对应的天气现象编码  
Table 1 Weather code corresponding to precipitation type of rain and snow

降水相态	天气现象编码
1 雨	20-21,24-25,50-67,80-82,91-
2 雪	22-23,26,68-76,83-85,92-9

在模型训练过程中，每个输入数据条包含了不同的气象因子，而这些气象因子的量纲和数值量级都是不一样的。如果在模型训练中直接使用原始的数据值，就会突出数值较高的气象因子在模型训练中的作用，相对削弱数值水平较低因子的作用。因此，为了消除不同气象因子之间的量纲和数量级的影响，本文对所有输入的气象因子分别进行标准化处理。本文标准化的方法采用归一化处理，对原始数据进行线性变换，将数据统一映射到 0 至 1 之间的区间上，转换公式如下：

$$X^* = \frac{X - \min(X)}{\max(X) - \min(X)}$$

式中： $X$  为输入的气象因子序列， $X^*$  为标准化后的新序列， $\max(X)$  和  $\min(X)$  分别为该因子序列的最大值和最小值。

## 1.3 数据质量控制

在样本数据输入前，还需对其进行严格的质量控制。本文高空探空数据选取的是自下向上依次 6 个特性层的数据，不同海拔高度的站点选取的特性层也不一样，例如在低海拔地区如湖南长沙站，6 个特性层选取的是 1000、925、850、700、500 和 400hPa，而在高海拔地区如西藏拉萨站，选取的是 500、400、300、250、200 和 150hPa。在此过程中，将由站点海拔高度过高等原因导致该探空站数据不足 6 个特性层的样本剔除，当选取的数据样本中的气象要素存在缺测，也将该条数据样本进行剔除，同时还将包含奇异值，即超出该气象因子的正常阈值范围的数据样本剔除。最终，得到输入模型中的雨和雪两类降水相态的训练集和测试集，样本集数量如表 2 所示。

表 2 雨、雪降水相态的样本数（单位：个）  
Table 2 Samples corresponding to precipitation type of rain and snow

降水相态	雨	雪	总计
------	---	---	----

训练集	145767	20988	166755
测试集	2222	1059	3281

## 2 方法

### 2.1 深度神经网络算法

深度神经网络（Deep Neural Network, DNN）是一种人工神经网络（Hinton et al, 2006），包含多个隐藏层，根据神经元的特点可分为多层感知机（Multi-layer Perception, MLP）、卷积神经网络（Convolutional Neural Networks, CNN）、循环神经网络（Recurrent Neural Network, RNN）等，不管它是线性还是非线性的关系，DNN 能够在数据之间找到正确的计算关系，通过在各个层之间的计算，得到每个输出结果的概率。通过训练识别降水相态的 DNN，将遍历给定的数据集并计算每一种降水相态的概率，用户查看结果并选择最好的概率（高于某个阈值），返回对应建议的标签。这样每种降水相态的计算操作被认为是一个层，复杂的 DNN 有许多层，因此称为深层神经网络。

从 DNN 按不同层的位置划分，DNN 内部的神经网络层可以分为三类：输入层、隐藏层和输出层（图 2），其中第一层是输入层，最后一层是输出层，而中间的层数都是隐藏层。DNN 通常是前馈网络，其中数据从输入层流向输出层而不会回送。首先，DNN 创建虚拟神经元的映射，并将随机数值或“权重”分配给它们之间的连接，权重和输入相乘并返回 0 到 1 之间的输出。如果网络没有准确识别特定模式，算法将调整权重，直到它确定了正确的数学运算，以充分处理数据。目前，包括计算机视觉、语音识别和机器人在内的诸多人工智能应用已广泛使用了深度神经网络，DNN 在很多人工智能任务中表现出了当前最佳的准确度，因此本文采用 DNN 构建降水相态判识模型。

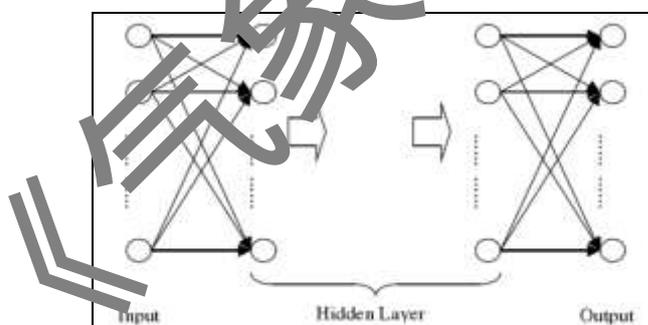


图 2 深度神经网络结构示意图（庞勇，2003）

Fig. 2 Structure diagram of deep neural network (Pang, 2003)

### 2.2 降水相态判识模型

通过大量训练试验，本文基于 DNN 的降水相态判识模型共设置 5 层神经网络，其中输入层主要提取经过预处理和质量控制后的数据。在输入层中对数据进行归一化处理，消除不同气象因子量纲和数量级的影响，在使用梯度下降的方法求解最优问题时，归一化后还可加快梯度下降的求解速度，即提升模型的收敛速度。经过输入层后，数据将通过 3 个隐藏层进行一系列变换，隐藏层节点数分别设置为 500、100 和 20 个，最后在到达输出层，得到模型的分层结果。线性整流函数（Rectified Linear Unit, ReLU），又称为修正线性单元，通常指代以斜坡函数及其变种为代表的非线性函数，是人工

神经网络中常用的一种激活函数 (Krizhevsky et al, 2012)。本文使用 ReLU 作为激活函数, 设置初始为 0.001 的自适应学习率, 得到前向传播的结果, 结合对数损失函数 (李航, 2012) 的方法对比结果与实况的差别, 使用自适应矩估计 (Adaptive Moment Estimation, Adam) 优化算法 (Kingma and Ba, 2014) 进行反向传播, 更新权重, 每次训练选取的样本数设为 200 个, 共设置 2000 次迭代, 通过反复训练, 寻找最优的结果, 最终得到基于 DNN 的降水相态判别网络模型。

### 2.3 检验方法

本文利用实况资料构建基于深度学习网络的降水相态判别模型, 对该模型的检验分为两个部分, 一部分是基于实况数据进行实况判别检验, 另一部分是基于 ECMWF 未来 24 h 预报数据, 对模型输出的预报结果和 ECMWF 降水相态产品进行预报对比检验。模型预报结果和 ECMWF 降水相态预报产品均采用最近邻点插值法, 将离站点最近的网格点数据赋值给该站点, 实现格点数据向站点数据的转化。检验中判别准确率、TS (Threat Score) 评分、空报率和漏报率计算公式如下:

$$\text{准确率: } PC = \frac{NA+ND}{NA+NB+NC+ND} \times 100\%$$

$$\text{TS 评分: } TS = \frac{NA}{NA+NB+NC} \times 100\%$$

$$\text{空报率: } FAR = \frac{NB}{NA+NB} \times 100\%$$

$$\text{漏报率: } PO = \frac{NC}{NA+NC} \times 100\%$$

式中  $NA$  为实况出现时的判别正确站 (次) 数、 $NB$  为实况未出现但模型判别出现的站 (次) 数、 $NC$  为实况出现但模型判别不出现的站 (次) 数、 $ND$  为实况未出现时的判别正确站 (次) 数。

## 3 结果检验

### 3.1 统计学检验

2016 至 2017 年冬季, 我国 120 个探空站 08 时和 20 时发生降水的样本共有 3281 个, 其中降雨样本 2222 个, 降雪样本 1059 个 (表 2)。通过计算模型的判别准确率以及降雨和降雪的 TS 评分、漏报率和空报率, 对基于深度学习网络的降水相态判别模型进行检验。结果显示, 模型的判别准确率可达 98.2%, 其中有 3221 个样本判别正确, 60 个样本判别错误, 出错的样本主要集中在我国南方地区, 模型在湖南郴州站和贵州贵阳站判别出错的频次最高, 均出现了 5 次判别错误 (图 3)。统计学检验的结果显示 (图 4), 降雨和降雪的 TS 评分分别达到了 97.4% 和 94.4%, 空报率分别为 1.7% 和 2.0%, 漏报率为 1.0% 和 3.7%, 在错判的样本中, 有 39 个样本实况为降雪, 模型判别为降雨, 还有 21 个样本实况为降雨, 模型判别为降雪。指标阈值法对降雪的判别准确率很少有超过 90% 的 (漆梁波和张瑛, 2012; 张琳娜等, 2013; 孙燕等, 2013; 余金龙等, 2017; 彭霞云等, 2018), 相较于传统指标阈值法, 模型的判别准确率有较大提升。可见, 基于深度学习网络的降水相态判别模型对实况数据表现出良好的判别性能。

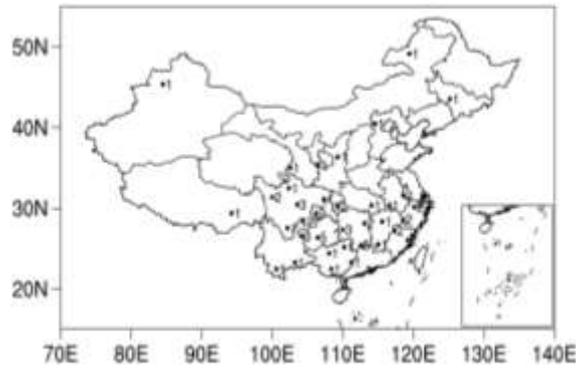


图 3 基于 2016-2017 年冬季样本模型判识出错的探空站点频次

Fig. 3 Frequency of sounding stations with the model giving incorrect identification based on the samples during the winter of 2016 and 2017

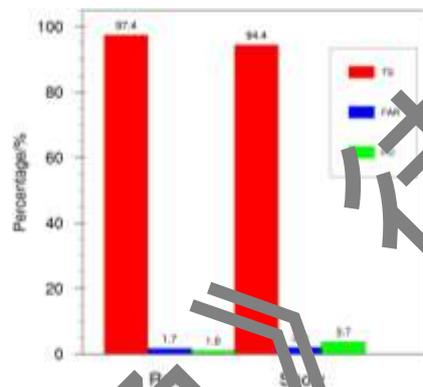


图 4 基于 2016-2017 年冬季样本的雨、雪相态统计学检验结果

Fig. 4 Statistical test results of rain and snow phase based on the samples during the winter of 2016 and 2017

### 3.2 北方天气个例检验

2018 年 1 月下旬，我国各地出现了大范围的雨雪天气，其中 1 月 21-22 日北方地区出现雨雪天气过程，接着 24-28 日我国南方出现了一次大范围的低温雨雪天气过程。此次过程具有雨雪冰冻范围广、严寒程度重、持续时间长等特点，造成了自 2008 年以来又一次较大范围的雨雪冰冻灾害。

在北方地区雨雪天气过程的开始阶段（图 5），从降水相态的实况可看出，在内蒙古中部、山西北部、河北中北部、北京和天津都出现了降雪，而长江中下游地区出现大片的降雨区。21 日 20 时我国探空站共有 12 个站点发生降水，其中 10 个站为降雨，2 个站为降雪，模型基于探空站实况数据的判识结果与降水相态实况全部一致，判识准确率为 100%。从 ECMWF 和模型对 21 日 20 时降水相态的预报结果对比可看出（与地面站观测对比，下文同），二者均在华北地区和长江中下游地区分别预报了降雪和降雨，与降水相态实况较一致，但存在较大范围的空报。此时 ECMWF 对降雨和降雪的 TS 评分分别为 36.8% 和 12.6%，而模型对降雨和降雪的 TS 评分可达 43.4% 和 20.0%，模型预报结果相对较好。

在北方地区雨雪天气过程的结束阶段（图 6），从降水相态的实况可看出，降雪区南压，此时降雪主要出现在山西北部、河北中南部、天津、辽宁南部和山东的中北部，除了南方有分散的降雨

外，山东的东南部地区也表现为降雨，在此处出现雨雪相态的分界线。22日08时我国探空站只有4个站点发生降水，其中2个站为降雨，2个站为降雪，模型基于探空站实况数据的判识结果与降水相态实况全部一致，判识准确率为100%。从ECMWF和模型对22日08时降水相态的预报结果对比可看出，二者基本在秦岭淮河一线以北地区预报为降雪，以南地区预报为降雨，降水相态预报与实况基本一致，但对山东的雨雪相态分界线的位置预报相比于实况略偏南，也存在较大范围的空报。此时ECMWF对降雨和降雪的TS评分分别为3.9%和21.6%，而模型对降雨和降雪的TS评分可达6.1%和32.7%，相较于ECMWF的降水相态预报产品，模型预报结果仍较好。

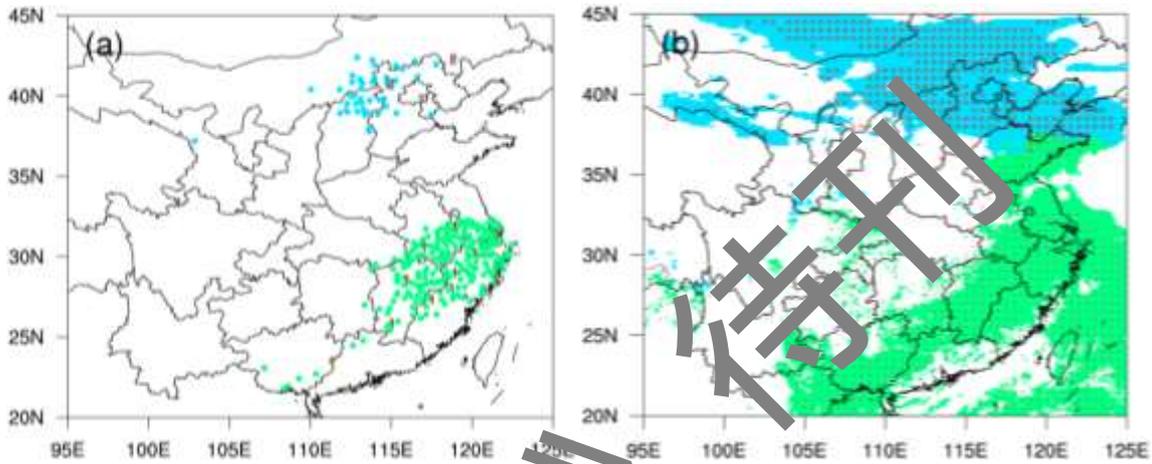


图5 2018年1月下旬中国北方地区雨雪天气过程开始阶段(21日20时)(a)降水相态实况(绿点和蓝点分别代表降雨和降雪)和模型基于实况的判识结果(数字1和2分别代表降雨和降雪)以及(b)ECMWF预报未来24h的降水相态产品(绿色和蓝色分别代表降雨和降雪)和模型基于ECMWF预报数据的未来24h降水相态预报结果(点号、星号分别代表降雨和降雪)

Fig. 5 (a)The real precipitation type (points) and the model identification results (numbers) based on observation which green point, number 1 represent rain, blue point and number 2 represent snow and (b)the ECMWF (shaded) and model forecast results (marks) of next 24 hours during the beginning stage of rain and snow weather process over north China at 20:00 BT on 21 January 2018, which green and dots represent rain, blue and number 2 represent snow.

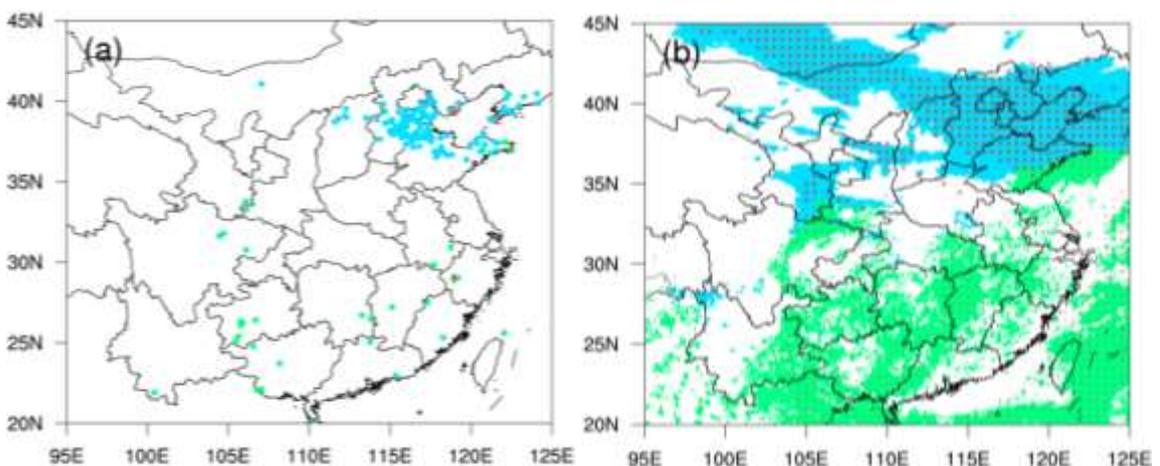


图6 同图5, 但为2018年1月下旬中国北方地区雨雪天气过程结束阶段(22日08时)

Fig. 6 Same as Figure5, but for the ending stage of rain and snow weather process over north China at 08:00 BT on 22 January 2018

### 3.3 南方天气个例检验

在南方地区雨雪天气过程的开始阶段(图7), 从降水相态的实况可看出, 我国南方出现大范围的雨雪天气, 雨雪分界线呈东西向分布, 位置分布在四川北部-重庆北部-湖南北部-湖北东北部-安徽南部-浙江北部一线。25日08时我国探空站共有24个站点发生降水, 其中8个站为降雨, 16个站为降雪, 此时模型判识准确率为95.8%, 降雨和降雪的TS评分分别为88.9%和93.4%。基于探空站实况数据的模型在上海站判识错误, 上海站实况为降雪, 而模型判识为降雨, 其他站点模型均判识正确。

从ECMWF和模型对25日08时降水相态的预报结果对比可看出, 二者的预报分歧主要位于四川东部和湖南西北部地区。从降水相态实况来看, 四川东部主要以降雨为主, 只有部分站点转为降雪, ECMWF预报此时在四川东部全部为降雪, 预报与实况存在较大偏差, 而模型预报的结果在该地区表现为降雨, 只在北部预报了降雪, 与实况更为接近。在湖南西北部地区的降水相态实况此时已转为降雪, ECMWF预报此时在湖南西北部地区主要以降雨为主, 模型预报该地区为降雪。此时ECMWF对降雨和降雪的TS评分分别为33.7%和41.3%, 而模型对降雨和降雪的TS评分可达42.4%和52.8%, 模型预报结果相对较好。

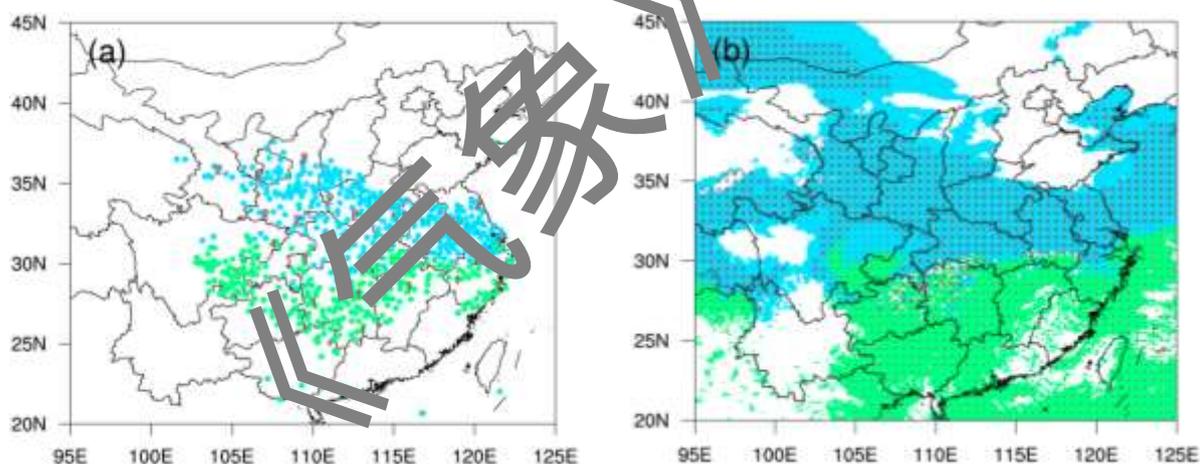


图7 同图5, 但为2018年1月下旬中国南方地区雨雪天气过程开始阶段(25日08时)

Fig. 7 Same as Figure5, but for the beginning stage of rain and snow weather process over south China at 08:00 BT on 25 January 2018

在南方地区雨雪天气过程的持续阶段(图8), 从降水相态的实况可看出, 此时雨雪分界线呈“V”型分布, 位置主要沿四川中部-贵州东部-湖南中部-江西北部-浙江中部地区。27日08时我国探空站共有33个站点发生降水, 其中10个站为降雨, 23个站为降雪, 此时模型判识准确率为94.0%, 降雨和降雪的TS评分分别为81.8%和91.7%。基于探空站实况数据的模型在江西南昌站和浙江衢州站判识错误, 南昌站实况为降雨, 模型判识为降雪, 衢州站实况为降雪, 模型判识为雨, 其他站点模型均判识正确。判识出错站点均出现在雨雪边界线附近, 这些地区降雨和降雪的温湿层结曲线比

较近似，这可能是导致模型判识出错的原因。

从 ECMWF 和模型对 27 日 08 时降水相态的预报结果对比可看出，二者的预报分歧主要位于雨雪分界线附近地区。在贵州东部、湖南中部、江西北部地区和浙江中部地区，降水相态的实况显示该地区均已转变为降雪，ECMWF 预报仍主要以降雨为主，雨雪分界线的位置预报偏北，与实况存在一定偏差。而模型预报结果显示在该地区均为降雪，雨雪分界线的预报与实况基本一致，另外针对四川东南部和重庆西部地区降水相态的预报来看，模型较 ECMWF 预报的降水区更大，与实况更吻合。此时 ECMWF 对降雨和降雪的 TS 评分均为 35.1%，而模型对降雨和降雪的 TS 评分可达 40.6%和 44.8%，模型预报结果相对较好。

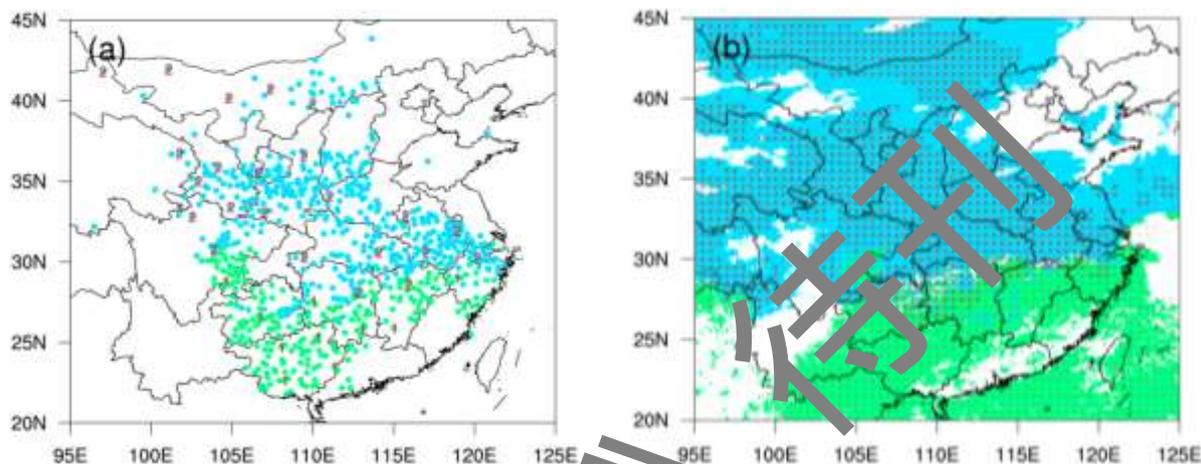


图 8 同图 5，但为 2018 年 1 月下旬中国南方地区雨雪天气过程持续阶段（27 日 08 时）

Fig. 8 Same as Figure 5, but for the continuous stage of rain and snow weather process over south China at 08:00 BT on 27 January 2018

在南方地区雨雪天气过程的结束阶段（图 9），从降水相态的实况可看出，此时雨雪分界线呈东西向分布，位置分布在贵州南部-西北部-湖南南部-江西中部-浙江中部一线。28 日 20 时我国探空站共有 17 个站点发生降水，其中 10 个站为降雨，7 个站为降雪，判识准确率为 100%，模型基于探空站实况数据的判识结果与降水相态实况全部一致。

从 ECMWF 和模型对 28 日 20 时降水相态的预报结果对比可看出，二者的预报分歧主要位于湖南南部和江西中部地区。湖南南部的降水相态实况已转为降雪，ECMWF 预报此时仍为降雨，雨雪分界线较实况偏北，而模型预报的结果在该地区表现为降雪，跟实况基本一致。而从江西中部的雨雪分界线对比来看，ECMWF 预报产品与实况基本一致，而模型预报的结果略偏南。此时 ECMWF 对降雨和降雪的 TS 评分分别为 50.8%和 13.6%，而模型对降雨和降雪的 TS 评分可达 51.9%和 22.1%，相较于 ECMWF 的降水相态预报产品，模型预报结果仍较好。

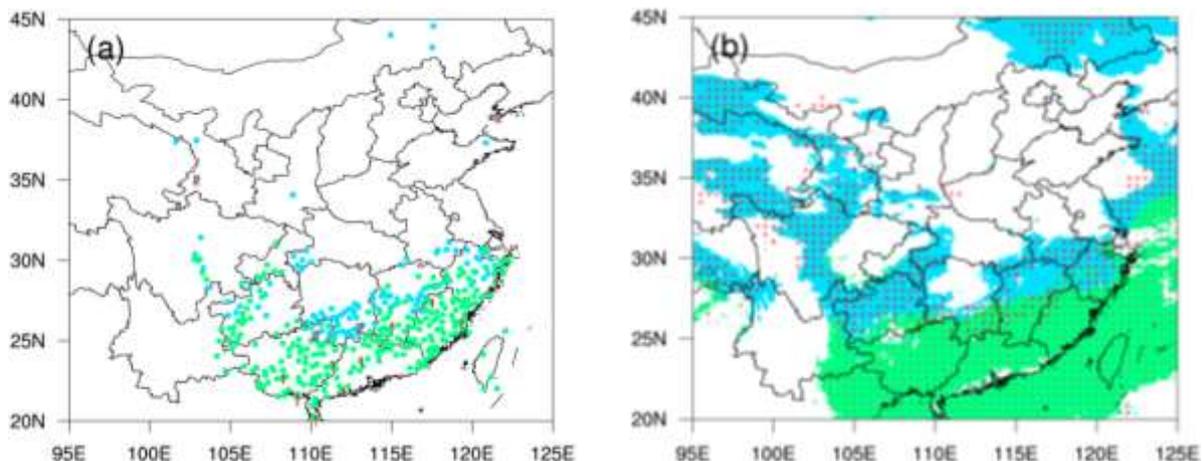


图9 同图5, 但为2018年1月下旬中国南方地区雨雪天气过程结束阶段(28日20时)

Fig. 9 Same as Figure5, but for the ending stage of rain and snow weather process over south China at 20:00 BT on 28 January 2018

通过2018年1月下旬中国一次雨雪天气个例检验发现,基于深度学习网络的降水相态判识模型对实况数据的判识结果与降水相态实况基本一致,判识准确率保持在94%以上。针对整个雨雪天气过程,ECMWF降水相态预报产品对降雨和降雪的TS评分分别为31.3%和28.6%,而本模型的预报结果对降雨和降雪的TS评分可达40.2%和39.8%。ECMWF降水相态预报产品和模型的预报结果对中国的降水相态都有较好的预报能力,但对雨雪分界附近地区,模型的预报结果较ECMWF总体上更接近实况,表明基于深度学习网络的降水相态判识和预报中的应用是合理可行的,并且具有其独特的优势。

#### 4 总结和讨论

本文利用1996-2015年共20年的探空资料和地面观测资料,应用深度学习网络技术构建降水相态判识模型,对2016-2017年的数据进行测试检验,并用2018年1月下旬中国一次大范围雨雪天气过程进行个例检验。在此基础上,对深度学习网络在降水相态判识和预报中的应用进行有益探讨,主要结论如下:

(1) 利用2016-2017年冬季3281个测试样本,对基于深度学习网络判识模型进行统计检验,该模型的判识准确率为98.2%,判识出错的样本主要集中在我国南方地区,降雨和降雪的TS评分分别可达97.4%和94.4%,空报率分别为1.7%和2.0%,漏报率为1.0%和3.7%,表明该模型较好地提取了雨、雪降水相态的结构特征,对于降水相态的判识表现出很好的效果。

(2) 2018年下旬雨雪天气个例的检验表明,基于实况数据的模型在全国的判识结果与实况基本保持一致,判识准确率保持在94%以上,针对整个雨雪天气过程,ECMWF预报对降雨和降雪的TS评分分别为31.3%和28.6%,而模型预报结果对降雨和降雪的TS评分可达40.2%和39.8%,ECMWF降水相态预报产品和模型的预报结果对全国的降水相态都有较好的预报能力,针对雨雪分界线的预报,模型的预报结果较ECMWF总体上更接近实况,表征深度学习网络在降水相态预报中的应用具有可行性和一定的优势。

本文构建的模型还存在一些不足,可尝试结合气象要素指标,进一步提高模型在雨雪分界附近

地区的判别准确率，另外本模型判别和预报的降水相态只有雨和雪两类，无法识别和预报雨雪分界附近地区出现的雨夹雪、冻雨等降水相态，需要进一步研究细化，改进模型具备多种复杂降水相态的判别和预报能力。

## 参考文献:

- 陈双, 谌芸, 何立富, 等, 2019. 我国中东部平原地区临界气温条件下降水相态判别分析[J]. 气象, 45(8): 1037-1051. Chen S, Chen Y, He L F, et al, 2019. Discrimination analysis of snow and rain occurring under critical temperature conditions in central and eastern China[J]. Meteor Mon, 45(8): 1037-1051 (in Chinese).
- 董全, 黄小玉, 宗志平, 2013. 人工神经网络法和线性回归法对降水相态的预报效果对比[J]. 气象, 39(3): 324-332. Dong Q, Huang X Y, Zong Z P, et al, 2013. Comparison of artificial neural network and linear regression methods in forecasting precipitation types[J]. Meteor Mon, 39(3): 324-332 (in Chinese).
- 郭瀚阳, 陈明轩, 韩雷, 等, 2019. 基于深度学习的强对流高分辨率临近预报试验[J]. 气象学报, 77(4): 715-727. Guo H, Chen M X, Han L, et al, 2019. High resolution nowcasting experiment of severe convections based on deep learning[J]. Acta Meteor Sin, 77(4): 715-727 (in Chinese).
- 韩丰, 龙明盛, 李月安, 等, 2019. 循环神经网络在雷达临近预报中的应用[J]. 应用气象学报, 30(1): 61-69. Han F, Long M S, Li Y A, et al, 2019. The application of recurrent neural network to nowcasting[J]. J Appl Meteor Sci, 30(1): 61-69 (in Chinese).
- 黄小玉, 张焱, 叶成志, 等, 2019. 地面积雪天气现象人工智能观测识别研究[J]. 气象, 45(9): 1189-1198. Huang X Y, Zhang Y, Ye C Z, et al, 2019. Research on artificial intelligence observation and identification of snow cover weather phenomenon on surface[J]. Meteor Mon, 45(9): 1189-1198 (in Chinese).
- 蒋建莹, 史历, 倪允琪, 2005. 一次“高影响天气”的弱降雪过程的数值研究[J]. 应用气象学报, 16(2): 231-237. Jiang J Y, Shi L, Ni Y Q, 2005. A simulation of a high impact weather event[J]. J Appl Meteor Sci, 16(2): 231-237 (in Chinese).
- 李航, 2012. 统计学习方法[M]. 清华大学出版社. Li H, 2012. Statistical Learning Method[M]. Tsinghua University Press(in Chinese).
- 李江波, 李根娥, 裴雨杰, 等, 2009. 一次春季强寒潮的降水相态变化分析[J]. 气象, 35(7): 87-94. Li J B, Li G, Pei Y J, et al, 2009. Analysis on the phase transformation of precipitation during a strong cold wave happened in spring[J]. Meteor Mon, 35(7): 87-94 (in Chinese).
- 李文娟, 赵放, 酃敏杰, 等, 2018. 基于数值预报和随机森林算法的强对流天气分类预报技术[J]. 气象, 44(12): 1555-1564. Li W J, Zhao F, Li M J, et al, 2018. Forecasting and classification of severe convective weather based on numerical forecast and random forest algorithm[J]. Meteor Mon, 44(12): 1555-1564 (in Chinese).
- 马宗晋, 2009. 2008年华南雪雨冰冻巨灾的反思[J]. 自然灾害学报, 18(2): 1-3. Ma Z J, 2009. A retrospective study of the 2008 huge disaster by low temperature, snow and ice in South China[J]. J Nat Dis, 18(2): 1-3 (in Chinese).
- 庞勇, 2003. 遗传算法和人工神经网络的分析与改进[D]. 天津大学. Pang Y, 2003. Analysis and improvement of genetic algorithm and artificial neural network[D]. Tianjin: Tianjin University (in Chinese).
- 彭霞云, 裴薇, 李文娟, 等, 2018. 数据挖掘技术用于降水相态识别的研究[J]. 科技通报, 34(1): 44-47, 71. Peng X Y, Qiu W, Li W J, et al, 2018. Apply the data digging technique on discerning the precipitation type[J]. Bull Sci Technol, 34(1): 44-47, 71 (in Chinese).
- 漆梁波, 张瑛, 2012. 中国东部地区冬季降水相态的识别判别研究[J]. 气象, 38(1): 96-102. Qi L B, Zhang Y, 2012. Research on winter precipitation types' discrimination criterion in Eastern China[J]. Meteor Mon, 38(1): 96-102 (in Chinese).
- 孙继松, 梁丰, 陈敏, 等, 2003. 北京地区一次小雪天气过程造成路面交通严重受阻的成因分析[J]. 大气科学, 27(6): 1057-1066. Sun J S, Liang F, Chen M, et al, 2003. An analysis on serious city traffic trouble caused by light snow[J]. Chin J Atmos Sci, 27(6): 1057-1066 (in Chinese).
- 孙燕, 严文莲, 尹东屏, 等, 2013. 江苏冬季降水相态气候分布特征及预报方法探讨[J]. 气象科学, 33(3): 325-332. Sun Y, Yan W L, Yin D P, et al, 2013. Climatic characteristics and forecast of precipitation phase in winter of Jiangsu[J]. J Meteor Sci, 33(3): 325-332 (in Chinese).
- 杨舒楠, 徐珺, 何立富, 等, 2017. 低层温度平流对华北雨雪天气过程的降水相态影响分析[J]. 气象, 43(6): 665-674. Yang S N, Xu J, He L F, et al, 2017. Impacts of low-level temperature advection on the precipitation type of heavy rain-snow process in North China[J]. Meteor Mon, 43(6): 665-674 (in Chinese).
- 余金龙, 朱红芳, 邱学兴, 等, 2017. 安徽冬季地面降水相态的判别研究[J]. 气象, 43(9): 1052-1063. Yu J L, Zhu H F, Qiu X X, et al, 2017. A method to determine winter precipitation type in Anhui[J]. Meteor Mon, 43(9): 1052-1063 (in Chinese).
- 张琳娜, 郭锐, 曾剑, 等, 2013. 北京地区冬季降水相态的识别判别研究[J]. 高原气象, 32(6): 1780-1786. Zhang L N, Guo R, Zeng J, et al, 2013. Research on discrimination criterion of precipitation types in Beijing in winter[J]. Plateau Meteor, 32(6): 1780-1786 (in Chinese).
- Bernstein B C, 2000. Regional and local influences on freezing drizzle, freezing rain, and ice pellet events[J]. Wea Forecasting, 15(5): 485-508.
- Heppner P O G, 1992. Snow versus rain: looking beyond the “Magic” number[J]. Wea Forecasting, 7(4): 683-691.
- Hinton G E, Osindero S, Teh Y W, 2006. A fast learning algorithm for deep belief nets[J]. Neural Comput, 18(7): 1527-1554.
- Kingma D P, Ba J, 2014. Adam: a method for stochastic optimization[J]. arXiv:1412.6980.
- Kingma D P, Ba J L, 2015. Adam: A Method for Stochastic Optimization[A]. The International Conference on Learning Representation(ICLR).
- Krizhevsky A, Sutskever I, Hinton G E, 2012. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc.: 1097-1105.
- Lowndes C A S, Beyon A, Hawson C L, 1974. An assessment of the usefulness of some snow predictors[J]. Meteor Mag, 103: 341-358. Ortiz-García E G, Salcedo-Sanz S, Casanova-Mateo C, 2014. Accurate precipitation prediction with support vector classifiers: A study including novel predictive variables and observational data[J]. Atmos Res, 139: 128-136.
- Young C C, Liu W C, Wu M C, 2017. A physically based and machine learning hybrid approach for accurate rainfall-runoff modeling during extreme typhoon events[J]. Appl Soft Comput, 53: 205-216.