第45卷 第4期 气 象 科 学 Vol. 45, No.4
2025年8月 Journal of the Meteorological Sciences Aug., 2025

李洪臣,李明,王鹏皓.基于因果分析和机器学习算法的站点气温短临预报试验.气象科学,2025,45(4):535-548.
LI Hongchen, LI Ming, WANG Penghao. Experiments on short-term station temperature forecast based on causality analysis and machine learning algorithms. Journal of the Meteorological Sciences, 2025,45(4):535-548.

基于因果分析和机器学习算法的站点气温短临预报试验

李洪臣[1] 李明[2] 王鹏皓[1]

(1 国防科技大学 气象海洋学院,长沙 410073; 2 国防科技大学 前沿交叉学科学院,南京 211101)

摘要 本文构建了一种基于因果分析和机器学习的站点气温短临预报模型,以台湾省松山站为试验对象,利用欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)再分析资料、松山站实测气象资料和中国气象局陆面数据同化系统(Chinese Land Data Assimilation System-v2.0, CLDAS-v2.0)近实时产品资料,引入因果信息流理论,采用四种机器学习算法:多层前馈神经网络(Back Propagation Neural Network, BPNN)、随机森林(Random Forest, RF)、最小二乘支持向量机(Least Square Support Vector Machine, LSSVM)和贝叶斯网络(Bayesian Network, BN),开展气温短临预报试验。结论如下:(1)在选取的任一种数据资料驱动下,对于BPNN、RF、BN,基于因果分析的预报结果优于相关分析,均方根误差的平均降幅在1%~2%之间。对于LSSVM,因果分析与相关分析差别较小,验证了因果分析具备更优的关联关系挖掘能力;(2)在预报模型中增加相邻空间预报因子能够显著提高气温预报效果,改进后气温预报模型均方根误差的平均降幅在2%~8%之间;(3)在模型训练样本较少情况下,基于CLDAS-v2.0近实时产品资料的预报效果优于ECMWF再分析资料的预报效果,均方根误差的平均降幅在4%~8%之间,从侧面验证了CLDAS-v2.0近实时产品资料在中国区域质量优于国际同类产品。

关键词 气温短临预报; 机器学习; 因果分析

分类号: P732 **doi**:10.12306/2023jms.0059 **文献标识码**: A

Experiments on short-term station temperature forecast based on causality analysis and machine learning algorithms

LI Hongchen[1] LI Ming[2] WANG Penghao[1]

(1 *College of Meteorology and Oceanography, National University of Defense Technology, Changsha* 410073, *China*;
2 *Frontier Interdisciplinary College, National University of Defense Technology, Nanjing* 211101, *China*)

Abstract This paper constructed a model for short term forecasting of station temperature based on causal analysis of information flow and machine learning algorithms, taking Songshan Station in Taiwan as the test samples, using ECMWF reanalysis data, measured meteorological data of Songshan Station and CLDAS-v2.0 near-real-time product data, combined with causal analysis and correlation analysis, using four Machine Learning (ML) algorithms: BP neural network, Random Forest (RF), Least Squares Support Vector Machine (LSSVM) and Bayesian Network (BN) to carry out temperature short-term forecasting experiments. The conclusions are as follows: (1) driven by any of the data selected in this paper, for BP neural network, RF, and BN, the prediction results based on causal analysis are better

收稿日期(Received):2023-05-30;**修改稿日期**(Revised):2023-07-31

基金项目:国家自然科学基金资助项目(62073332)

通信作者(Corresponding author):李明(LI Ming).mingli152@163.com

than those of correlation analysis, and the average reduction of RMSE is between 1%-2%. For LSSVM, the difference between causal analysis and correlation analysis is small, which verifies that causal analysis has better correlation mining capabilities; (2) adding adjacent spatial prediction factors in the forecast model can improve the temperature prediction effect, and the average reduction of the RMSE of the improved temperature prediction model is between 2%-8%; (3) in the case of small samples, the forecasting effect based on CLDAS-V2.0 data is better than that of ECMWF reanalysis data, and the average reduction of RMSE is between 4%-8%, which verifies that the quality of CLDAS-V2.0 data in China is indeed better than that of similar international products.

Key words short-term temperature forecast; machine learning; causality analysis

引 言

近年来,由于人类活动和气候变化的影响,高温、严寒等极端天气频发,气象部门常规发布的气温变化区间已经远远无法满足实际需求,因此提高气温预报的准确率具有重大的现实意义。

二十世纪以来,数值天气预报已成为天气预报的重要手段。从 Klein, et al[1] 提出的完全预报法(Perfect Prognostic Method, PP)到 Glahn, et al[2] 提出的模式输出统计法(Model Output Statistics, MOS),数值天气预报的精度不断提高。随着大数据和人工智能技术的发展,机器学习(Machine Learning, ML)逐渐在众多任务中取得超越传统方法的效果,在气象预报领域呈现出巨大的应用潜力,如多层前馈神经网络(Back Propagation Neural Network, BPNN)、支持向量机(Support Vector Machine, SVM)、随机森林(Random Forest, RF)、贝叶斯网络(Bayesian Network, BN)等算法被大量应用于数值天气预报。基于人工智能的气象要素预报是典型的数据驱动建模,气温预报建模的前提是依靠大规模数据集进行模型训练,从数据中挖掘气温变化的潜在规律进行预报。因此,不同来源的数据预报效果不尽相同,目前常用的气温资料大致分为两种,即台站资料和格点资料,具体细分为地面资料、高空资料、模式资料、卫星资料、再分析资料等。

郭俊廷等[3] 基于欧洲中期天气预报中心(European Centre for Medium-Range Weather Forecasts, ECMWF)模式输出产品,利用 BPNN 预报方法,对吉林省东南部山区进行未来 24 h 日最高和最低气温的预测。黄威等[4] 基于美国国家环境预报中心(National Centers for Environmental Prediction, NCEP)和 ECMWF 的模式资料,采用 SVM 方法,建立了多模式集成的强降水预报模型。门晓磊等[5] 基于多国数值预报模式的 2 m 气温预报,应用岭回归和随机森林模型,对华北地区的 2 m 气温进行了多模式集合预报分析。赵菲菲等[6] 基于黄河流域 1979—2018 年的 ECMWF 再分析气候与水文数据和全球气候变化数据,建立黄河流域贝叶斯网络模型,预测黄河流域未来径流量。Sharma[7] 采用两种不同的 BN 结构算法,对阿萨姆邦的月平均降水量进行预测。耿丹等[8] 基于 FY-4A 卫星数据和江苏及周边地区自动气象站的能见度观测数据,利用随机森林算法构建了海雾识别模型,实现了江苏及周边地区的日间海雾识别。

前人使用诸多 ML 算法以及台站实测资料、卫星资料、各国气象预报模式资料等数据对气象要素进行了预报,对不同资料下不同 ML 算法的预报效果结论不一。针对上述问题,本文拟采用多种 ML 算法,结合不同的气象资料,探讨不同资料下 ML 算法的气温预报效果。

本文以台湾省松山站为研究对象,采用不同机器学习算法,结合因果分析和相关分析,基于站点实测资料、ECMWF 再分析资料以及中国气象局陆面数据同化系统(Chinese Land Data Assimilation System-v2.0, CLDAS-v2.0)近实时产品资料,针对性开展两个气温预报试验,具体分析了 3 个问题:(1)在不同资料与不同机器学习算法下,基于因果分析和相关分析的气温预报效果;(2)基于格点资料改进以站点实测资料驱动的气温预报模型能否显著提高气温预报效果;(3)在小样本情况下,基于 CLDAS-v2.0 和站点实测数据构建的气温预报模型的预报效果。

1 理论与方法

1.1 机器学习算法

本文选择了 4 种机器学习算法,即多层前馈神经网络、随机森林、最小二乘支持向量机(Least

Square Support Vector Machine, LSSVM)和贝叶斯网络,用于气温短临预报建模。下面本文将对 4 种机器学习算法进行具体的阐述。

1.1.1 多层前馈神经网络

误差逆传播(Error Back Propagation, BP)算法,是一种用于高效训练多层神经网络的学习算法,至今仍是应用最广泛的神经网络算法之一。BP 算法不仅可用于多层前馈神经网格,还可以用于其他类型的神经网格,例如训练递归神经网格。通常所说的 BP 神经网络,一般指用 BP 算法训练的多层前馈神经网络,它包含一个输入层、一个或多个隐含层和一个输出层,每一层可含有多个神经元,具有良好的自适应性、抗差性和联想记忆功能。

1.1.2 随机森林

随机森林是以决策树(Decision Tree, DT)作为基础学习机,利用多棵决策树进行集成,并对样本进行训练并预测的一种分类器,因此 RF 的预测值是取所有决策树的平均值预测得到的。此外,RF 能够有效地运行处理具有高维特征空间和复杂数据结构的输入样本,具有很强的鲁棒性。

1.1.3 最小二乘支持向量机

支持向量机是统计学习理论的一种实现方法,能够较好地实现风险最小化思想,传统的标准 SVM 需要求解一个二次规划问题,往往速度很慢,计算复杂度高。为了降低计算复杂性,一种支持向量机的改进算法——最小二乘支持向量机被提出。该算法将支持向量机中的不等式约束转换为等式约束,把训练过程的二次规划问题转换为线性方程组求解问题,简化了计算过程。

1.1.4 贝叶斯网络

贝叶斯网络的学习是根据某种测度寻找与样本数据集最匹配的网络,该网络需包含两个要素:结构学习和参数学习。结构学习就是结合先验知识从大量样本数据中自动构建最优的拓扑结构,在数据集完整的前提下,常用的结构算法可以分为基于统计检测方法和基于搜索评分方法两类。基于统计检测方法的核心在于选取合适的测度函数测试节点间的依赖程度,尤其是条件独立性测试,以此完成网络结构学习。基于搜索评分方法的核心在于根据评分函数在网络结构空间中引导搜索最优网络结构,虽然搜索评分方法的效率通常较低,且容易陷入局部最优,但是过程简单规范,具有很好的鲁棒性,因此当节点数量较多时大都采用搜索评分方法。在搜索评分的方法中,应用最广泛的是基于 K2 评分的爬山算法[9]和基于最小描述长度评分函数的 K3 算法[10]。K2 算法以贝叶斯度量函数为评分准则,从一个空网格开始,根据预先确定的节点顺序,依次遍历所有节点,将后验概率最大的节点作为父节点,然后逐步为每个变量添加最佳的父节点。K3 算法与 K2 流程基本相同,K3 算法在数据集较小时结果更准确,但在数据集较大时,两者结果相近。

参数学习就是明确贝叶斯网格结构后,确定各节点的条件概率表,常用的方法包括最大似然估计法(MLE)和贝叶斯方法(MAP)[11]。MLE 估计算法的核心是搜索使得似然函数最大的参数,MAP 估计算法的核心是根据先验概率,搜索使得后验概率最大的位置参数。特别地,当忽略参数的先验知识时,MAP 方法就转化为 MLE 方法。综上,本文对于贝叶斯网络的结构学习采用 K2 算法,参数学习采用 MLE 估计算法。

1.2 基于信息流的因果分析基本原理

机器学习建模中最重要的环节为特征选择,在气温预报中即预报因子的选取。将不相关的变量作为模型的输入变量,不仅会无故增加预测系统的计算量,还会降低预报的准确率[12]。在以往预报因子选择方法的研究中,最常见的是相关分析,它通过分析输出变量与预报因子之间的关联性来选择最佳的预报因子。虽然相关分析的应用较为广泛,但其对系统动力学背后的因果机制并不深入,而这在气象学和海洋学领域中是极其重要的。因果推断方法则可以克服相关分析的一些关键缺点[13]。通过因果分析可以发掘系统中的隐藏关系,是无法通过相关分析实现的。例如,Kretschmer, et al[14]通过因果推理方法发现了巴伦支—卡拉海的海冰浓度是影响冬季北极涛动的中纬度环流的重要驱动因素。McGraw, et al[15]利用格兰杰英国分析法检验了北极海冰与大气环流之间的因果关系。LI, et al[16]通过基于格兰杰因果关系检验的因果分析,筛选出影响海冰浓度的关键环境因素,开发了一种新的海冰浓度数据驱动预测技术。ZHANG, et al[17]基于信息流的因果推断,证明了太平洋—北美洲遥感模式受到南海的显著影响。Docquier, et al[18]使用因果信息流验证了近期和未来北极海冰的变化主要是由空气和海面温度以及海洋热传输驱动的。这些研究证明因果分析相较于相关性分析有更强的隐藏关系发掘能力,是一种很有前途的预报因子筛选方法。

信息流是 LIANG[19] 通过分析转移熵和格兰杰因果检验,自主提出的以一种定量方式来表征变量(或事件)之间因果关系的物理量,通过一个变量序列到另一个变量序列的信息时间速率来衡量因果关系,并且这种因果关系是单向的。两个变量之间的信息交换量不仅说明了因果关系的大小,而且指明了方向。通过信息流或信息传递来衡量变量之间的因果关系,能够实现因果分析的公式化和定量化。

考虑一个二维随机系统,信息流的原始表达式可以写成:

$$\mathrm{d}X = \boldsymbol{F}(X,t)\,\mathrm{d}t + \boldsymbol{B}(X,t)\,\mathrm{d}\boldsymbol{W} \ , \tag{1}$$

式中:$F=(F_1,F_2)^{\mathrm{T}}$ 为漂移系数向量(可微向量场),$B=(b_{ij})$ 为扩散系数矩阵,$\boldsymbol{W}$ 为标准的 Wiener 过程向量,令 $g_{ij}=\sum_k b_{ik}b_{jk}$,则变量 X_2 到 X_1 的信息流为:

$$T_{2\to1} = -E\left(\frac{1}{\rho_1}\frac{\partial F_1\rho_1}{\partial x_1}\right) + \frac{1}{2}E\left(\frac{1}{\rho_1}\frac{\partial^2 g_{11}\rho_1}{\partial {x_1}^2}\right) \ , \tag{2}$$

式中:ρ_1 是 X_1 的边缘密度函数,E 是数学期望。从形式上看,变量 X_2 到 X_1 的信息流等于 X_1 的边际熵变化率与系统排除 X_2 后的边际熵变化率之差。

此基础上表明公式(1)中[20]信息流的最大似然估计在形式上非常紧密,只涉及常见的统计量即样本协方差,那么对于变量 X_1 和 X_2 序列,信息从 X_2 流向 X_1 的速率(单位:单位时间的转移量)为:

$$T_{2\to1} = \frac{C_{11}C_{12}C_{2,d1} - C_{12}^2 C_{2,d1}}{C_{11}^2 C_{22} - C_{11}C_{12}^2} \ , \tag{3}$$

式中:C_{ij} 为 X_i 与 X_j 之间的样本协方差,$C_{i,dj}$ 是 X_i 与 X_j 之间的协方差,X_j 是 $\mathrm{d}X_j/\mathrm{d}t$ 的差分近似,采用欧拉前向格式:$X_j(n)=[X_j(n+k)-X_j(n)]/k\Delta t$,这里的 k 通常为 1,但是对于高度混乱和密集采样的序列,应选择 $k=2$,避免出现虚大的 X_j。反方向的信息流,可以通过交换下标 1 和 2 的位置得到。

为了能够进行因果关系的强弱比较,将信息流公式进行规范化[20]:

$$Z_{2\to1} \equiv |T_{2\to1}| + \left|\frac{\mathrm{d}H_1^*}{\mathrm{d}t}\right| + \left|\frac{dH_1^{\mathrm{noise}}}{\mathrm{d}t}\right|$$

$$\frac{\mathrm{d}H_1^*}{\mathrm{d}t} = E\left(\frac{\partial F_1}{\partial x_1}\right)$$

$$\frac{\mathrm{d}H_1^{\mathrm{noise}}}{\mathrm{d}t} = -\frac{1}{2}E\left(g_{11}\frac{\partial^2 \log\rho_1}{\partial {x_1}^2}\right) - \frac{1}{2}E\left(\frac{1}{\rho_1}\frac{\partial^2 g_{11}\rho_1}{\partial^2 x_1^2}\right) \ , \tag{4}$$

式中:H_1^* 表示沿 X_1 方向的相空间展开,H_1^{noise} 表示随机效应。将 Z 进行归一化,便得到标准化信息流公式:

$$\tau_{2\to1} = \frac{T_{2\to1}}{Z_{2\to1}} \ 。 \tag{5}$$

通过公式(5)计算的标准化信息流 $\tau_{2\to1}$ 可以为 0 或非 0。如果 $\tau_{2\to1}=0$,表明 X_2 不会导致 X_1 发生,即两者之间无因果关系;如果 $\tau_{2\to1}\neq0$,则表明两者之间存在因果关系。此时,可以根据符号细分为两种情况:$\tau_{2\to1}>0$,表示 X_2 导致 X_1 趋向不确定,即 X_2 是 X_1 的原因;$\tau_{2\to1}<0$,表示 X_2 导致 X_1 趋向稳定,即 X_2 不能作为 X_1 的原因。特别地,在显著性水平为 $\alpha=0.1$ 的情况下,$\tau_{2\to1}>1\%$ 可判断因果关系是显著的。

经过上述分析可以看出,信息流能够较优地计算两者之间的因果关系,非常适用于贝叶斯网络的结构学习。信息流的大小可以判断贝叶斯网络各节点之间的依赖关系强弱,即结构弧的存在问题;信息流的正负表征结构弧的方向,基于信息流能够实现网络结构的整体化学习。

2 预报模型的建立

本节将详细阐述基于因果信息流和 ML 算法的数据驱动预测模型,模型技术流程如图 1 所示,具体分为 3 个方面:因子选择、模型建立和模型预测及效果检验。

(1)因子选择:首先对数据进行质量控制和归一化处理,将数据分为训练集和测试集。然后,基于信息流的因果检验,对气象环境要素进行因果分析,筛选出气温的最佳预报因子。

(2)模型建立:将最佳预报因子作为输入变量,气温作为输出变量。根据所选取的气象要素资料,考虑三种不同情况:只用站点数据进行预报、利用站点数据和 ECMWF 提供的相邻空间格点的再分析数据进行预报、利用站点数据和 CLDAS-v2.0 提供的相邻空间格点的数值预报数据进行预报。每种情况下分别采用 BPNN、RF、LSSVM 和 BN 算法建立气温的预测模型。根据算法的特点设置初始参数,在训练集数据的基础上,完成预测模型的训练。

(3)模型预测及效果检验:利用训练完成的预测模型对测试集进行测试,得到气温的预报结果。通过误差分析分别比较不同资料下,不同 ML 算法的预测能力,并详细讨论了不同资料和不同 ML 算法在气温预测中的适用性。

3　气温短临预报分析

以台湾省松山机场站为例，基于站点实测资料、ECMWF 再分析资料以及中国气象局陆面数据同化系统（CLDAS-v2.0）近实时产品资料，利用上节所提出的方法进行气温预报试验。

3.1　数据来源

本文选取松山站点 2012—2021 年共 10 a 的逐小时气象要素实测数据，包含温度、露点温度、气压、风速、降水 5 个要素。站点相邻空间的格点数据来自 ECMWF 再分析资料和 CLDAS-v2.0 近实时产品数据集。其中，ECMWF 再分析资料包含 2 m 温度、10 m U/V 风速、1 h 总降水量和地面气压 5 个要素，本文所选取的时间范围为 2012 年 1 月 1 日—2021 年 12 月 31 日，时间分辨率为 1 h，空间范围为（20°～26°N，119°～126°E），空间分辨率为 0.1°×0.1°；CLDAS-v2.0 近实时产品数据集集成了地面观测数据、ECMWF 数值分析/预报产品、GFS 数值分析/预报产品、卫星降水产品、风云 2 号卫星全圆盘标称图，有较高的时空分辨率，在中国区域质量优于国际同类产品。由于该数据起始范围有限、获取难度较大，且本文选取的是逐小时数据，1 a 的样本可以基本反映气温变化规律，因此本文仅选取 2021 年 1 月 1 日—12 月 31 日时间范围内的相关数据，时间分辨率为 1 h，空间范围为（20°～26°N，119°～126°E），空间分辨率为 0.062 5°×0.062 5°。

3.2　误差分析

为了更好地评估不同 ML 算法的预报效果，本文采用 4 个指标来评估 ML 算法的预报精度，具体指标如下：

平均绝对误差（Mean Absolute Error, MAE）：

$$MAE = \frac{1}{N}\sum_{i=1}^{N} |\hat{y}_i - y_i| \text{ ,} \tag{6}$$

均方误差（Mean Square Error, MSE）：

$$MSE = \frac{1}{N}\sum_{i=1}^{N} (\hat{y}_i - y_i)^2 \text{ ,} \tag{7}$$

均方根误差（Root Mean Square Error, RMSE）：

$$RMSE = \left[\frac{1}{N}\sum_{i=1}^{N} (\hat{y}_i - y_i)^2\right]^{\frac{1}{2}} \text{ ,} \tag{8}$$

拟合度（R^2）：

$$R^2 = 1 - \frac{\sum_{i=1}^{N}(\hat{y}_i - y_i)^2}{\sum_{i=1}^{N}(\bar{y}_i - y_i)^2} \text{ 。} \tag{9}$$

其中：$\hat{y}_i$ 为气温的预测数据；y_i 为真实气温值（测试集的输出变量）；$\bar{y}_i$ 为真实气温的均值；N 代表样本总量。

3.3　预报试验设计

为了评估基于因果分析和相关分析的预报效果、结合相邻空间格点数据的改进气温预报效果以及小样本情况下国产数据的预报效果。本文设计

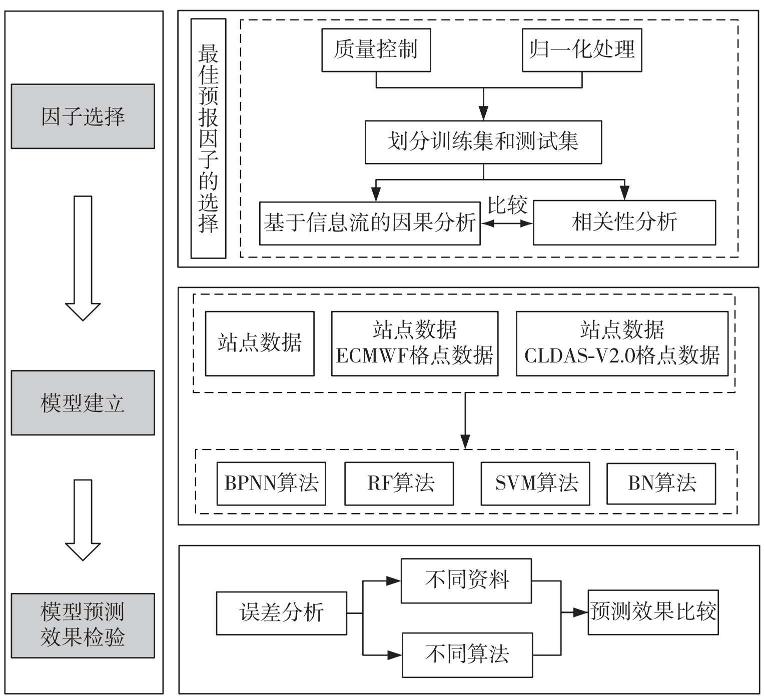

图 1　气温短临预报方法流程

Fig. 1　Flow chart of the short-range forecast method

了两个试验:(1)基于站点实测资料和 ECMWF 再分析资料,通过因果分析与相关分析,使用 4 种 ML 算法进行气温 1、3、6 h 预报;(2)基于站点数据和 CLDAS-v2.0 近实时产品资料,结合因果分析与相关分析,使用 4 种 ML 算法进行气温 1、3、6 h 预报。

表 1 4 种 ML 算法的参数设置

Table 1 Parameter settings for the four ML algorithms

ML 算法	参数设置
BPNN	相关分析和因果分析的输入层节点数分别为 15 和 16。两个试验的隐含层节点数量由经验公式 $k=\sqrt{m+n}-1+a$ 确定,其中 k 为隐含层节点数量,m 和 n 分别为输入层和输出层节点数量,a 一般取为 1~10 之间的整数。3 个试验输出层的节点数量都是 1。
RF	决策树的数量为 100,最小叶子树为 5。
LSSVM	采用径向基核函数。试验一:gam = 10, sig2 = 15;试验二:gam = 10, sig2 = 150。
BN	结构学习:K2 算法;参数学习:MLE 估计算法。

3.3.1 试验一:基于站点数据和 ECMWF 再分析数据的气温短临预报

传统的站点气温短临预报方法大致有两种:一是使用站点实测数据预测未来几个小时内的气温,即站点气温自预报;二是使用动力模式历史资料对站点气温进行预报,即将格点数据插值到站点,以此进行未来几小时内的站点气温预报。试验一在传统站点气温自预报方法的基础上,考虑邻近空间内的气象环境要素对站点气温的影响(相邻空间内的预报因子由 ECMWF 再分析资料提供),建立了以站点实测资料和数值模式资料为基础驱动的气温短临预报模型。试验一目的:(1)基于因果分析的预报效果与基于相关分析的预报效果的比较;(2)基于站点实测数据和 ECMWF 再分析资料,评估 4 种 ML 算法的预测效果;(3)验证预报模型中增加相邻空间预报因子能否提高模型的预报效果。

基于站点实测数据和 ECMWF 再分析数据,本文将站点所在位置的气压 P、风速 W、相对湿度 H、降水 TP 和站点周围格点的温度($T1$、$T2$、$T3$、$T4$)、气压($P1$、$P2$、$P3$、$P4$)、风速($W1$、$W2$、$W3$、$W4$)、降水($TP1$、$TP2$、$TP3$、$TP4$)这 20 个变量作为初始预报因子,分别进行相关分析和因果分析。表 2、3 分别显示了预测因子与气温之间的因果分析与相关分析结果。相关分析表明站点气压、相对湿度和其周围格点的气温、气压、风速共 14 个环境要素为最佳预报因子。因果分析表明站点气压和周围格点的气温、气压、风速与气温之间具有显著的因果关系,站点风速和相对湿度是引起气温变化的单向原因($W\to T$,$H\to T$),因此站点气压、风速、相对湿度和周围格点的气温、气压、风速共 15 个环境要素为经过因果分析确定的最佳预报因子,可以解释气温未来的变化。

表 2 气温与各预报因子之间的标准化信息流

Table 2 Standardised information flow between temperature and each forecast factor

变量	P	W	H	TP
$T\to$	0.440 616	0.001 45	0.000 68	4.32×10^{-5}
$\to T$	0.135 17	0.020 34	0.272 97	0.001 85
	$T1$	$P1$	$W1$	$TP1$
$T\to$	0.438 059	0.443 658	0.066 432	9.1×10^{-5}
$\to T$	0.452 104	0.145 524	0.107 85	0.001 46
	$T2$	$P2$	$W2$	$TP2$
$T\to$	0.445 844	0.444 294	0.052 896	0.000 288
$\to T$	0.443 303	0.152 296	0.096 868	0.000 524
	$T3$	$P3$	$W3$	$TP3$
$T\to$	0.442 609	0.435 746	0.066 577	−0.000 25
$\to T$	0.448 898	0.121 474	0.129 368	−0.001 4
	$T4$	$P4$	$W4$	$TP4$
$T\to$	0.432 078	0.439 068	0.069 316	0.001 139
$\to T$	0.452 407	0.129 838	0.136 852	−0.003 12

表 3 气温与各预报因子之间的相关系数

Table 3 Correlation coefficients between temperature and each forecast factor

变量	P	W	H	TP
T	−0.760 34	−0.030 05	−0.358 13	−0.033 82
	T1	P1	W1	TP1
T	0.971 829	−0.772 07	−0.356 5	−0.024 57
	T2	P2	W2	TP2
T	0.970 729	−0.783 11	−0.307 37	0.009 21
	T3	P3	W3	TP3
T	0.971 554	−0.744 66	−0.389 09	−0.027 65
	T4	P4	W4	TP4
T	0.970 152	−0.750 9	−0.420 12	−0.064 21

图 2 展示了预测模型的输入。其中图 2a、b 为引入邻近空间预报因子,以因果分析和相关分析选择的预报因子作为输入变量,分别采用 4 种 ML 算

法建立的预测模型。图 2c 为未引入邻近空间预报因子，以因果分析选择的预报因子（P、W、H）作为输入变量，使用相同的 4 种 ML 算法建立的预测模型，以此衡量引入邻近空间预报因子的模型改善程度。Deser，et al[21] 指出输出变量的历史信息有助于解释输出变量的未来变化。因此，过去的站点温度 T 也被作为预报因子输入模型。

将相关分析和因果分析筛选出来的预报因子作为模型的输入变量，2012—2018 年的站点实测数据和 ECMWF 再分析数据作为训练集，2019—2021 年对应的数据作为测试集，开展气温 1、3、6 h 预报。

由表 4 可以看出，BPNN 的预报效果较差，当预报时效为 6 h 时，R^2 的数值大于 1，使模型预测效果的可信度大大降低。在预报模型中加入相邻空间的预报因子，在原有预报因子的基础上多引入了 12 个变量，致使数据样本过大、预报因子过多。由于 BPNN 自身的稳定性较差，因此在进行气温短临预报时很难保证一定的预报精度。结合表 4，仍能得到一定的结论：（1）对于 BPNN，基于因果分析的预报效果优于相关分析；（2）当数据样本较大、预报因子较多时，BPNN 的预报效果较差。因此试验一的下文重点讨论 RF、LSSVM 和 BN 的预报效果。

表 4 第 6 列展示的是基于因果分析对比相关分析的评估参数改善效果。在 1~6 h 的预报时效内，对于 RF，基于因果分析的预报效果优于相关分析，且随着预报时效的增加，基于因果分析的优势越明显。均方根误差的平均降幅为 2.31%；对于 LSSVM，基于相关分析的预报效果优于因果分析；对于 BN，基于因果分析的预报效果优于相关分析，均方根误差的平均降幅为 1.73%。

表 4 第 8 列展示的是增加相邻空间预报因子的评估参数改善效果。在 1~6 h 的预报时效内，对于 RF，改善效果最明显，均方根误差的平均降幅为 7.73%；对于 LSSVM，均方根误差的平均降幅为 6.54%；对于 BN，均方根误差的平均降幅为 2.48%。由此可得，增加相邻空间预报因子能够提升气温短临预报的准确度。

为直观比较不同 ML 算法下的气温短临预报效果，试验一随机选取 50 个样本点，画出 RF、LSSVM 和 BN 预报的气温 1、3、6 h 预报曲线与对应的站点气温散点（图 3）和不同预报时效与不同 ML 算法下的评估参数柱状图（图 4）。

图 3 中蓝色圆圈为真实温度散点，黑色、红色、绿色分别为采用 BN 算法、RF 算法和 LSSVM 算法预报的气温折线。由图 3 可知，随着预报时效的增加，预报的误差也随之增大，不同 ML 算法间的差异逐渐显现出来。预测气温样本与真实气温样本之间也出现了相位偏差，且预报时效越长，样本间的相位偏差越大。

图 4 中从左到右的柱体分别代表预报时效为 1、3 和 6 h 的评估指标值。可知，3 种 ML 算法的预报精度：RF>LSSVM>BN。

综上，基于站点实测数据和 ECMWF 再分析数据，结论如下：

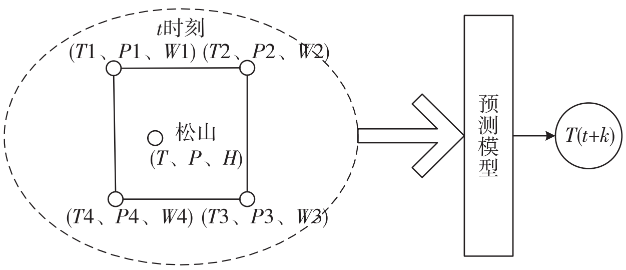

(a) 引入邻近空间预报因子，采用因果分析建立的ML模型预测机制

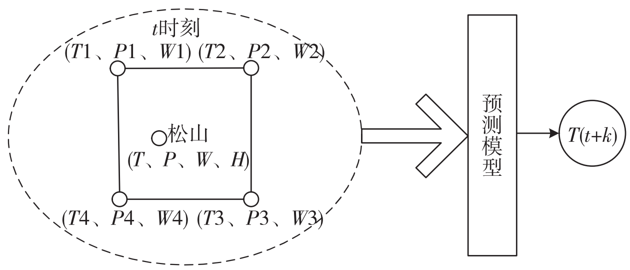

(b) 引入邻近空间预报因子，采用相关分析建立的ML模型预测机制

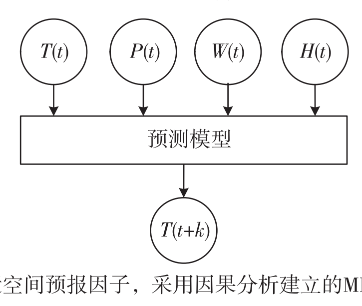

(c) 未引入邻近空间预报因子，采用因果分析建立的ML模型预测机制

图 2　ML 模型预测机制
Fig. 2　ML model predictive mechanisms

表 4 试验一,4 种 ML 算法下的评估指标值及改善程度

Table 4 Experiment 1, values of assessment metrics and degree of improvement under four ML algorithms

评估指标	预报时效/h	ML 算法	站点+ECMWF			站点	改善程度/%
			相关分析	因果分析	改善程度/%	因果分析	
RMSE	1	BPNN	3.077 7	2.648 1		1.013 1	
		RF	0.971 9	0.951 05	+2.20	0.980 5	+3.10
		LSSVM	1.019 8	1.026 9	−0.69	1.130 2	+10.06
		BN	1.570 6	1.551 1	+1.26	1.574 8	+1.53
	3	BPNN	5.770 7	5.178 3		2.007 4	
		RF	1.924 6	1.880 4	+2.35	2.002 6	+6.50
		LSSVM	2.030 9	2.059 2	−1.37	2.127 7	+3.33
		BN	2.371 0	2.322 9	+2.07	2.394 1	+3.07
	6	BPNN	12.368 5	9.908 9		2.829 8	
		RF	2.584 2	2.524 4	+2.37	2.867 8	+13.60
		LSSVM	2.767 5	2.784 6	−0.61	2.958 3	+6.24
		BN	2.840 6	2.788 6	+1.86	2.867 9	+2.84
MSE	1	BPNN	9.472 3	7.0126		1.026 3	
		RF	0.944 7	0.904 3	+4.47	0.961 5	+6.33
		LSSVM	1.039 9	1.054 4	−1.38	1.277 3	+21.14
		BN	2.466 6	2.405 9	+2.52	2.479 9	+3.08
	3	BPNN	33.300 5	26.815		4.029 8	
		RF	3.704 1	3.535 9	+4.76	4.010 6	+13.43
		LSSVM	4.124 7	4.240 1	−2.72	4.527 2	+6.77
		BN	5.621 4	5.396 0	+4.18	5.731 6	+6.22
	6	BPNN	152.979 6	98.186 3		8.008 0	
		RF	6.6783	6.372 8	+4.79	8.224 0	+29.05
		LSSVM	7.659 2	7.754 1	−1.22	8.751 5	+12.86
		BN	8.068 9	7.776 3	+3.76	8.224 9	+5.77
MAE	1	BPNN	2.002 5	1.884 0		0.706 0	
		RF	0.678 5	0.664 1	+2.17	0.675 8	+1.76
		LSSVM	0.740 3	0.763 9	−3.09	0.783 4	+2.55
		BN	1.098 9	1.087 6	+1.04	1.099 2	+1.07
	3	BPNN	4.304 0	3.751 4		1.485 3	
		RF	1.429 8	1.393 8	+2.58	1.483 9	+6.46
		LSSVM	1.596 8	1.645 5	−2.96	1.576 3	−4.21
		BN	1.749 7	1.713 2	+2.13	1.769 0	+3.26
	6	BPNN	8.972 5	7.485 0		2.152 8	
		RF	1.939 0	1.885 1	+2.86	2.170 6	+15.15
		LSSVM	2.284 6	2.306 6	−0.95	2.248 9	−2.50
		BN	2.156 5	2.106 4	+2.38	2.170 7	+3.05

续表

评估指标	预报时效/h	ML 算法	站点+ECMWF 相关分析	站点+ECMWF 因果分析	站点+ECMWF 改善程度/%	站点因果分析	改善程度/%
R^2	1	BPNN	0. 721 8	0. 7940		0. 969 9	
		RF	0. 972 3	0. 973 4	+0. 11	0. 971 8	+0. 16
		LSSVM	0. 969 5	0. 969 0	−0. 05	0. 962 5	+0. 67
		BN	0. 927 5	0. 929 3	+0. 19	0. 927 2	+0. 23
	3	BPNN	0. 021 8	0. 212 3		0. 881 6	
		RF	0. 891 2	0. 896 1	+0. 55	0. 882 2	+1. 55
		LSSVM	0. 878 8	0. 875 4	−0. 39	0. 867 0	+0. 96
		BN	0. 834 9	0. 841 5	+0. 78	0. 822 8	+2. 22
	6	BPNN	−3. 493 9	−1. 884 3		0. 764 8	
		RF	0. 803 8	0. 812 8	+1. 11	0. 758 4	+6. 69
		LSSVM	0. 775 0	0. 772 2	−0. 36	0. 742 9	+3. 79
		BN	0. 763 0	0. 771 6	+1. 11	0. 747 4	+3. 14

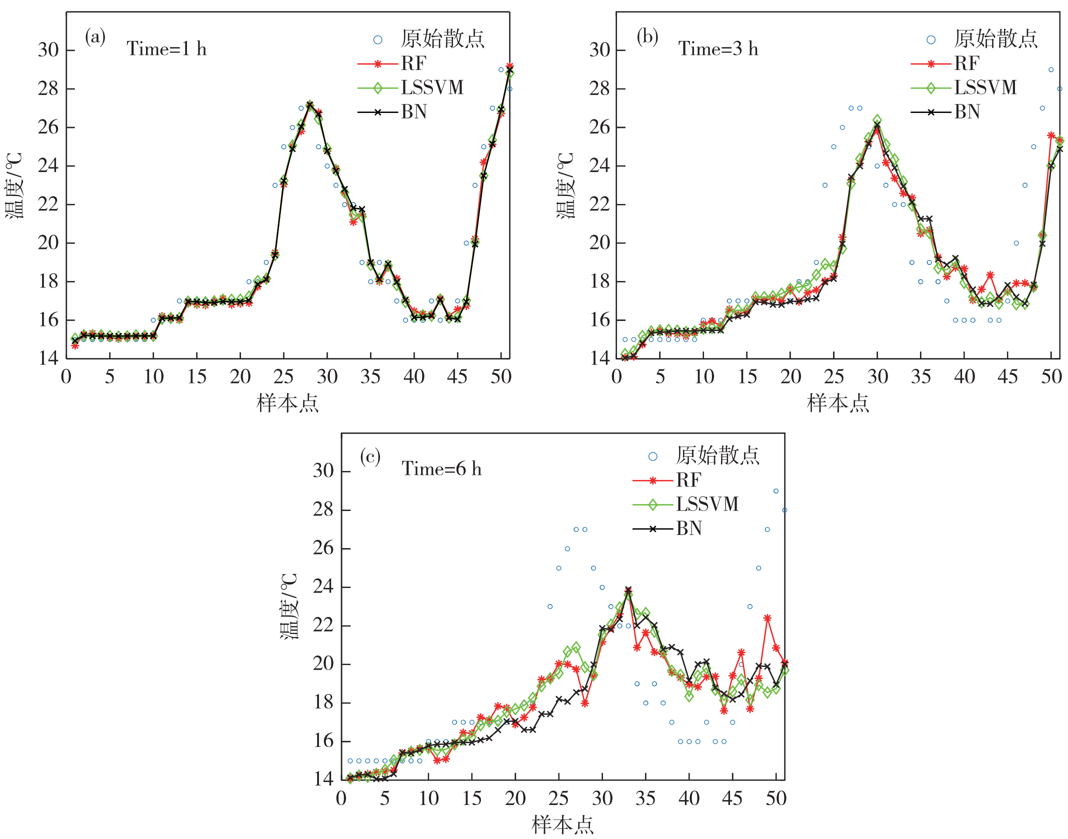

图 3　3 种 ML 算法预报的温度与真实温度对比:(a)1 h; (b)3 h; (c)6 h
Fig. 3　Comparison of the temperature forecast by the three ML algorithms with the real temperature: (a)1 h; (b)3 h; (c)6 h

(1)对于 LSSVM,基于相关分析的预报效果优于因果分析;对于 BPNN、RF 和 BN,基于因果分析的预报效果优于相关分析,后两种算法均方根误差的平均降幅分别为 2. 31%和 1. 73%。

(2)当数据样本较大、预报因子较多时,BPNN 的预报效果较差。基于站点实测数据和 ECMWF 再分析数据,4 种 ML 算法的预报精度:RF>LSSVM>BN>BPNN。

(3)纳入格点数据改进的以站点实测数据驱动的气温预报模型能够提高气温预报效果，即在预报模型中增加相邻空间预报因子能够提高气温预报效果。对于 RF、LSSVM 和 BN 算法，均方根误差的平均降幅分别为 7.73%、6.54%和 2.48%。

3.3.2 试验二：基于站点数据和 CLDAS-v2.0 近实时产品数据集的气温短临预报

试验一在传统站点气温自预报方法的基础上，采用 ECMWF 再分析资料，验证了在预报模型中加入邻近空间的预报因子能够提高气温预报效果。试验二为了验证不同资料下气温预报模型的预报效果，在试验一的基础上，采用不同的格点资料，即 CLDAS-v2.0 近实时产品资料建立气温预报模型进行气温短临预报实验。试验二目的如下：一是基于因果分析和相关分析预报效果的比较；二是基于站点数据和 CLDAS-v2.0 近实时产品资料，评估 4 种 ML 算法的预测效果；三是比较 ECMWF 再分析资料和 CLDAS-v2.0 近实时产品资料的气温短临预报效果。

试验二选取了 2021 年 1 月 1 日—12 月 31 日的 ECMWF 格点资料和 CLDAS-v2.0 格点资料。与试验一类似，经过相关分析和因果分析后，得到了与试验一相同的最佳预报因子，具体的预报因子参考试验一。

表 5 第 8 列展示的是使用国产 CLDAS-v2.0 格点数据对比 ECMWF 格点数据的评估参数改善效果。对于 BPNN、LSSVM 和 BN，使用 CLDAS-v2.0 格点数据的预报效果优于 ECMWF 格点数据，均方根误差的平均降幅分别为 8.35%、4.29%和 4.05%；对于 RF，当预报时效为 1 h 时，两种数据的预报效果相当。当预报时效为 3 h 时，使用 CLDAS-v2.0 格点数据的预报效果要优于 ECMWF 格点数据。当预报时效为 6 h 时，使用 ECMWF 格点数据的预报效果更好。因此，对于 RF，两种资料的预报效果难以判断。

表 5 第 6 列展示的是基于因果分析对比相关分析的评估参数改善效果。在 1~6 h 的预报时效内，对于 BPNN、RF 和 BN，基于因果分析的预报效果优于相关分析。均方根误差的平均降幅分别为 0.84%、1.56%和 1.11%；对于 LSSVM，基于因果分析和基于相关分析的预报效果相当，二者均方根误差的差异不超过 0.5%。

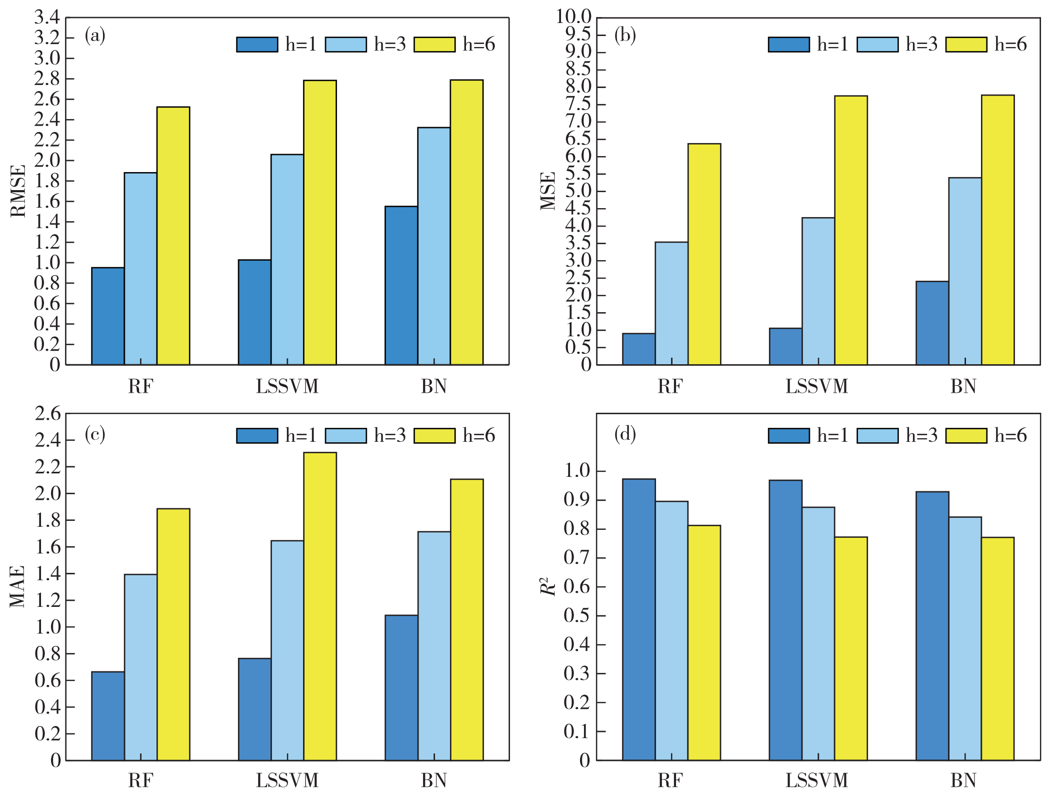

图 4 3 种算法的评估指数对比：(a)RMSE；(b)MSE；(c)MAE；(D)R^2

Fig. 4 Comparison chart of assessment indices for the three algorithms: (a)RMSE; (b)MSE; (c)MAE; (D)R^2

表 5　试验二，4 种 ML 算法下的评估指标值及改善程度

Table 5　Experiment 2, values of assessment metrics and degree of improvement under four ML algorithms

评估指标	预报时效/h	ML 算法	CLDAS-v2.0			站点	改善程度/%
			相关分析	因果分析	改善程度/%	因果分析	
RMSE	1	BPNN	0.837 5	0.836 0	+0.18	0.891 8	+6.67
		RF	0.890 8	0.882 5	+0.94	0.882 3	−0.02
		LSSVM	0.841 5	0.840 9	+0.07	0.882 6	+4.96
		BN	0.851 5	0.849 4	+0.25	0.887 5	+4.49
	3	BPNN	1.586 6	1.567 6	+1.21	1.751 5	+11.73
		RF	1.680 8	1.662 0	+1.13	1.681 5	+1.17
		LSSVM	1.549 4	1.543 3	+0.40	1.669 8	+8.20
		BN	1.069 7	1.023 1	+4.55	1.055 9	+3.21
	6	BPNN	2.329 5	2.303 2	+1.14	2.456 7	+6.66
		RF	2.371 8	2.3117	+2.60	2.203 9	−4.66
		LSSVM	2.247 6	2.257 0	−0.42	2.250 9	−0.27
		BN	1.600 7	1.624 4	−1.46	1.696 9	+4.46
MSE	1	BPNN	0.701 5	0.699 0	+0.36	0.795 2	+1.38
		RF	0.793 6	0.778 8	+1.90	0.778 5	−0.04
		LSSVM	0.708 2	0.707 2	+0.14	0.778 9	+10.14
		BN	0.725 1	0.721 6	+0.49	0.787 6	+9.15
	3	BPNN	2.517 4	2.457 3	+2.45	3.067 8	+24.84
		RF	2.825 2	2.762 3	+2.28	2.824 7	+2.26
		LSSVM	2.400 6	2.381 8	+0.79	2.788 3	+17.07
		BN	1.144 3	1.046 6	+9.33	1.114 8	+6.52
	6	BPNN	5.426 4	5.304 6	+2.30	6.035 5	+13.78
		RF	5.625 4	5.343 7	+5.27	4.857 0	−9.11
		LSSVM	5.051 5	5.093 9	−0.83	5.066 6	−0.54
		BN	2.562 3	2.638 5	−2.89	2.879 5	+9.13
MAE	1	BPNN	0.631 5	0.625 8	+0.91	0.658 5	+5.23
		RF	0.659 2	0.648 9	+1.59	0.649 7	+0.12
		LSSVM	0.627 2	0.624 2	+0.48	0.649 9	+4.12
		BN	0.619 2	0.6150	+0.68	0.646 1	+5.06
	3	BPNN	1.168 2	1.163 5	+0.40	1.324 5	+13.84
		RF	1.237 6	1.221 8	+1.29	1.268 2	+3.80
		LSSVM	1.155 2	1.146 9	+0.72	1.267 0	+10.47
		BN	0.829 1	0.786 1	+5.47	0.817 6	+4.01
	6	BPNN	1.760 6	1.750 8	+0.56	1.857 4	+6.09
		RF	1.778 8	1.729 6	+2.84	1.668 0	−3.56
		LSSVM	1.746 4	1.742 3	+0.24	1.741 4	−0.05
		BN	1.212 5	1.238 5	−2.10	1.291 6	+4.29
R^2	1	BPNN	0.944 8	0.9450	+0.02	0.937 5	+0.79
		RF	0.937 6	0.938 8	+0.13	0.938 8	+0.00

续表

评估指标	预报时效/h	ML 算法	CLDAS-v2.0			站点	改善程度/%
			相关分析	因果分析	改善程度/%	因果分析	
		LSSVM	0.944 3	0.944 4	+0.01	0.938 7	+0.60
		BN	0.942 9	0.943 2	+0.03	0.983 0	+0.55
	3	BPNN	0.801 6	0.806 4	+0.60	0.758 3	+5.96
		RF	0.777 4	0.782 3	+0.63	0.777 2	+0.65
		LSSVM	0.810 8	0.812 3	+0.18	0.780 3	+3.94
		BN	0.909 8	0.917 5	+0.84	0.912 1	+0.59
	6	BPNN	0.572 2	0.581 8	+1.65	0.524 2	+9.90
		RF	0.556 6	0.578 8	+3.84	0.6171	−6.62
		LSSVM	0.601 8	0.598 5	−0.55	0.600 6	−0.35
		BN	0.797 6	0.791 6	−0.76	0.772 6	+2.40

图 5 展示了 4 种 ML 算法模拟的预报气温折线与真实温度散点对比的一段 50 个样本点长度的图像,其中蓝色圆圈为真实温度散点,洋红色、黑色、红色、绿色折线分别为采用 BP 算法、BN 算法、RF 算法、LSSVM 算法预测的气温折线。由图 5 可知,BN 的精度最高,数据点的波动最小。随着预报时效的增加,预报的误差也随之增大,不同 ML 算法间的差异越来越明显。同时预报气温样本与真实气温样本之间也会出现相位偏差,预报时效越长,样本间的相位偏差越大。

图 6 中从左到右的柱体分别代表预报时效为 1、3 和 6 h 的评估指标值。由图 6 和表 5 可得,随着预报时效的增加,预报的精度逐渐降低。4 种 ML 算法的预报精度:BN>LSSVM>BPNN>RF,后 3 种算法之间的差距不明显。

综上,基于站点实测资料和 CLDAS-v2.0 资料,结论如下:

(1)对于 BPNN、RF 和 BN,基于因果分析的预报效果优于相关分析,均方根误差的平均降幅分别为 0.84%、1.56%和 1.11%;对于 LSSVM,基于因果分析的预报效果略好,但两者之间的差距不大,均方根误差的差异不超过 0.5%。

(2)基于站点实测资料和 CLDAS-v2.0 资料,4 种 ML 算法的预报精度:BN>LSSSVM>BPNN>RF,后 3 种算法之间的差距不明显。

(3)对于 BPNN、LSSVM 和 BN,使用 CLDAS-v2.0 格点数据的预报效果优于 ECMWF 格点数据,均方根误差的平均降幅分别为 8.35%、4.29% 和 4.05%;对于 RF,无法有效界定两种数据的预测效果。综合比较,由于 CLDAS-v2.0 格点数据的空间分辨率更高,预报效果优于 ECMWF 格点数据。

4 结论

本文以松山站为研究对象,基于站点实测资料、ECMWF 再分析资料和 CLDAS-v2.0 近实时产品资料,结合因果分析和相关性分析,采用 4 种机器学习算法:多层前馈神经网络、随机森林、最小二乘支持向量机和贝叶斯网络,针对性开展了两个气温短临预报试验。具体分析探讨了 3 个问题:(1)在不同资料与不同机器学习算法下,基于因果分析和相关分析的气温预报效果;(2)增加相邻空间格点资料,改进以站点实测资料驱动的气温预报模型能否提高气温预报效果;(3)在小样本情况下,比较 CLDAS-v2.0 近实时资料和 ECMWF 再分析资料的气温预报效果。主要结论如下:

(1)在本文选取的任一种数据资料驱动下,对于 BPNN、RF、BN,基于因果分析的预报效果优于相关分析,均方根误差的平均降幅在 1%~2%之间;对于 LSSVM,基于相关分析的预测效果略优于因果分析,验证了因果分析具备更优的关联关系挖掘能力。

(2)根据两个试验,可以得到 4 种 ML 算法的预报效果:当预报样本较小时,BN>LSSVM>RF>BPNN,后 3 种 ML 算法间的差异不明显;当预报样本较大且预报因子较多时,BPNN 预报效果较差,其余 3 种 ML 算法的预报效果:RF>LSSVM>BN。

(3)在预报模型中增加相邻空间预报因子能够提高气温预报效果。对于不同 ML 算法,改进后气温预报模型均方根误差的平均降幅在 2%~8%之间。

(4)在模型训练样本较少的情况下,基于

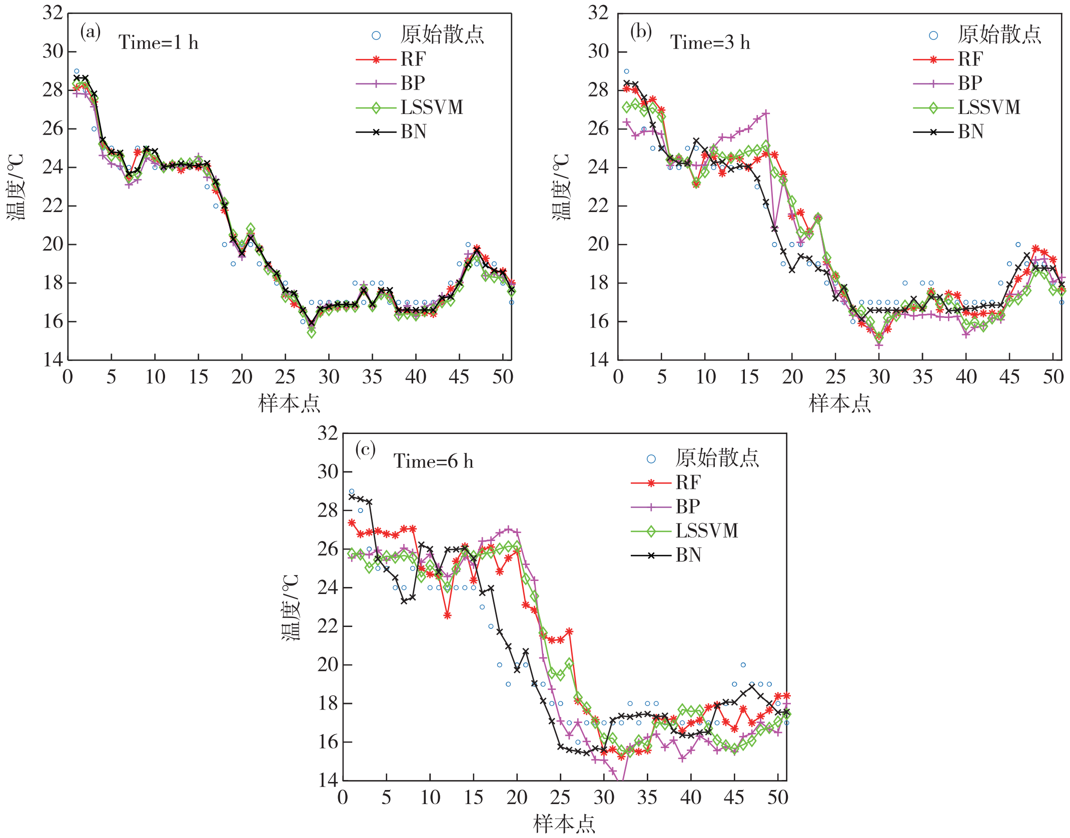

图 5　4 种 ML 算法预报的温度与真实温度对比：(a) 1 h；(b) 3 h；(c) 6 h

Fig. 5　Comparison of the temperature forecast by the four ML algorithms with the real temperature：(a) 1 h；(b) 3 h；(c) 6 h

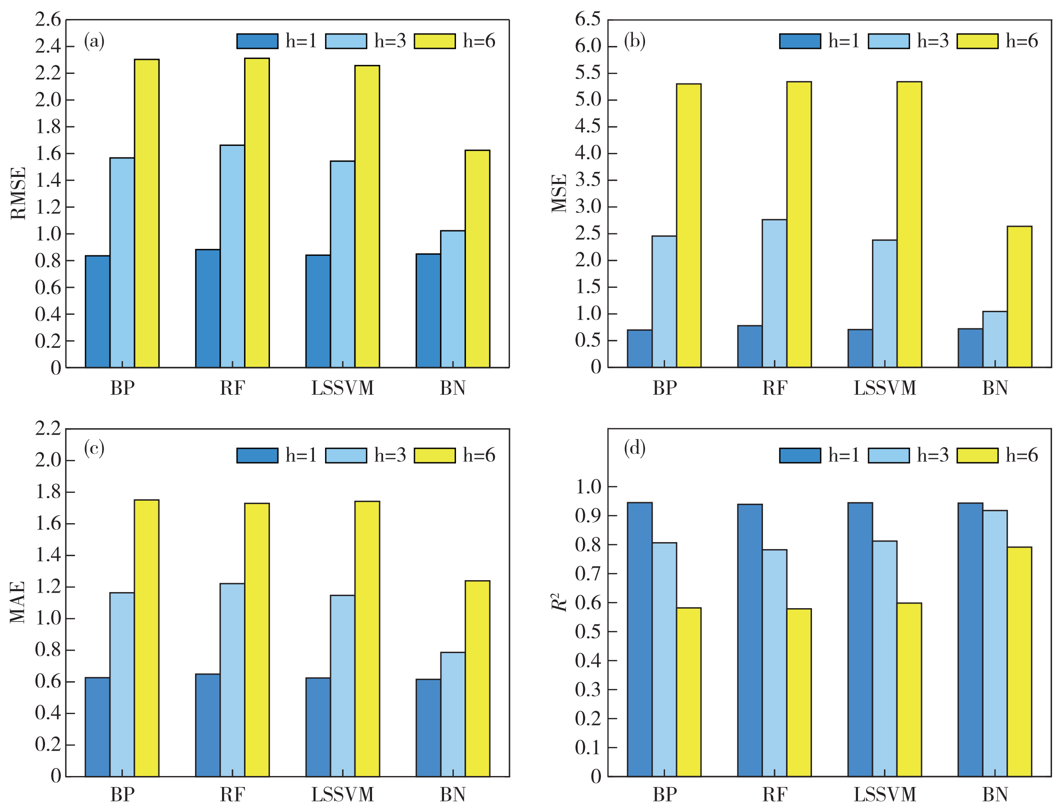

图 6　4 种 ML 算法的评估指数对比：(a) RMSE；(b) MSE；(c) MAE；(D) R^2

Fig. 6　Comparison chart of assessment indices for the four algorithms：(a) RMSE；(b) MSE；(c) MAE；(D) R^2

CLDAS-v2.0资料的预报效果优于ECMWF再分析资料的预报效果。对于不同ML算法,均方根误差的平均降幅在4%~8%之间,验证了CLDAS-v2.0近实时产品资料在中国区域质量优于国际同类产品。

参 考 文 献

[1] Klein W H, Lewis B M, Enger I. Objective prediction of five-day mean temperatures during winter. J.Atoms. Sci., 1959, 16(6): 672-682.

[2] Glahn H R, Lowry D A. The use of model output statistics(MOS) in objective weather forecasting. J. Appl. Meteor. Climatol., 1972, 11(8): 1203-1211.

[3] 郭俊廷, 胥珈珈, 吴晗, 等. 基于ECMWF细网格产品的吉林省东南部冬季气温BP-MOS预报方法. 气象灾害防御, 2021, 28(4): 24-29.
GUO Junting, XU Jiajia, WU Han, et al. Winter temperature forecast method based on ECMWF fine grid product in southeastern Jilin Province by BP-MOS. Meteorological Disaster Prevention (in Chinese), 2021, 28(4): 24-29.

[4] 黄威, 牛若芸. 基于集合预报和支持向量机的中期强降雨集成预报试验. 气象, 2017, 43(9): 1110-1116.
HUANG Wei, NIU Ruoyun. The medium-term multi-model integration forecast experimentation for heavy rain based on support vector machine. Meteorological Monthly (in Chinese), 2017, 43(9): 1110-1116.

[5] 门晓磊, 焦瑞莉, 王鼎, 等. 基于机器学习的华北气温多模式集合预报的订正方法. 气候与环境研究, 2019, 24(1): 116-124.
MEN Xiaolei, JIAO Ruili, WANG Ding, et al. A temperature correction method for multi-model ensemble forecast in North China based on machine learning. Climatic and Environmental Research (in Chinese), 2019, 24(1): 116-124.

[6] 赵菲菲, 张青青, 张宇, 等. 基于贝叶斯网络的黄河径流预测. 南水北调与水利科技, 2021, 19(3): 511-519.
ZHAO Feifei, ZHANG Qingqing, ZHANG Yu, et al. The Yellow River runoff forecast based on Bayesian network. South-to-North Water Transfers and Water Science & Technology (in Chinese), 2021, 19(3): 511-519.

[7] Sharma A, Goyal M K. Bayesian network for monthly rainfall forecast: a comparison of K2 and MCMC algorithm. Int. J.Comput. Appl., 2016, 38(4): 199-206.

[8] 耿丹, 刘婷婷, 李超. 结合FY-4A卫星及随机森林的日间沿海海雾识别模型的研究. 海洋预报, 2022, 39(3): 83-93.
GENG Dan, LIU Tingting, LI Chao. Research on a daytime sea fog identification model based on FY-4A satellite data and random forest algorithm. Marine Forecasts (in Chinese), 2022, 39(3): 83-93.

[9] Cooper G F, Herskovits E. A Bayesian method for the induction of probabilistic networks from data. Mach. Learn., 1992, 9(4): 309-347.

[10] Bouckaert R R. A stratified simulation scheme for inference in Bayesian belief networks // Proceedingsof the 10th International Conference on Uncertainty in Artificial Intelligence. Seattle: Morgan Kaufmann Publishers Inc., 1994: 110-117.

[11] 李明. 贝叶斯网络结构与参数优化学习及其海洋环境风险评估应用研究[硕士论文]. 长沙: 国防科技大学, 2018.
LI Ming. Optimization learning of Bayesian network structure and parameter and its application in marine environmental risk assessment [D]. Changsha: National University of Defense Technology (in Chinese), 2018.

[12] LI Ming, LIU Kefeng. Probabilistic prediction of significant wave heightusing dynamic Bayesian network and information flow. Water, 2020, 12(8): 2075.

[13] Runge J, Bathiany S, Bollt E, et al. Inferring causation from time series in Earth system sciences. Nat. Commun., 2019, 10(1): 2553.

[14] Kretschmer M, Coumou D, Donges J F, et al. Using causal effect networks to analyze different arctic drivers of midlatitude winter circulation. J. Climate, 2016, 29(11): 4069-4081.

[15] McGraw M C, Barnes E A. New insights on subseasonal Arctic-midlatitude causal connections from a regularized regression model. J. Climate, 2020, 33(1): 213-228.

[16] LI Ming, ZHANG Ren, LIU Kefeng. Machine learning incorporated with causal analysis for short-term prediction of sea ice. Front.Mar. Sci., 2021, 8: 649378.

[17] ZHANG Yinchen, LIANG X S. The causal role of South China Sea on the Pacific-North American teleconnection pattern. Climate Dyn., 2022, 59(5): 1815-1832.

[18] Docquier D, Vannitsem S, Ragone F, et al. Causal links between Arctic Sea ice and its potential drivers based on the rate of information transfer. Geophys. Res. Lett., 2022, 49(9): e2021GL095892.

[19] LIANG X S. Unraveling the cause-effect relation between time series. Phys. Rev. E Stat. Nonlin. Soft Matter Phys., 2014, 90(5): 052150.

[20] LIANG X S. Normalizing the causality between time series. Phys. Rev.E Stat.Nonlin. Soft Matter Phys., 2015, 92(2): 022126.

[21] Deser C, TENG Haiyan. Evolution of Arctic sea ice concentration trendsand the role of atmospheric circulation forcing, 1979-2007. Geophys. Res. Lett., 2008, 35(2): L02504.