

多年平均气温空间化 BP 神经网络模型的模拟分析

张 赛^{1,2}, 廖顺宝^{1*}

(1. 中国科学院地理科学与资源研究所 资源与环境信息系统国家重点实验室, 北京 100101;

2. 中国科学院研究生院, 北京 100049)

摘要: 气温数据空间化是插补无站地区温度、使气温数据便于综合分析的重要手段。理想情况下, 气温的空间化分布受经度、纬度和海拔高度的影响, 呈现规律性的空间分布态势。但是, 各种微观因子如坡度、坡向、地形起伏、地表覆被等的存在, 在一定程度上扰乱并弱化了这种规律性的分布态势。本文基于 Matlab 平台, 利用 BP 神经网络研究了多年平均气温数据空间化的新方法。结果表明, 与传统的 IDW 插值、Kriging 插值、样条插值和趋势面插值相比, BP 神经网络的绝对误差仅为 0.51°C , 具有较高的空间化精度, 同时它更加准确地反映了诸如阿尔泰山、天山、昆仑山、喜马拉雅山等山区低温带的气温分布规律。本研究不仅丰富了气温数据空间化的理论、技术和方法, 为相关研究提供了重要的基础数据; 而且也为降雨、蒸发等模型因果关系不十分明确的气候/气象要素的空间化提供了一定的参考和借鉴。

关键词: 多年平均气温; 空间化; ANN; BP 神经网络

DOI: 10.3724/SP.J.1047.2011.00534

1 引言

气温是生态环境的重要组成因子, 气温数据空间化主要是利用有限的陆面观测站点资料, 采用 GIS、数学模拟与遥感等技术手段, 充分考虑地形和地理因子推算得到气温要素的空间分布规律, 特别是无测站点区域的温度要素值^[1]。目前, 气温数据空间化研究主要集中在以下几个方面: (1) 基于简单的空间插值技术, 如 IDW、Kriging、样条插值和趋势面插值等; (2) 考虑地形因子的影响, 利用残差对简单插值作进一步修正^[2], 以及协同克里格 (CoKriging)^[3]等; (3) 数学模型法, 如线性回归、趋势面分析^[4-5]、Anusplin 模型^[6]、PRISM 模型^[7]等。通过更多因子的引入和更复杂技术的应用, 在空间化精度提高的同时, 计算的难度也进一步加大。

人工神经网络 (Artificial Neural Network, ANN), 亦称为神经网络 (Neural Networks, NN),

是一种规模并行的非线性动力系统, 具有全息的联想学习能力、自适应能力、高效的计算能力和复杂非线性函数的高度逼近能力^[8]。它不要求对事物机制有明确的了解, 系统的输出取决于系统输入和输入/输出之间的连接权, 而这些连接权的数值是通过训练样本的学习获得。这种方式对解决机理尚不明确的问题特别有效。

误差反向传播算法 (Back-Propagation algorithm, BP 算法) 是 ANN 中最有效、最活跃的方法之一^[8], 由此算法训练的神经网络, 称之为 BP 神经网络。在 ANN 实际应用中, BP 网络被广泛应用于函数逼近、模式识别/分类、数据压缩等, 80%~90% 的 ANN 模型都是基于 BP 网络或其变化形式, 体现了人工神经网络最精华的部分^[9-10]。

气温的空间分布, 在宏观尺度上受经度、纬度和海拔高度等可量化因子的影响, 呈现出地区上的规律性分布; 在微观尺度上, 坡度、坡向、地形起伏

收稿日期: 2010-02-19; 修回日期: 2011-07-15.

基金项目: 中科院“十一五”信息化专项——人地系统主题数据库建设与服务 (INF0-115-C01-SDB3-02); 资源与环境信息系统国家重点实验室自主研究课题——地球科学数据质量评价研究 (088RA106SA)。

作者简介: 张赛 (1982-), 女, 硕士, 工程师, 研究方向为地理信息系统应用。E-mail: zhangs@lreis.ac.cn

* 通讯作者: 廖顺宝 (1966-), 男, 博士, 副研究员, 研究方向为遥感与 GIS 应用。E-mail: liaosb@igsr.ac.cn

度、地形遮蔽度、地表覆被状况等因子扰乱了这种规律性趋势,使得局地特征复杂起来。针对这些不可量化因子造成的机理不明确的影响,本文试图利用 BP 神经网络的预测优势,探讨气温数据空间化的新方法,以进一步丰富气温数据空间化的研究内容。

2 BP 神经网络与气温数据空间化仿真模拟分析

2.1 BP 神经网络模型

BP 神经网络是一种多层前馈神经网络,包括输入层、隐层(中间层)和输出层。其中,隐层可以是一层也可以是多层。Hornik 等人的研究表明,这种网络能以任意精度逼近任意函数^[11-12]。BP 神经网络的训练是通过应用误差反传原理不断调整网络权值,使网络模型输出值与已知的训练样本输出值之间的误差平方和达到最小或小于某一期望值。

BP 神经网络的一般模型如图 1 所示^[9]。图中, P_R 表示输入向量, $W_{1,R}$ 表示输入向量的第 R 个输入元素到网络层的连接权, b 表示网络层对应的阈值。

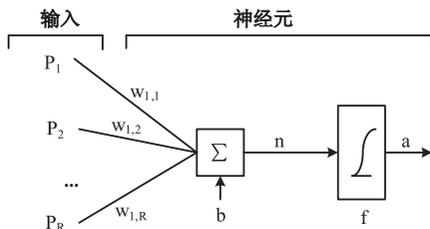


图 1 BP 神经网络的一般模型

Fig. 1 The general model of BP neural network

2.2 基于 BP 神经网络的气温数据空间化仿真分析

在宏观尺度上,纬度、海拔高度和海拔分布(经度)是影响气温分布的主要自然地理要素。因此,用 BP 神经网络进行气温数据空间化,需将已知气象站点的经度、纬度和海拔高度,以及相应的气温作为训练样本,构建能够反映因变量(气温)和自变量(经度、纬度和海拔高度)关系的 BP 神经网络模型。利用 BP 神经网络对待插值点进行模拟,即得到拟合气温。

美国 MathWorks 公司开发的 MATLAB 具备强大的矩阵计算和仿真能力,其所提供的神经网络

工具箱提供了多种学习算法和相关函数,借助它可以直观方便地进行神经网络的应用设计、分析和计算。本文利用 MATLAB 7.1 作为 BP 神经网络的设计平台,实现研究区域的气温数据空间化。

2.2.1 数据源分析

本研究进行气温数据空间化所用的数据源包括气温和数字高程模型两部分:

(1)1971 - 2000 年中国大陆地区 698 个气象站点的气温资料,来自中国科学院地理科学与资源研究所地球系统科学信息共享中心。按照站名、编号、经度、纬度、高程、多年平均气温 6 个字段进行整理,建立了常规的多年平均气温数据表。

(2)美国地质调查局(USGS)30 弧秒 DEM 数据(分辨率大约 1km)。对数字高程数据 DEM 的空值区域,利用提取等高线内插的方法进行填补,即从 GTOPO1km 数据中直接提取等高线,再内插生成 DEM,用内插出来的值填补原始数据得到中国范围 30 弧秒 DEM 栅格图。

2.2.2 空间化分析方法

(1)样本数据归一化

由于 BP 神经网络的隐层一般采用 Sigmoid 转换函数,为提高训练速度和灵敏性以及有效避开 Sigmoid 函数的饱和区,同时保证模型具有一定的外推能力,输入数据的值最好处于 0.2 ~ 0.8 之间^[13]。因此,首先要对输入数据进行预处理。设置样本自变量的区域范围如下:

经度: $\text{Min}X=60, \text{Max}X=150$

纬度: $\text{Min}Y=10, \text{Max}Y=60$

高程: $\text{Min}Z=-300, \text{Max}Z=10000$

那么,

经度: $X'=(X-\text{Min}X)/(\text{Max}X-\text{Min}X)$

纬度: $Y'=(Y-\text{Min}Y)/(\text{Max}Y-\text{Min}Y)$

高程: $Z'=(Z-\text{Min}Z)/(\text{Max}Z-\text{Min}Z)$

输出层节点采用 purelin 线性转换函数,故而因变量气温无需作归一化处理。

(2)样本的分类

采用 BP 神经网络建模的前提条件是足够多、典型性好和精度高的样本。同时,为了监控训练过程和评价所建网络的性能和泛化能力,将总的样本数据分为训练样本 I 和检验样本 T 两部分。

按照均匀分布的原则^[2],选择了 56 个站点作为检验样本。检验样本之外的 642 个站点数据作为训练样本,气象站分布情况如图 2 所示。

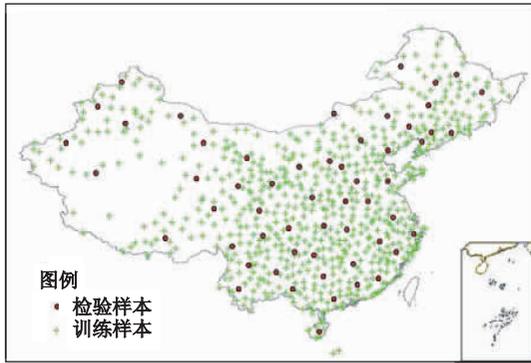


图2 气象站分布

Fig. 2 Distribution of meteorological stations

2.2.3 BP神经网络建模

根据气温数据空间化这一具体问题,在多次试算的基础上,选择3-15-1三层网络结构,即输入层神经元为3个:经度、纬度和高程;隐层为一层,包含15个隐神经元;输出层神经元为气温。设置传输函数为 tansig 和 purelin;训练函数为 trainlm;误差性能目标值为 0.01。其中,tansig 表示正切 S 型传递函数;purelin 表示线性函数;trainlm 是一种反向传播训练函数。对训练样本进行多次训练,最终得到 BP 神经网络模型 Net。BP 神经网络结构如图 3 所示。网络权值矩阵如图 4 所示。

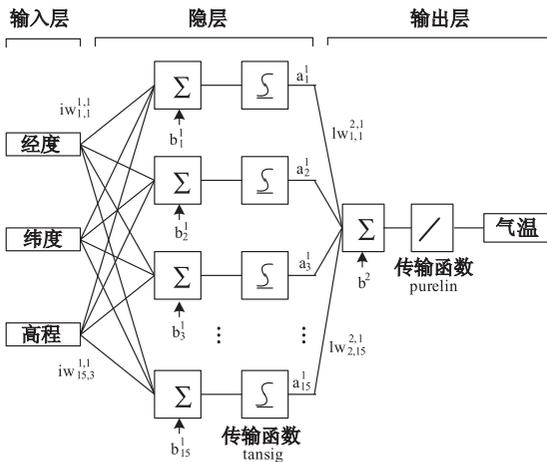


图3 BP神经网络结构

Fig. 3 Structure of BP neural network

2.2.4 试验结果与分析

利用建立的 BP 神经网络对预先设定的 56 个检验样本进行模拟,得到检验样本的拟合值,然后与检验样本的真实值比较(如图 5、6 所示),误差 100% 分布于 $-2.5 \sim 2.5^{\circ}\text{C}$ 之间。其中,检验样本拟合值的平均绝对误差为 0.51°C ,标准误差为

0.74°C 。拟合值与真实值的相关系数为 0.993。

7.3566	5.4013	3.9419
-9.7385	17.6649	-9.2500
2.7438	0.5495	1.0578
-1.0127	1.0599	4.9227
29.4365	8.8011	-0.7746
29.4729	-14.5578	2.0796
3.8754	-1.8518	12.7002
-15.0483	16.3045	17.4030
30.4774	8.8387	-0.6850
-2.6981	1.0445	14.1446
9.3828	-17.6578	9.3522
2.4351	-3.1743	-14.9993
24.3229	27.0621	23.5741
2.3063	-6.7140	-2.7499
-5.1286	-3.6102	11.9234

图4 权值矩阵

Fig. 4 Matrix of weights

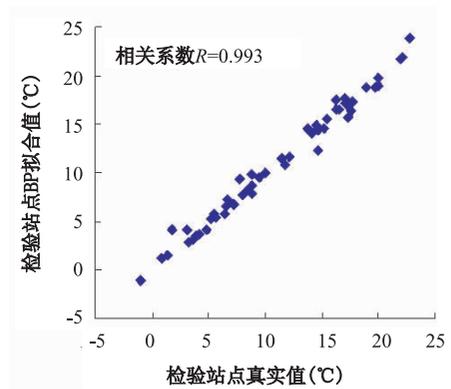


图5 检验站点拟合值和真实值的关系

Fig. 5 The relationship between simulated and observed temperature

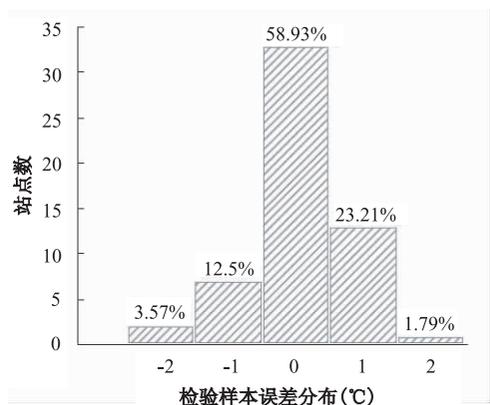


图6 检验站点的误差分布直方图

Fig. 6 The histogram of errors distribution

与 IDW、Kriging、样条插值、趋势面插值 4 种空间插值方法内插结果^[2]进行比较,如表 1 所示,在相关系数、标准误差、平均误差方面均有明显的改善。众所周知,长时间尺度的多年平均气温值无明显变化,故而利用 1951 - 1980 年与 1971 - 2000 年之间的气温值比较的结果是可信的。

表 1 BP 神经网络与 IDW、Kriging、样条插值和趋势面插值的比较

Tab. 1 The comparison on BP neural network, IDW, Kriging, Spline and Trend

	反距离 权重 (IDW)	克里格 插值 (Kriging)	样条插值 (Spline)	趋势面 插值 (Trend)	BP 神经 网络插值 (BP neural network)
相关系数	0.944	0.937	0.910	0.857	0.993
标准误差(°C)	2.21	2.34	2.89	3.45	0.74
平均误差(°C)	1.44	1.41	1.76	2.68	0.51

利用 GTOPO30 弧秒 DEM 衍生出区域相同,且栅格单元均为 0.04 度(大约 4km)的经纬度栅格图和高程栅格图。利用所建的 BP 神经网络模型对归一化后的经纬度栅格图和高程栅格图进行仿真,得到全国 0.04 度(大约 4km)的气温栅格图。在反映全国气温分布基本规律的基础上,与传统的依赖于空间自相关的 IDW 方法、Kriging 方法、样条插值方法、趋势面插值方法相比,BP 神经网络的输出结果更好地反映了局地的气温极端值,如阿尔泰山、天山、祁连山、喜马拉雅山、昆仑山等高山区,由于海拔高度的升高,这些地区的气温可低至 -10°C 以下。而 IDW、Kriging 方法无法准确地模拟出这些真实值。BP 神经网络通过高程的引入和对微观尺度上扰动因子的训练试算,在反映气温分布总体规律的基础上,更好地展示了这些高海拔地区的气温分布(如图 7 所示)。

3 结语

神经网络模型及其学习算法,试图从数学上描述 ANN 的动力学过程,建立相应的 ANN 模型,在该模型的基础上,对于给定的学习样本,以较快的速度和较高的精度调整神经元间互连权值,使系统达到稳定状态,满足模拟要求。在对气温与经纬度和高程之间关系难以精确量化的情况下,本文利用

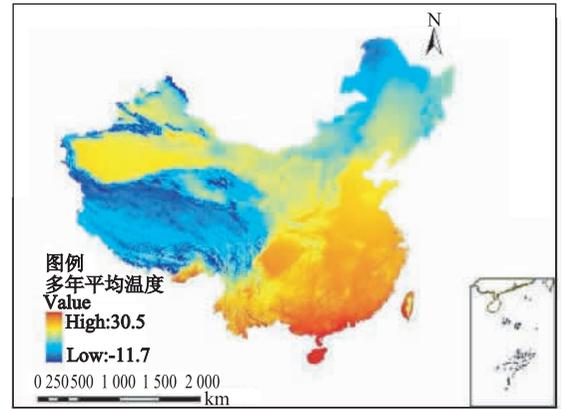


图 7 中国多年平均气温分布(1971 - 2000)

Fig. 7 The distribution of mean annual air temperature in China during the period of 1971 - 2000

BP 神经网络模型,通过参数的调整和网络的自训练,达到了很好的拟合效果。一方面丰富了气温数据空间化的研究内容,另一方面也为降雨、蒸发等因果关系不十分明确的气象/气候要素的空间化提供了参考。

当然,人工神经网络的优越性是建立在重复试验的基础上。首先,数据预处理方法的选取,要保证所建模型的外推能力。其次,隐层节点个数的选取至关重要,在保证网络性能的基础上,要避免出现过拟合的状态。这些是后续研究中需注意的问题。

参考文献:

- [1] 于贵瑞,何洪林,刘新安,等. 中国陆地生态信息空间化技术研究(I)——气象/气候信息的空间化途径[J]. 自然资源学报,2004,19(4):537 - 544.
- [2] 廖顺宝,李泽辉. 气温数据栅格化中的几个具体问题[J]. 气象科技 2004,32(5):352 - 356.
- [3] 杨凤海,孙彦坤,于太义,等. 近 10 年黑龙江省气温的时空变异分析[J]. 地球信息科学学报,2009,11(5):585 - 595.
- [4] 任传友,于贵瑞,刘新安,等. 东北地区热量资源栅格化信息系统的建立与应用[J]. 资源科学,2003,25(1):66 - 71.
- [5] 刘新安,于贵瑞,范辽生,等. 中国陆地生态信息空间化技术研究(III)——温度、降水等气候要素[J]. 自然资源学报,2004,19(6):131 - 138.
- [6] 刘志红, Li Lingtao, McVicar T R, 等. 专用气候数据空间插值软件 ANUSPLIN 及其应用[J]. 气象,2008,34(2):92 - 100.
- [7] Daly C, Gibson W P, Taylor G H, et al. A Knowledge

- based Approach to the Statistical Mapping of Climate [J]. *Climate Research*, 2002, 22(6): 99 – 113.
- [8] 莫林, 张秋文. 神经网络在降水量空间插值中的应用研究[J]. *计算机与数字工程*, 2007, 35(9): 9 – 12.
- [9] 周开利, 康耀红. 神经网络模型及其 MATLAB 仿真应用程序设计[M]. 北京: 清华大学出版社, 2005.
- [10] 高隽. 神经网络原理及仿真实例[M]. 北京: 机械工业出版社, 2007.
- [11] Hornik K, Stinchcombe M, White H. Universal Approximation of an Unknown Mapping and its Derivatives Using in Multiplayer Feedforward Networks[J]. *Neural Networks*, 1990(3): 55 – 560.
- [12] Hornik K, Stinchcombe M, White H. Multiplayer Feedforward Networks are Universal Approximators [J]. *Neural Networks*, 1996(3): 359 – 366.
- [13] 刘长安. 神经网络的研究方法及应用[R]. <http://210.45.168.35:8080/shuxue/SyxUploadFile/2009-11/205470%A1%BEPPT%A1%BFMATLAB%C9%F1%BE%AD%CD%F8%C2%E74.pdf>, 2004, 12.

Simulation and Analysis of Spatialization of Mean Annual Air Temperature Based on BP Neural Network

ZHANG Sai^{1,2}, LIAO Shunbao¹

- (1. *State Key Laboratory of Resources and Environmental Information System, Institute of Geographic Sciences and Natural Resources Research, CAS, Beijing 100101, China;*
2. *Graduate University of Chinese Academy of Sciences, Beijing 100049, China*)

Abstract: Air temperature is one of the main influential factors of ecosystem. Ideally, air temperature is mainly affected by longitude, latitude, altitude and the distance from the ocean, so its spatial distribution should show a regular tendency. However, to some extent, the existence of various microcosmic topographical factors (such as slope, aspect, topographic relief, terrain shade land cover, etc.) disturbs its fundamental distribution tendency, even strongly in certain areas, and thus complicates the research and estimation on air temperature. Artificial Neural Network (ANN), which has adaptive capability, high-efficient computing power and powerful nonlinearity approach capability, can effectively improve prediction precision and have generalization capacity. BP neural network is one of the easily understood and most effective methods of ANN. By applying BP neural network and Matlab platform, the spatialization of mean annual air temperature was carried out in this paper, and the spatialization result was compared with those by previous researchers. The comparison confirmed the advantage of the spatialization method. The results from the comparison indicate that BP neural network has higher accuracy with a mean absolute error of 0.51°C than other spatialization methods, including IDW, Kriging, Spline and Trend. Furthermore, the results of the spatialization are able to describe the distribution of low air temperature in mountain areas, such as the Altai, the Tianshan Mountains, the Kunlun Mountains and the Himalayas in more details. This study not only complements theories, technologies and methods of air temperature spatialization, but also provides an important data product for relevant researches. It also provides a reference to spatialization of other climate data, such as rainfall, evaporation, and so on.

Key words: mean annual air temperature; spatialization; ANN; BP neural network