

海滢, 陈光华. 2019. 利用人工神经网络模型预测西北太平洋热带气旋生成频数 [J]. 气候与环境研究, 24(3): 324–332. Hai Ying, Chen Guanghua. 2019. Prediction of frequency of tropical cyclones forming over the western North Pacific using an artificial neural network model [J]. Climatic and Environmental Research (in Chinese), 24(3): 324–332. doi:10.3878/j.issn.1006-9585.2019.18110

# 利用人工神经网络模型预测西北太平洋热带气旋生成频数

海滢<sup>1,2</sup> 陈光华<sup>2</sup>

<sup>1</sup> 成都信息工程大学大气科学学院, 成都 610225

<sup>2</sup> 中国科学院大气物理研究所季风系统研究中心, 北京 100029

**摘要** 通过对60年(1950~2009年)北半球夏、秋季(6~10月)热带气旋(TC)频数与春季(3~5月)大尺度环境变量的相关分析, 挑选出8个相关性较高的前期预报因子建立人工神经网络(ANN)模型, 对2010~2017年8年夏、秋季TC频数进行回报, 并将回报结果与传统多元线性回归(MLR)方法所得结果进行对比分析。结果表明, ANN模型对60年历史数据的拟合精度高, 相关系数高达0.99, 平均绝对误差低至0.77。在8年回报中, ANN模型相关系数为0.80, 平均绝对误差为1.97; 而MLR模型相关系数仅为0.46, 平均绝对误差为3.30。ANN模型在历史数据拟合和回报中的表现都明显优于MLR模型, 未来可考虑应用于实际的业务预测中。

**关键词** 人工神经网络 热带气旋 西北太平洋 频数

文章编号 1006-9585(2019)03-0324-09

中图分类号 P458.1<sup>+</sup>24

文献标识码 A

doi:10.3878/j.issn.1006-9585.2019.18110

## Prediction of Frequency of Tropical Cyclones Forming over the Western North Pacific Using An Artificial Neural Network Model

HAI Ying<sup>1,2</sup> and CHEN Guanghua<sup>2</sup>

<sup>1</sup> School of Atmosphere Science, Chengdu University of Information Technology, Chengdu 610225

<sup>2</sup> Center for Monsoon System Research, Institute of Atmospheric Physics, Chinese Academy of Science, Beijing 100029

**Abstract** In this study, artificial neural network (ANN) model and the multiple linear regression (MLR) model are used to predict the numbers of tropical cyclones (TCs) forming over the western North Pacific from June to October. The correlations between the frequency of TCs and the large-scale environmental variables during boreal spring (March–May) were analyzed for a period of approximately six decades 1950–2009; subsequently eight highly correlated predictors were selected to predict the TC frequency from 2010 to 2017. A comparison between ANN and MLR models shows that ANN model exhibits better performance as compared to MLR model. Specifically, the correlation coefficient ( $R$ ) reached 0.99 and the mean absolute error (MAE) was 0.77 during the historical data simulation. During the prediction period,  $R$  values of ANN and MLR models were 0.80 and 0.46, respectively. MAE values of ANN and MLR models were 1.97 and 3.30, respectively, which further confirms that ANN model significantly outperforms MLR model in both simulation and prediction and has potential for application in operational forecast.

收稿日期 2018-08-11; 网络预出版日期 2019-01-04

作者简介 海滢, 女, 1994年出生, 硕士, 主要从事热带气旋研究。E-mail: HAIYING@mailaddress@163.com

通讯作者 陈光华, E-mail: cgh@mail.iap.ac.cn

资助项目 国家自然科学基金项目 41775063、41475074, 国家重点研发计划项目 2017YFC1501901

**Funded by** National Natural Science Fundation of China (Grants 41775063 and 41475074), National Key Research and Development Program of China (Grant 2017YFC1501901)

**Keywords** Artificial neural network, Tropical cyclone, Western North Pacific, Frequency

## 1 引言

西北太平洋(WNP)是全球热带气旋(TC)生成频数最多、分布范围最广的海域之一。我国每年由TC引发的灾害损失高达370亿人民币(李真真等, 2016)。Chan(2000)以及Zhan et al.(2013)发现WNP夏、秋季(6~10月)的TC频数占全年的80%,且存在明显的年际变化。因此,准确预测WNP 6~10月的TC频数对政府部门提前制定防灾减灾计划至关重要。

Zhan et al.(2013)揭示了WNP TC频数预测的误差可能来源于预测因子的不足。关于影响WNP TC频数的因子,早期研究揭示了厄尔尼诺/南方涛动(ENSO)和准两年振荡(QBO)对TC生成频数的影响。ENSO的暖位相对应赤道中东太平洋的上升运动和西太平洋的下沉运动,引发异常的沃克环流,抑制对流活动和TC的生成;而QBO的西风相位可以通过减小对流层顶附近的垂直切变从而有利于TC频数增加(Chan, 1985, 1995)。此外,海表温度、纬向风异常、垂直风切变以及大尺度波动等因素也会对TC频数变化产生影响。陈光华和黄荣辉(2006)发现WNP暖池热状态会影响季风槽位置偏移,对应低层涡度和高层散度增强,引发中层上升运动异常,有利于TC在WNP生成。Zhan et al.(2011)揭示东印度洋海表温度异常可以通过调节西太平洋夏季风和赤道开尔文波活动,影响WNP的TC生成频数。何敏等(2007)利用相关合成分析方法研究高低层纬向风异常对TC生成频数的影响,发现在赤道东太平洋地区高层纬向风异常高于低层以及西太平洋地区高层纬向风异常低于低层的条件下,热带太平洋地区沃克环流偏强,WNP的TC生成频数偏多。王会军等(2007)提出北太平洋涛动(NPO)的正相位(弱的阿留申低压和北太平洋高压)对应于WNP的纬向风垂直切变减小,海表温度升高,有利于TC生成频数增加。当然,时间尺度上的遥相关作用对TC频数的预测也至关重要。Zhan et al.(2013)发现当春季西南太平洋海表温度高于西太平洋暖池时,会造成WNP低层环流负涡旋异常和强垂直风切变,并在整个台风季节(6~10月)抑制WNP夏季风活动,

很大程度上降低了TC频数。Fan(2007)发现春季北太平洋海冰面积的增加,影响赤道太平洋海表温度降低,并且由于海表温度的季节持续性,抑制6~10月赤道太平洋的对流发展,导致WNP的TC生成频数减少。进一步根据春季NPO指数、Nino 3.4指数、位势高度场、低层涡度场、海冰面积和风垂直切变等9个因子建立一个多元线性回归模型用于预测WNP 6~10月的TC频数。随后根据海冰面积、低层温度、垂直纬向风切变、低层涡度和海表面气压5个因子利用年际增量预测方法对西北太平洋台风生成频数进行预测(Fan and Wang, 2009; Fan, 2009)。

随着影响TC生成频数的因子的发现,统计预测模型开始运用于TC频数的预测。Nicholls(1979, 1985)最早利用ENSO和TC频数的关系开发了一套用于预测澳大利亚地区的TC频数的统计预测模型;Gray(1984a, 1984b)综合ENSO和QBO等建立了北大西洋TC频数的预测模型;Chan et al.(1998, 2001)定期发布WNP TC活动的预测,其预测模型里包含了澳大利亚季风强度,ENSO等指数,以及南太平洋副高强度等因子。统计预测结果较为精准,自此之后,针对各个不同研究海域又提出了众多统计方法,比如多元线性回归模型(Kwon et al., 2007)、泊松回归方法(Kim and Webster, 2010)、贝叶斯回归方法(Chu and Zhao, 2007)、投影寻踪回归方法(Goh and Chan, 2010)等。

除了统计预测方法,近些年各气象中心还开发了动力方法(苏志重等, 2010; Zhan et al., 2011)以及动力—统计混合方法(Kim et al., 2012; Zhan and Wang, 2016)预测季节性TC活动。然而,常规预测方法存在一定的局限性,Zhan et al.(2012)总结认为对非线性活动预测的缺陷可能在本质上限制了预测质量。而近年来受到关注的人工神经网络方法(ANN, Artificial Neural Network)拥有在描述非线性活动上的优势。BP(Back Propagation)神经网络是ANN的一种,指运用BP算法的多层感知机,而含多隐藏层的BP神经网络也属于一种深度学习结构(Bengio and Delalleau, 2011)。BP神经网络的算法成熟,具有成效,且广泛应用于气象领域。例如,利用BP神经网络方法

预测TC强度和影响广西的TC频数，解释风暴潮的数值预报（黄小刚等，2009；何慧等，2009；张娟等，2016）等等。针对TC生成频数，Nath et al. (2015) 利用5-5-1三层结构的ANN模型，及5个前期预报因子：海平面气压场、200 hPa和700 hPa的纬向风场、500 hPa位势高度场和相对湿度场，对10~12月在北印度洋生成的TC生成频数进行预测。Nath et al. (2016) 进一步分析比对了3种不同的ANN预测模型：多层BP神经网络、径向基函数以及广义回归神经网络在东印度洋TC生成频数预测中的表现，最终发现5-5-3-1结构的多层BP神经网络模型在预测中表现最优。

过去的工作均表明ANN模型在描述非线性活动方面具有明显优势。该方法在印度洋的TC频数预报中已得到应用（Nath et al., 2015, 2016）。而在WNP地区，尹宜舟等（2010）仅仅考虑了海表温度和位势高度两个环境变量的点数据，利用BP神经网络方法对TC年频数进行了预测。为了进一步探讨改善WNP 6~10月TC生成频数的季节预测水平的可能途径，本文将综合考察前期春季（3~5月）主要大尺度环境变量与WNP（不包括南海）6~10月生成的TC频数的相关关系，选定预报因子，结合60年（1950~2009年）历史数据建立ANN模型和多元线性回归（MLR）模型，再用近8年（2010~2017年）的TC数据分别对两个模型的预测结果进行对比分析，展现非线性ANN模型相较于常规线性模型的优越性。

## 2 数据和方法

### 2.1 数据

用于构建模型的原始数据分别来自：(1)

NCEP/NCAR的逐月再分析资料，包括1950~2017年北半球春季（3~5月）逐月500 hPa位势高度场、850 hPa和200 hPa纬向风场、700 hPa相对湿度场，分辨率为 $2.5^\circ$ （纬度） $\times 2.5^\circ$ （经度）；(2) Hadley环流中心 $1^\circ$ （纬度） $\times 1^\circ$ （经度）的海表温度；(3) NOAA气候预测中心的Nino 3.4指数；(4) 模型中的TC（中心最大风速大于10.8 m/s）数据来源于中国气象局热带气旋资料中心最佳路径数据集。

### 2.2 方法

ANN是由大量人工神经元互连形成的复杂神经网络。神经元结构如图1所示，输入层各因子 $x_i$ 与对应权重值 $w_i$ 相乘并求和之后与偏置值 $b$ 相加所得的结果，再利用激励函数 $f$ 将线性运算转换为非线性运算。激励函数种类繁多，比如Sigmoid函数 $y(x) = 1/(1 + e^{-x})$ 、ReLU函数 $y(x) = \max(0, x)$ 等，需根据具体模型结构和数据特征进行选择。BP神经网络作为ANN中应用最广泛的一种，其算法思路是，输入值正向传播，经过隐藏层和输出层的计算得到神经网络的输出值，与标记值（真实值）相比较，计算出损失函数，将损失函数反向传播，作为依据修正各层的权重，偏置，并且反复迭代这一过程，直至输出值与标记值的损失函数达到预定的收敛标准，或者学习次数为止，从而确定最终的BP神经网络的权重等系列参数。

### 2.3 预报因子的选取

有关大尺度环境变量调制TC频数的研究有很多（Gray, 1984a; Chan, 2000; Zhan et al., 2013），本文首先考察了太平洋前期主要环境变量与WNP 6~10月TC频数的相关关系（图2），发现春季（3~5月）这些环境变量与TC频数的相关表

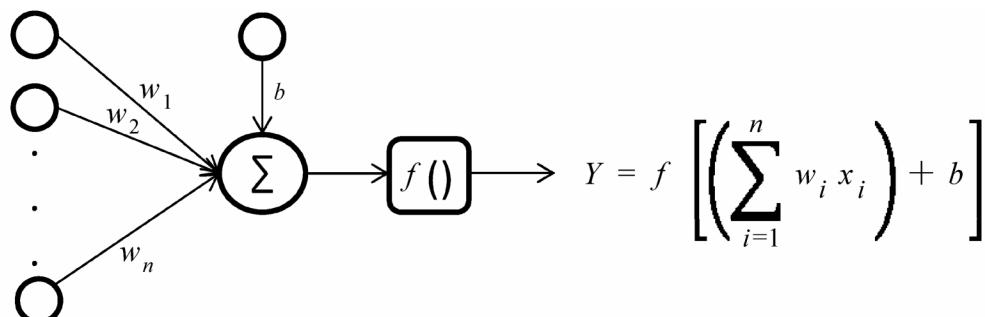


图1 人工神经元模型  
Fig. 1 Artificial neural network model

现更稳定。因此,选定春季太平洋区域的各环境变量作为TC频数的预报因子。选择相关性区域时,为了避免数据本身存在的问题,应选取相关系数较高且相关范围较广的区域。当区域平均相关系数通过95%的显著性检验时,即认为该环境变量具有潜在的预报能力。

图2反映了1950~2009年春季各大尺度环境变量与WNP TC频数的相关系数空间分布,图2a显示TC频数与赤道中东太平洋区域( $5^{\circ}\text{S} \sim 10^{\circ}\text{N}$ ,  $140^{\circ}\text{W} \sim 105^{\circ}\text{W}$ )平均850 hPa纬向风的相关系数为-0.51,而与秘鲁海岸附近( $22.5^{\circ}\text{S} \sim 15^{\circ}\text{S}$ ,  $80^{\circ}\text{W} \sim 70^{\circ}\text{W}$ )850 hPa纬向风相关系数为0.41,综合考察环境变量的正负相关区域差异(正相关区域减

去负相关区域)后,850 hPa纬向风与TC频数最终的相关系数提升至0.63。图2b中TC频数与海表温度分别在西南太平洋和赤道东太平洋附近呈现值为-0.52和-0.47的相关系数,两个负相关区域结合之后相关系数达-0.612。图2c综合200 hPa与850 hPa纬向风垂直切变在赤道东、西太平洋相关区域差异后,相关系数值为0.54。图2d为与850 hPa涡度场的相关分布,结合平均相关系数为-0.4的( $10^{\circ}\text{S} \sim 5^{\circ}\text{N}$ ,  $135^{\circ}\text{W} \sim 110^{\circ}\text{W}$ )区域和0.42的( $10^{\circ}\text{N} \sim 15^{\circ}\text{N}$ ,  $155^{\circ}\text{W} \sim 120^{\circ}\text{W}$ )区域,得到0.54的相关系数。图2e显示在赤道东( $2.5^{\circ}\text{N} \sim 7.5^{\circ}\text{N}$ ,  $130^{\circ}\text{E} \sim 152.5^{\circ}\text{E}$ )、西( $7.5^{\circ}\text{S} \sim 2.5^{\circ}\text{N}$ ,  $115^{\circ}\text{W} \sim 95^{\circ}\text{W}$ )太平洋区域的200 hPa纬向风与TC频数的

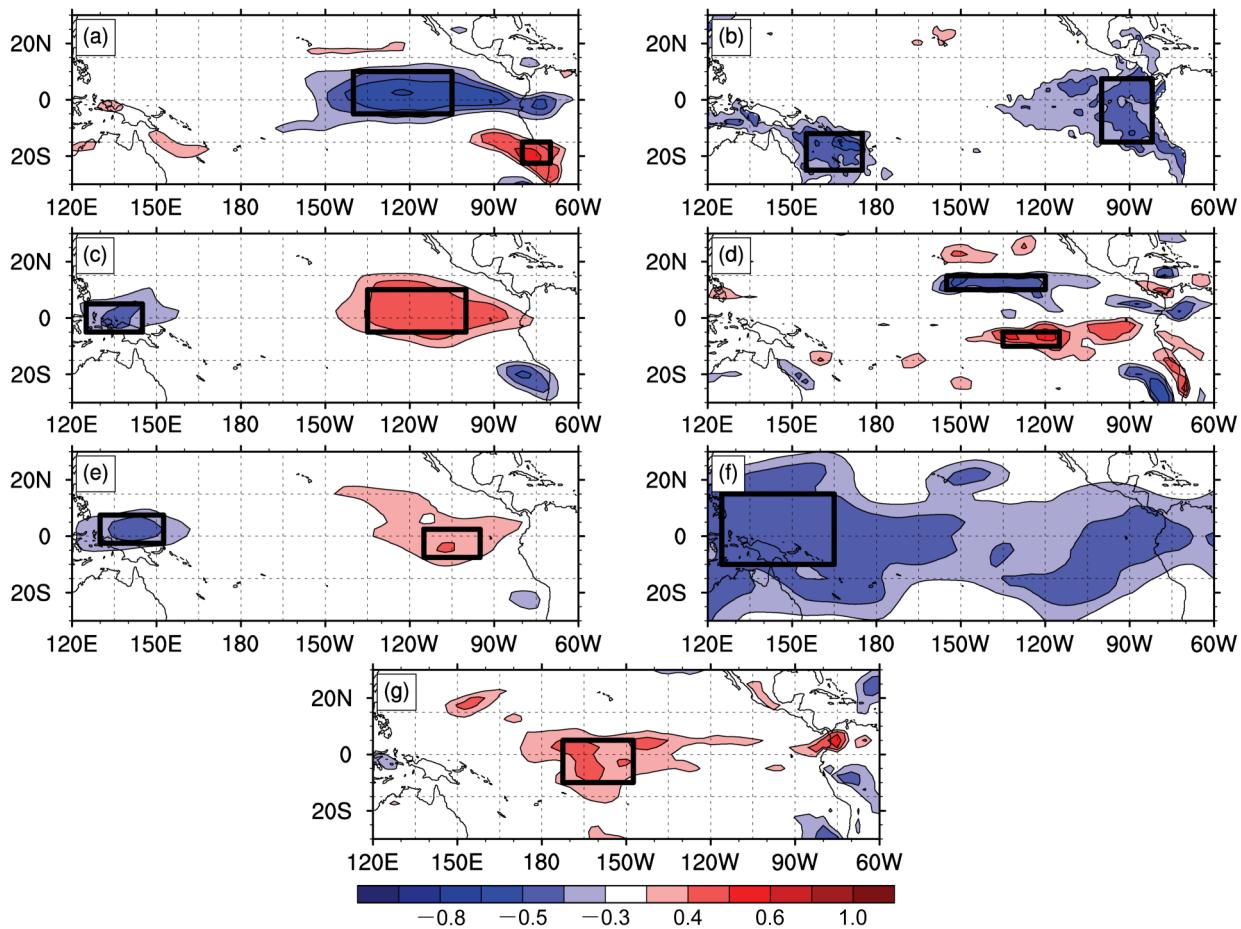


图2 1950~2009年6~10月TC频数与春季环境变量的相关分析: (a) 850 hPa纬向风; (b) 海表温度; (c) 200 hPa与850 hPa纬向风垂直切变; (d) 850 hPa涡度; (e) 200 hPa纬向风; (f) 500 hPa位势高度; (g) 700 hPa相对湿度。方框区域表示为本文选取的相关区域, 阴影区域表示相关系数的绝对值大于或等于0.3, 通过信度为95%的显著性检验

Fig. 2 Correlations between the frequency of tropical cyclones (TCs) from June to October and the large-scale environmental variables during boreal spring (March–May) in 1950–2009: (a) 850-hPa zonal wind; (b) sea surface temperature; (c) vertical shear between 200-hPa and 850-hPa zonal wind; (d) 850-hPa vorticity; (e) 200-hPa zonal wind; (f) 500-hPa geopotential height; (g) 700-hPa relative humidity. Solid boxes indicate the selected correlation regions and the shaded areas indicate the absolute values of correlation coefficients  $\geq 0.3$ , which pass the test at 95% confidence level

平均相关系数分别为-0.35和0.32，结合后相关系数值达0.47。图2f为与500 hPa位势高度的相关场，单独考察西太平洋区域( $10^{\circ}\text{S} \sim 15^{\circ}\text{N}$ ,  $125^{\circ}\text{E} \sim 165^{\circ}\text{E}$ )，平均相关系数为-0.45。在图2g的700 hPa相对湿度场中选择中太平洋相关较高的区域( $10^{\circ}\text{S} \sim 5^{\circ}\text{N}$ ,  $172.5 \sim 157.5^{\circ}\text{W}$ )，平均相关系数达0.39。第8个预报因子为Nino3.4指数，它与TC频数的相关系数为-0.31。根据相关分析，综合考察相关区域，最终选择了以上8个环境变量，作为WNP TC频数的预报因子。

### 3 模型构建

#### 3.1 多元线性回归模型 (MLR)

线性回归之前，为了使预报因子的数值处于同一个量级，首先对数据进行标准化运算，再利用多元线性回归技术： $y = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n$ ，其中， $y$ 为因变量(预报量)， $x_1, x_2, \dots, x_n$ 为自变量(预报因子)， $a_1, a_2, \dots, a_n$ 为回归系数(Nath et al., 2015)。模型中8个预报因子分别为上节所介绍的8个环境变量指数。

#### 3.2 人工神经网络模型 (ANN)

数据集分为训练集(1950~2009年)和预测集(2010~2017年)两个部分，再将预测集分为验证集(2010~2013年)和测试集(2014~2017年)两个部分(尹宜舟等, 2010)。MLR与ANN模型将根据60年(1950~2009年)训练集数据搭建模型，并用预测集(2010~2017年)检测模型的回报能力。ANN模型将预测集分出验证集与测试集的原因是ANN模型中的超参数，比如：学习率，激励函数的选择，模型的层数以及每层的神经元个数等等。这些超参数在训练过程中恒定不变，但需要根据验证集的回报结果改变超参数的设置。因此，验证集既属于预测数据，又在广义上参与了模型的部分训练过程。所以，单独分出测试集，就是为了检测模型在面对从未见过的数据时的回报表现。

数据投入模型之前使用主分量分析方法消除各预报因子之间的共线性(Acharya et al., 2012)。如图3所示，本文通过多次试验最终采用4层(运算层数)BP人工神经网络，输入层节点数为8(对应MLR模型中相应的8个预报因子)，输出层节点数为1(TC频数)，3个隐藏层节点数依次为8、5、3。

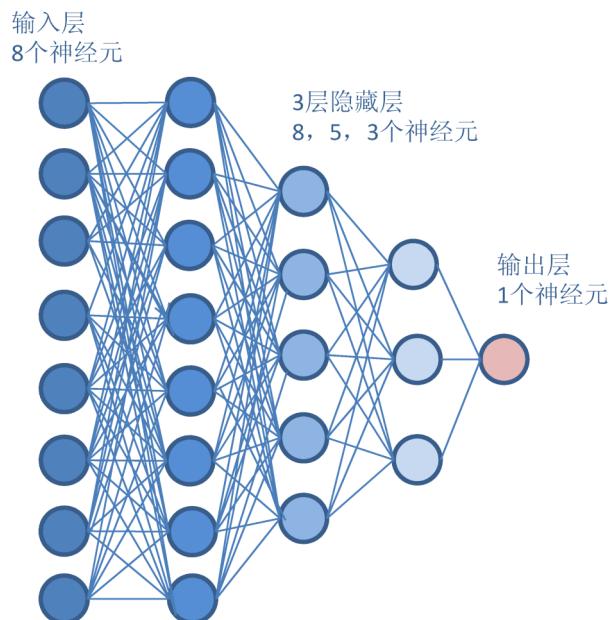


图3 四层人工神经网络结构图

Fig. 3 The structure chart of the four-layer artificial neural network model

3. 人工神经网络在实际应用中最大的困难在于模式常出现“过拟合”现象，模型对历史数据训练时准确性高，而在测试阶段准确性偏低。为了尽量减弱“过拟合”现象，本文模型采用：(1)降低权重(Dropout)方法，通过随机按比率临时删除某些节点，在训练时减少模型对一些特定节点的依赖导致的过度拟合现象。(2)正则化方法，对于有限的数据集，在损失函数项中加入正则项，模型为了达到最小化损失函数的目的，会阻止正则项变大，从而降低模式的复杂度，防止拟合过度。模型的部分设置如下：初始化设置权重值为高斯随机分布，偏置值设置为0，选择适用于样本量小且具有自适应性的Adagrad优化器，激励函数使用ReLU函数，损失函数采用均方差，降低权重的比率设置为0.95，学习率为0.001。

### 4 结果分析

分别利用均方根误差RMSE(Root Mean-Square Error)、相关系数 $R$ (Correlation Coefficient)、符合指数 $d$ (index of agreement)和平均绝对误差MAE(Mean Absolute Error)评估MLR模型和ANN模型的拟合及回报准确性。其中，符合指数 $d$ 是由Willmott(1982)提出的值位

表1 ANN模型和MLR模型对TC频数的回报评估

Table 1 Evaluation of the prediction of TC frequency by ANN and MLR models

	RMSE		R		d		MAE	
	ANN模型	MLR模型	ANN模型	MLR模型	ANN模型	MLR模型	ANN模型	MLR模型
训练集(1950~2009年)	1.10	3.77	0.99	0.72	0.99	0.87	0.77	3.02
验证集(2010~2013年)	2.70	4.11	0.90	0.71	0.82	0.57	2.26	3.78
测试集(2014~2017年)	1.83	3.59	0.84	-0.66	0.96	0.64	1.68	2.82
预测集(2010~2017年)	2.30	3.86	0.80	0.46	0.85	0.61	1.97	3.30

于0~1的无量纲指数,  $d$ 值越大代表符合程度越高。

$$d = 1 - \left[ \sum_{i=1}^N (P_i - O_i)^2 \Big/ \sum_{i=1}^N (|P_i - \bar{O}| + |O_i - \bar{O}|)^2 \right], \quad (1)$$

其中,  $P_i$ 表示第*i*次回报值,  $O_i$ 表示第*i*次观测值,  $\bar{O}$ 表示观测平均值,  $N$ 为回报次数。

#### 4.1 交叉验证结果

为分析8个预测因子建立的ANN模型和MLR模型的回报能力和模型的稳定性, 先对两种模型进行样本交叉检验(Fan and Wang, 2009)。具体做法是利用60年历史数据中59年建立回报模型, 对余下1年进行回报。由图4可知, 两种模型对TC的变化趋势都具有一定的回报能力, ANN模型的60年交叉验证与实况的RMSE值为1.13, 相关系数为0.99, 而MLR模型的RMSE值为4.42, 相关系数为0.60。从总体样本的交叉验证检验结果可以看出ANN模型在RMSE和相关系数的表现都优于MLR模型, 其回报能力与模型稳定性较高。

#### 4.2 训练集拟合结果

利用1950~2009年8个预报因子和TC频数构建MLR模型和4层ANN模型, 图5为2个模型分别对训练集样本数据的拟合曲线与观测值, 可以明显看出, 两种预报模型对历史样本的拟合趋势都与观测值保持一致, 但ANN模型对历史样本的拟合与观测的偏差更小, 精确度更高, 两条曲线几乎重合。表1给出了反映两个模型拟合情况的4个评估指数(RMSE、R、d、MAE), ANN模型对历史样本拟合的RMSE为1.1, MAE为0.77, 而MLR模型的RMSE值达3.77, MAE达3.02, ANN模型的两个误差均明显低于MLR模型; ANN模式对历史样本拟合的R值和d值均高达0.99, 拟合效果优异, 分别大幅高于MLR模式的0.72, 和0.87。可见不论从误差或是相关分析, ANN模型的拟合精度均远高于MLR模型。

#### 4.3 预测集回报结果

对比两个模型在验证集(2010~2013年)的回报结果, 如表2所示, TC频数的观测值分别为13、18、18、25; ANN模型回报值分别为15.43、18.05、15.63、20.81, RMSE值为2.7; MLR模型回报值依次为15.43、13.63、15.85、18.84, RMSE值为4.11。表1中评估指数显示, ANN模型回报的MAE值为2.26, 低于MLR模型的3.78, 两个误差结果均表明ANN模型优于MLR模型。而ANN模型的R值与d值分别为0.9和0.82, 相关性也高于MLR模型的0.71和0.57。

进一步对两个模型在测试集(2014~2017年)的回报结果进行分析, 如表3所示, 观测值分别为13、17、21、17; ANN模型回报值为16.26、

表2 ANN模型与MLR模型在验证集(2010~2013年)对TC频数的回报结果

Table 2 Evaluation of the prediction of TC frequency by ANN and MLR models during 2010~2013

	TC频数 观测值	TC频数预报值	
		ANN模型	MLR模型
2010年	13	15.43	15.43
2011年	18	18.05	13.63
2012年	18	15.63	15.85
2013年	25	20.81	18.84

表3 ANN模型与MLR模型在测试集(2014~2017年)对TC频数的回报结果

Table 3 Evaluation of the prediction of TC frequency by ANN and MLR models during 2014~2017

	TC频数 观测值	TC频数预报值	
		ANN模型	MLR模型
2014年	13	16.26	15.72
2015年	17	17.86	16.28
2016年	21	21.87	14.55
2017年	17	15.86	15.60

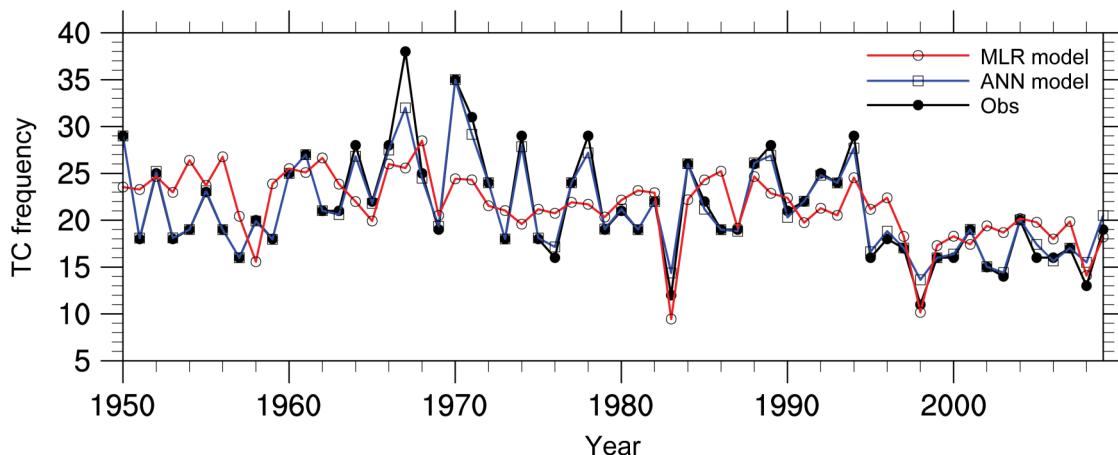


图4 ANN模型和MLR模型对TC频数的历史样本（1950~2009年）观测值的交叉验证

Fig. 4 Time series for cross-validation of the actual and simulated TC frequency using ANN (artificial neural network) model and MLR (multiple linear regression) model for the historical data (1950–2009)

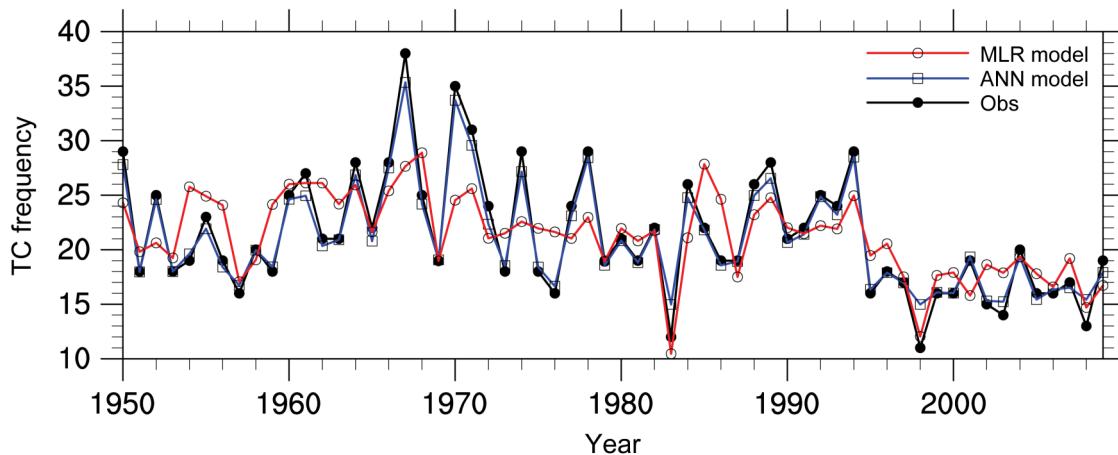


图5 ANN模型和MLR模型对TC频数的历史样本（1950~2009年）的拟合曲线与历史样本观测值

Fig. 5 Time series for actual and simulated TC frequency using ANN model and MLR model for the historical data (1950–2009)

17.86、21.87、15.86, RMSE 为 1.83; MLR 模型预报值为 15.72、16.28、14.55、15.6, RMSE 为 3.59; 结合表 1, 发现 ANN 模型在面对从未遇见的测试集数据时, 回报结果只有  $R$  值有少许降低,  $d$  值从验证集中的 0.82 升至 0.96, 大幅优于 MLR 模型, 两个误差 RMSE 和 MAE 值分别从验证集中的 2.7 和 2.26 降至 1.83 和 1.68。充分说明 ANN 模型在 TC 频数回报中的稳定性, 以及未来可能应用在业务预报中的潜力。

综合 8 年预测数据 (2010~2017 年), ANN 模型回报的  $R$ ,  $d$  值为 0.8 和 0.85, MLR 模型只达到 0.46 和 0.61; 并且 ANN 模型的两个误差值 (RMSE 和 MAE) 相较于 MLR 模型都保持 1.5 个 TC 的优势。可见, 不论是在训练集的拟合, 或是预测集的

回报, ANN 模型均表现出低误差, 高相关的特征, 充分证明了 ANN 模型相较于传统 MLR 模型在 TC 频次季节回报中的显著优势。

## 5 结果和讨论

WNP 作为全球 TC 的主要源地之一, 夏、秋季 (6~10 月) 生成的 TC 频数存在明显的年际变化。因此, 提前预测 WNP 6~10 月 TC 的生成频数, 对于相关部门防灾决策的制定至关重要。ANN 模型拥有描述非线性活动的优势, 具有改善 TC 频数预测的潜力。因此, 本文通过对 60 年 (1950~2009 年) TC 频数与北半球春季 (3~5 月) 大尺度环境变量的相关分析, 挑选出 8 个相关性较高的预报因子, 利用关键区域平均分别定义了 850 hPa 纬向

风、海表温度、200 hPa与850 hPa纬向风垂直切变、850 hPa涡度、200 hPa纬向风、500 hPa位势高度、700 hPa相对湿度和Nino 3.4指数，再对这8个因子构建结构为8-8-5-3-1的4层ANN模型和MLR模型，对2010~2017年8年WNP 6~10月生成的TC频数进行回报。采用均方根误差(RMSE)，平均绝对误差(MAE)，相关系数( $R$ )和符合指数( $d$ )这4个指数分别对两个模型进行优劣评估。模型结果对比发现，ANN模型对60年历史数据的拟合精度较高， $R$ 和 $d$ 的值都高达0.99，MAE值低至0.77，RMSE值为1.1。针对8年的预测数据，ANN模型的 $R$ 值为0.8， $d$ 值为0.85，MAE值为1.97，RMSE值为2.3；而MLR模型的 $R$ 值为0.46， $d$ 值为0.61，MAE值为3.3，RMSE值为3.86。ANN模型在对历史数据的拟合和回报中的表现都明显优于MLR模型，可以期待未来在实际业务中的应用。

制约ANN模型预报精度的因素有很多，比如：(1)模型中虽然已经采取了降低权重和正则化方法，尽量减弱模型的“过拟合”现象，但回报水平与历史数据拟合水平依然存在一定差异；(2)模型中各超参数的设定需要根据经验以及多次实验设定；(3)影响WNP TC频数的因素有很多，预报因子的选择是否有遗漏，或者存在其他更优的预报因子，这都需要未来更深入的研究。

## 参考文献 (References)

- Acharya N, Chattpadhyay S, Kulkarni M A, et al. 2012. A neurocomputing approach to predict monsoon rainfall in monthly scale using SST anomaly as a predictor [J]. *Acta Geophysica*, 60(1): 260–279. doi:10.2478/s11600-011-0044-y
- Bengio Y, Delalleau O. 2011. On the expressive power of deep architectures [M]//Kivinen J, Szepesvári C, Ukkonen E, et al. *Algorithmic Learning Theory*. Berlin: Springer-Verlag. doi:10.1007/978-3-642-24412-4\_3
- Chan J C L. 1985. Tropical cyclone activity in the Northwest Pacific in relation to the El Niño/Southern Oscillation phenomenon [J]. *Mon. Wea. Rev.*, 113(4): 599–606. doi: 10.1175 / 1520-0493(1985)113<0599:TCAITN>2.0.CO;2
- Chan J C L. 1995. Tropical cyclone activity in the western North Pacific in relation to the stratospheric Quasi-Biennial Oscillation [J]. *Mon. Wea. Rev.*, 123(8): 2567–2571. doi:10.1175 / 1520-0493(1995)123<2567:Tcaitw>2.0.Co;2
- Chan J C L. 2000. Tropical cyclone activity over the western North Pacific associated with El Niño and La Niña Events [J]. *J. Climate*, 13(16): 2960–2972. doi: 10.1175 / 1520-0442(2000)013<2960:TCAOTW>2.0.CO;2
- Chen J C L, Shi J E, Lam C M. 1998. Seasonal forecasting of tropical cyclone activity over the western North Pacific and the South China Sea [J]. *Wea. Forecasting*, 13(4): 997–1004. doi:10.1175/1520-0434(1998)013<0997:SFOTCA>2.0.CO;2
- Chen J C L, Shi J E, Liu K S. 2001. Improvements in the seasonal forecasting of tropical cyclone activity over the western North Pacific [J]. *Wea. Forecasting*, 16(4): 491–498. doi: 10.1175 / 1520-0434(2001)016<0491:IITSFO>2.0.CO;2
- 陈光华, 黄荣辉. 2006. 西北太平洋暖池热状态对热带气旋活动的影响 [J]. *热带气象学报*, 22(6): 527–532. Chen Guanghua, Huang Ronghui. 2006. The effect of warm pool thermal states on tropical cyclone in West Northwest Pacific [J]. *Journal of Tropical Meteorology* (in Chinese), 22(6): 527–532. doi:10.3969/j.issn.1004-4965.2006.06.002
- Chu P S, Zhao X. 2007. A bayesian regression approach for predicting seasonal tropical cyclone activity over the central North Pacific [J]. *J. Climate*, 20(15): 4002–4013. doi:10.1175/jcli4214.1
- Fan K. 2007. New predictors and a new prediction model for the typhoon frequency over western North Pacific [J]. *Science in China Series D: Earth Sciences*, 50(9): 1417–1423. doi: 10.1007/s11430-007-0105-x
- Fan K. 2009. Seasonal forecast model for the number of tropical cyclones to make landfall in China [J]. *Atmospheric and Oceanic Science Letters*, 2(5): 251–254. doi: 10.1080 / 16742834.2009.11446811
- Fan K, Wang H J. 2009. A new approach to forecasting typhoon frequency over the Western North Pacific [J]. *Wea. Forecasting*, 24(4): 974–986. doi:10.1175/2009WAF2222194.1
- Goh Z C A, Chan J C L. 2010. An improved statistical scheme for the prediction of tropical cyclones making landfall in South China [J]. *Wea. Forecasting*, 25(2): 587–593. doi:10.1175/2009waf2222305.1
- Gray W M. 1984a. Atlantic seasonal hurricane frequency. Part I: El Niño and 30 mb Quasi-Biennial Oscillation influences [J]. *Mon. Wea. Rev.*, 112(9): 1649–1668. doi: 10.1175 / 1520-0493(1984)112<1649:ASHFPI>2.0.CO;2
- Gray W M. 1984b. Atlantic seasonal hurricane frequency. Part II: Forecasting its variability [J]. *Mon. Wea. Rev.*, 112(9): 1669–1683. doi:10.1175/1520-0493(1984)112<1669:ASHFPI>2.0.CO;2
- 何慧, 欧艺, 李艳兰. 2009. 影响广西的热带气旋年频数的BP神经网络预测模型 [J]. *热带气象学报*, 25(4): 407–412. He Hui, Ou Yi, Li Yanlan. 2009. A BP neural network prediction model for the annual frequency of tropical cyclones affecting Guangxi [J]. *Journal of Tropical Meteorology* (in Chinese), 25(4): 407–412. doi:10.3969/j.issn.1004-4965.2009.04.004
- 何敏, 龚振淞, 徐明, 等. 2007. 高低层纬向风异常与西北太平洋热带气旋生成年频数关系的研究 [J]. *热带气象学报*, 23(3): 277–283.
- He Ming, Gong Zhensong, Xu Min, et al. 2007. Relationships between zonal wind anomalies in high and low troposphere and annual frequency of NW Pacific tropical cyclones [J]. *Journal of Tropical Meteorology* (in Chinese), 23(3): 277–283. doi:10.3969/j.

- issn.1004-4965.2007.03.010
- 黄小刚, 费建芳, 陈佩燕. 2009. 利用神经网络方法建立热带气旋强度预报模型 [J]. 应用气象学报, 20(6): 699–705. Huang Xiaogang, Fei Jianfang, Chen Peian. 2009. A neural network approach to predict tropical cyclone intensity [J]. Journal of Applied Meteorological Science (in Chinese), 20(6): 699–705. doi:10.3969/j.issn.1001-7313.2009.06.007
- Kim H M, Webster P J. 2010. Extended-range seasonal hurricane forecasts for the North Atlantic with a hybrid dynamical-statistical model [J]. Geophys. Res. Lett., 37(21): L21705. doi: 10.1029 / 2010gl044792
- Kim H S, Ho C H, Kim J H, et al. 2012. Track-pattern-based model for seasonal prediction of tropical cyclone activity in the Western North Pacific [J]. J. Climate, 25(13): 4660–4678. doi:10.1175/JCLI-D-11-00236.1
- Kwon H J, Lee W J, Won S H, et al. 2007. Statistical ensemble prediction of the tropical cyclone activity over the western North Pacific [J]. Geophys. Res. Lett., 34(24): L24805. doi: 10.1029 / 2007GL032308
- 李真真, 吴立广, 刘青元. 2016. 近20a影响我国台风活动变化趋势 [J]. 气象科学, 36(6): 752–759. Li Zhenzhen, Wu Liguan, Liu Qingyuan. 2016. Variation trend of typhoon activity influencing China during the past 20 years [J]. Journal of the Meteorological Sciences (in Chinese), 36(6): 752–759. doi:10.3969/2015jms.0089
- Nath S, Kotal S D, Kundu P K. 2015. Seasonal prediction of tropical cyclone activity over the North Indian Ocean using the neural network model [J]. Atmósfera, 28(4): 271–281. doi: 10.20937/atm.2015.28.04.06
- Nath S, Kotal S D, Kundu P K. 2016. Seasonal prediction of tropical cyclone activity over the North Indian Ocean using three artificial neural networks [J]. Meteor. Atmos. Phys., 128(6): 751–762. doi:10.1007/s00703-016-0446-0
- Nicholls N. 1979. A possible method for predicting seasonal tropical cyclone activity in the Australian region [J]. Mon. Wea. Rev., 107(9): 1221–1224. doi:10.1175/1520-0493(1979)107<1221:APMFPS>2.0.CO;2
- Nicholls N. 1985. Predictability of interannual variations of Australian seasonal tropical cyclone activity [J]. Mon. Wea. Rev., 113(7): 1144–1149. doi:10.1175/1520-0493(1985)113<1144:POIVOA>2.0.CO;2
- 苏志重, 余锦华, 孙丞虎, 等. 2010. IPRC区域气候模式对西北太平洋热带气旋潜在预测能力的初步检验 [J]. 热带气象学报, 26(2): 165–173. Su Zhizhong, Yu Jinhua, Sun Chenghu, et al. 2010. The initial evaluation of tropical cyclone potential predictability in the northwestern Pacific using the IPRC regional climate model [J]. Journal of Tropical Meteorology (in Chinese), 26(2): 165–173. doi: 10.3969/j.issn.1004-4965.2010.02.005
- 王会军, 孙建奇, 范可. 2007. 北太平洋涛动与台风和飓风频次的关系研究 [J]. 中国科学 D 辑: 地球科学, 37(7): 966–973. Wang Huijun, Sun Jianqi, Fan Ke. 2007. Relationships between the North Pacific Oscillation and the typhoon / hurricane frequencies [J]. Science in China Series D: Earth Sciences, 50(9): 1409–1416. doi:10.3969/j.issn.1674-7240.2007.07.013
- Willmott C J. 1982. Some comments on the evaluation of model performance [J]. Bull. Amer. Meteor. Soc., 63(11): 1309–1369. doi: 10.1175/1520-0477(1982)063<1309:SCOTEO>2.0.CO;2
- 尹宜舟, 罗勇, Gemmer M, 等. 2010. 基于BP神经网络技术的西北太平洋热带气旋年频数预测 [J]. 热带气象学报, 26(5): 614–619. Yin Yizhou, Luo Yong, Gemmer M, et al. 2010. Forecast method study on yearly tropical cyclone frequency in Northwest Pacific based on the BP neural network technique [J]. Journal of Tropical Meteorology (in Chinese), 26(5): 614–619. doi:10.3969/j.issn.1004-4965.2010.05.014
- Zhan R F, Wang Y Q. 2016. CFSv2-Based statistical prediction for seasonal accumulated cyclone energy (ACE) over the Western North Pacific [J]. J. Climate, 29(2): 525–541. doi:10.1175/JCLI-D-15-0059.1
- Zhan R F, Wang Y Q, Wen M. 2013. The SST gradient between the Southwestern Pacific and the Western Pacific warm pool: A new factor controlling the northwestern Pacific tropical cyclone genesis frequency [J]. J. Climate, 26(7): 2408–2415. doi: 10.1175/jcli-d-12-00798.1
- Zhan R F, Wang Y Q, Wu C C. 2011. Impact of SSTAs in the East Indian Ocean on the frequency of Northwest Pacific tropical cyclones: A regional atmospheric model study [J]. J. Climate, 24(23): 6227–6242. doi:10.1175/jcli-d-10-05014.1
- Zhan R F, Wang Y Q, Ying M. 2012. Seasonal forecasts of tropical cyclone activity over the western North Pacific: A review [J]. Tropical Cyclone Research and Review, 1(3): 307–324. doi:10.6057/2012TCRR03.07
- 张娟, 周永华, 黄宝霞, 等. 2016. 人工神经网络在台风风暴潮模拟中的解释应用 [J]. 海洋预报, 33(2): 60–65. Zhang Juan, Zhou Yonghua, Huang Baoxia, et al. 2016. Interpretation of numerical storm surge model results using the artificial neural network [J]. Marine Forecasts (in Chinese), 33(2): 60–65. doi: 10.11737/j.issn.1003-0239.2016.02.009