

时空预测技术在森林防火中的应用研究^{*}

王佳[✉], 程 涛

(中山大学地理科学与规划学院, 广东 广州 510275)

摘 要: 构建了一个随机的时间序列模型获得每一个空间上相互独立部分的时间预测, 然后建立动态回归神经网络 (DRNN) 发现隐藏的空间关系, 最后用统计回归方法把单个时间和空间预测整合起来产生最终预测。实验结果表明, 提出的方法能对森林火灾面积进行准确有效的预测。通过对时空预测结果的准确性和训练精度进行讨论, 分析了时空预测方法在林火预测中的可行性, 证明时空变化预测方法在林火预测中的应用价值。

关键词: 时空预测; 森林火灾; 动态回归神经网络

中图分类号: P208 **文献标识码:** A **文章编号:** 0529 6579 (2007) 02 0110 05

时空数据挖掘是当前 GIS 研究领域的一项重要课题, 也是实现从数据到信息和知识的一项关键技术。时空数据挖掘的技术可以分成时空关联规则挖掘、时空序列模式挖掘、时空数据预测以及时空聚类 and 区分规则挖掘^[1]。作为数据挖掘技术之一, 预测是指从当前和过去数据中挖掘隐藏的模式并用现有模式对未来进行预测的方法^[2]。近年来, 随着需求的迅速增长, 在森林火灾预测, 洪水控制, 降雨量分析, 环境污染研究, 核泄露保护等领域, 时空数据预测的作用越来越重要, 因此也出现了很多时空预测模型, 这些预测模型基于当前成熟的分析工具, 例如时间序列分析, 空间统计分析, 然后在这些成熟工具的基础上, 进行时空扩展^[3], 与此相反的是 Deutsch 等通过空间邻域矩阵把空间关系扩展到时间序列分析^[4-5]。然而, 这些模型方法离实用性还有一段距离。在以前工作的基础上, Li^[6]等利用统计分析策略和数据挖掘技术建立了一个称为 STIFF 的时空预测模型, 克服了以前工作的限制较好地解决了时空数据的问题, 得到了较好预测效果。这种方法的实质是对时空数据的挖掘采取分解与合并的策略, 即先对空间位置 (或目标) 进行时间序列分析, 然后用人工神经网络来发现所有空间位置数据间隐藏的空间相关性。在此基础上, 利用统计回归方法将时间序列分析和空间相关性分析结合起来, 得到时空一体化的多变量分析结果, 从而实现时空和高维的耦合。

林火有典型的时空特点, 是气候、地形、火源和可燃物诸因子相互作用形成的复杂现象, 通常具有复杂的随机性和非线性行为, 并且这些因子随着时间不断变化, 因此对森林火灾的预测属于时空预测范畴。为此提出了 STIFF 模型, 用来预测森林火灾。STIFF 模型用动态回归神经网络 (DRNN) 进行空间预测, 替代 STIFF 模型中的静态前馈神经网络。动态回归神经网络是在 80 年代末, 国际上一些神经网络专家如 Jordan, Pineda William s Ehn an 等人提出的一种新神经网络结构模型, 即动态回归神经网络。这种网络的本质特征是在处理单元之间既有内部的反馈连接又有前馈连接, 是一种强有力的非线性动力学系统, 比前馈神经网络具有更强的动态行为和计算能力, 能直接反映动态过程系统的特性, 比前向神经网络具有更强的计算能力, 这使得模型具有更强的鲁棒性 (Robust)^[7]。

1 时空数据预测原理

1.1 问题定义

定义时空问题的符号如表 1:

问题定义: 给一个位置的集合 Δ , 整个变量的时间序列数据 Π 和计划步骤 s , 一个时空预测问题要求找下列映射关系 f 定义为

$$f : \{ \Delta, \Pi, s \} \rightarrow \{ \sigma_{0+(t+1)}, \sigma_{0+(t+2)}, \dots, \sigma_{0+(t+s)} \}$$

1.2 算法

时空预测方法算法如下^[9]:

^{*} 收稿日期: 2006 - 04 - 17
基金项目: 国家重大基础研究资助项目 (2006CB701306); 教育部博士点基金资助项目 (20040558023); “ 985 工程 ” GIS 与遥感的地质应用科技创新平台资助项目 (105203200400006)
作者简介: 王佳[✉] (1975 年生), 男, 博士生; 通讯联系人: 程涛; Email : tao.cheng@ge.uc1.ac.uk
(C)1994-2019 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

表 1 符号定义
Tab. 1 Symbol Definition

符号	意义
Δ	$n+1$ 个位置集合
$a_i (i=0, 1, \dots, n)$	在 Δ 中空间上分离的位置
Π	在所有位置离散的时间序列集
$\sigma_i (i=0, 1, \dots, n)$	在位置 a_i 上第 i 个时间序列
$l (= a_i)$	时间序列数据的长度
$\sigma_{ij} (i=0, 1, \dots, n; j=0, 1, \dots, l)$	时间序列数据 σ_i 的第 j 个观察点
s	计划步骤

Setp 1: 定义要预测的问题, 决定要预测的目标位置 α_0 和与它空间上相关的位置 $\alpha_1, \alpha_2, \dots, \alpha_n$ 。

Setp 2: 为每一个位置 $\alpha_1, \alpha_2, \dots, \alpha_n$ 建一个时间序列模型 TS_i , TS_i 表示对每一个位置的时间预测。 α_0 提供的时间序列预测 TS_0 将被记为 f_i 。

Setp 3: 基于所有位置的空间关系 $\alpha_i (i \neq 0)$, 构造一个神经网络捕捉其它位置对目标位置 α_0 的空间影响。神经网络被经过训练后, 把每一位置的时间序列模型 $TS_i (i \neq 0)$ 作为神经网络的输入, 得到的输出为空间影响预测 f_i 。

Setp 4: 把得到的时间预测 f_i 和空间预测 f_i , 根据回归分析得到最终的时空预测值。

2 模型应用及结果

2.1 研究区及数据

本文选择加拿大森林火灾研究网站建立的森林大火数据库 (简称 LFDB) 作为实验数据^[8]。这个数据库记录了加拿大 1959 - 2000 年面积超过 200 km² 的森林大火, 数据覆盖了加拿大各个省份、区域和森林公园范围。各研究区域的空间关系如图 1 所示。确定 Alberta (AB) 和 New found land (NF) 省为预测目标, 相邻几个省位置分别为 British Columbia (BC)、Saskatchewan (SK)、Manitoba (MB)、Ontario (ON)、Northwest Territories (NWT) 和 Quebec (QC)。以 Alberta 省为例说明建模过程。

2.2 建时间序列模型预测时间关系

首先, 对数据进行分析, 发现原始数据中有一些缺失值, 所以对缺失的部分用线性插值的方法进行补缺, 使数据完整。画出 Alberta 省 1959 - 1989 年的数据的时间序列图, 如图 2 所示。



图 1 加拿大森林火灾预测空间关系图
Fig. 1 Spatial map of provinces in Canada




图 2 时间序列图
Fig. 2 Time series plot

通过观察时间序列图, 发现此序列不平稳, 因此需要进行数据转换, 通过对原始数据进行差分把不平稳的序列转变为平稳的序列, 然后对转换后的数据建立 ARMA 模型 (Autoregressive Integrated Moving Average Model), 模型的 (p, d, q) 三个参数分别选 $(1, 1, 1)$, 把参数代入模型, 得到 Alberta 省 1990 - 2000 年时间预测数据。最后, 通过同样的分析, 为每一个位置建立 ARMA 模型, 得到每一个位置的时间序列数据 f_i 。

2.3 建立动态回归神经网络预测空间关系

首先, 确定动态回归神经网络的拓扑结构。拓扑结构的设计要能够反映研究区域的空间相关性。空间相关性可用空间连接矩阵表示^[9]。空间连接矩阵认为只有相邻的空间单元之间才有空间交互。邻接性由 0 和 1 两个值表达。如果两个空间单元有非零长度的公共边界, 就认为二者是相邻的, 对应的连接元素赋值 1^[10]。因此可以根据图 1 得到相邻省份的二进制连接矩阵 (图 3)。




图 3 空间连接矩阵示意图

Fig 3 Sketch map of spatial binary contiguity

因此，考虑到研究区域的空间相关性，构造三层神经网络。输入层和隐层节点的数目为 6，输出层节点的数目为 1。由于森林火灾发生是动态过程，而目前大多数预测采用的是基于 BP 算法的静态前馈神经网络对动态过程进行预测，而且 BP 网络稳定性较差，采用动态回归神经网络（DRNN）进行预测。DRNN 不但稳定性较好，而且比 BP 网络具有更强的计算能力，能够得到更好的预测效果。Elman 回归神经网络是一种典型的动态神经元网络，它是在 BP 网络基本结构基础上，通过存储内部状态使其具备映射动态特征的功能，从而使系统具有适应动态变化的能力，而且网络据有较好的稳定性。为了比较它们之间的不同，构造一个 BP 网络（图 4a）和一个 Elman 网络（图 4b）。




图 4 空间预测神经网络结构图

Fig. 4 The structure of designed BP network and Elman network for spatial forecasting

网络训练所用的数据是从 1959 – 1989 年过去 30 a 加拿大森林火灾面积数据。此外，合理的选择转换函数也是很重要的，选择 $\tansig$ 为隐层转换函数， $\logsig$ 为输出层转换函数，训练函数为 trainlm 。

网络学习率设为 0.01，训练次数为 1000 次。把数据分别输入 Elman 网络和 BP 网络进行训练，Elman 网络训练 20 次，BP 网络训练 31 次以后达到训练目标。然后把 1990 – 2000 年的 ARMA 预测数据作为 Elman 和 BP 网络的输入进行测试，得到空间预测（Elman 预测结果）和（BP 预测结果）（图 5）。




图 5 Elman 和 BP 神经网络空间预测比较图

Fig. 5 Comparison of forecasting results based on Elman and BP network

2.4 回归分析产生全面时空预测

到现在为止，得到了关于 Alberta 省的时间和空间两方面的预测 f_t 和 f_s 。我们的目标是产生一个合理的全面的时空预测。为了使整合易于理解和简单，普遍的方法是运用线性回归，线性回归方程如下：
$$f_{overall} = x_1 \times f_t + x_2 \times f_s + \text{Regression_Constant} \quad (1)$$

方程中 x_1 和 x_2 是回归系数，Regression_Constant 是回归常数。经过最小二乘估计，得出 x_1 为 2.538， x_2 为 0.976，Regression_Constant 为 -42381.5。 $f_{overall}$ 的预测结果与 1989 – 2000 年的实际数据是基本一致的。图 6 显示了实际值与 ARMA 模型、STIFF 和 ISTIFF 预测方法的比较结果。




图 6 不同预测方法比较图

Fig. 6 Comparison of different forecasting methods

2.5 精度评估

用 NRMSE（Normalized Root Mean Square Er

ior) 公式对预测精度进行评估。

NRMSE 的表达式如下:

$$NRMSE = \sqrt{\frac{\sum [x(t) - \hat{x}(t)]^2}{\sum x^2(t)}} \quad (2)$$

式中, $\hat{x}(t)$ 是 $x(t)$ 实际值 $x(t)$ 的预测值。

另外, 用 ARMA、STIFF 和 ISTIFF 方法对加拿大 NF (纽芬兰) 省森林火灾面积进行了预测。对 AB 和 NF 两组预测数据进行评估, 预测精度比较如表 2 所示。

表 2 不同方法的预测精度比较

Tab. 2 Prediction accuracy comparison of different forecasting methods

Model	AB	NF
ARMA	0.5969	1.7411
STIFF	0.4151	1.0128
ISTIFF	0.2112	0.7707

通过对不同方法的比较, 我们发现 ISTIFF 方法预测精度比 STIFF 和 ARMA 方法都高。从 AB 和 NF 预测结果可以看出, AB 省的预测精度高于 NF 省的, 这可能是因为 AB 省空间相关性要大于 NF 省的空间相关性, 空间相关性越强预测误差越小, 预测精度也更高。

3 小 结

本文阐述了时空预测模型, 并将动态回归神经网络 (DRNN) 引入该模型, 提出的 ISTIFF 方法提高了模型预测稳定性和精度, 使模型有更强的空间预测能力。该模型被应用于加拿大森林火灾面积预测。通过对实验结果进行对比和误差分析, 发现 ISTIFF 模型明显比其它方法预测精度高, 预测结果可以为森林火灾扑救提供智能决策支持。然而, ISTIFF 方法仅仅考虑一种变量情况, 林火的相关因素很多, 是气候、地形、火源和可燃物诸因子相互作用形成的复杂现象, 单变量预测会存在一定误差, 即使相对误差小, 但绝对误差也可能很大。因

此, 在将来的工作中我们将考虑多变量情况下的森林火灾时空预测。

参考文献:

[1] MILLER H J HAN J. Geographic Data Mining and Knowledge Discovery[M]. London: Taylor & Francis, 2001.

[2] CRESSIE N MAJURE J J. Spatio temporal statistical modeling of livestock waste in streams[J]. Journal of Agricultural Biological and Environmental Statistics, 1997, 2(5): 20 – 28.

[3] POKRAJAC D OBRADOVIC Z. Improved spatial temporal forecasting through modeling of spatial residuals in recent history[C] // Proceedings of first international SIAM conference on data mining Chicago, 2001, 368 – 386.

[4] DEUTSCH S J RAMOS J A. Space time modeling of vector hydrologic sequences[J]. Water Resources Bulletin, 1986, 22(6): 967 – 980.

[5] PFEIFER P E DEUTSCH S J. A statistical model building procedure with application to description and regional forecasting[J]. Journal of Forecasting, 1990, 9(1): 50 – 59.

[6] LIZ DUNHAM M H. STIFF: A forecasting framework for spatio temporal data[M]. Mining Multimedia and Complex Data[M]. New York: Springer-Verlag, 2002, 183 – 188.

[7] 朱群雄, 孙锋. RNN 神经网络的应用研究[J]. 北京化工大学学报, 1998, 25(1): 86 – 90.

[8] Canada Forest Fire Services Network. Canada Large Fire Database[EB/OL]. [2002 – 10 – 12]. http://fire.cfs.nrcan.gc.ca/research/climate_change/lfdb/lfdb_download_e.htm.

[9] Moran P. The Interpretation of Statistical Maps[J]. Journal of the Royal Statistical Society B, 1948, 10: 243 – 251.

[10] 刘旭华, 王劲峰. 空间权重矩阵的生成方法分析与实验[J]. 地球信息科学, 2002(2): 38 – 44.

(下转第 116 页)

(42): 591 – 635.

Math Soc 2002 65 (2): 103 – 114.

[6] LIP TAM L F. Uniqueness and regularity of proper harmonic maps [J]. Ann of Math 1993 (137): 167 – 201.

[8] GARDNER F LAKIC N. Quasiconformal Teichmüller theory Mathematical Surveys and Monographs [M]. Providence American Mathematical Society (AMS), 2000.

[7] MARKOV E V. Harmonic diffeomorphisms of noncompact surfaces and Teichmüller spaces [J]. J London

Non-harmonicity of Beurling Ahlfors Extensions

SUN Zong-liang

(School of Mathematics and Computational Science, Sun Yat-sen University,
Guangzhou 510275, China)

Abstract The conformal naturality of extensions characterizes the compatibility of extensions with the group of Möbius transformations of the unit disk. In this paper, a counterexample is constructed to show that the Beurling-Ahlfors extension is not always conformally natural. The conformal naturality of quasiconformal harmonic rough isometric extensions is proved. As an application, the non-harmonicity of the Beurling-Ahlfors extension is shown.

Key words Beurling Ahlfors extension; conformal naturality; harmonic extension

(上接第 113 页)

Applications of Spatio-Temporal Forecasting to Forest Fire Prevention

WANG Ji-qiu, CHENG Tao

(School of Geography and Planning, Sun Yat-sen University, Guangzhou 510275, China)

Abstract A stochastic time series model was constructed to capture the temporal characteristics of each spatially independent subcomponent. Then a dynamic recurrent neural network (DRNN) was built to discover the hidden spatial correlation. Finally, the previous individual temporal and spatial forecasts were combined based upon statistical regression to produce the final forecasting result. The results indicated that the forest fire could be forecasted exactly and effectively by the proposed method. Detailed discussions on the performance and the training precision of the model were presented, and the feasibility of forest fire forecasting was analyzed. ISTIFF had comprehensive application value in the forecast of forest fire.

Key words spatio-temporal forecasting; forest fire prevention; dynamic recurrent neural network