

文章编号:1671-6833(2008)03-00137-04

一种基于径向基神经网络的组合预测模型

姚亚夫, 彭 昊

(中南大学 机电工程学院, 湖南 长沙 410083)

摘 要: 根据基于最近邻聚类算法(NNCA)的径向基(RBF)神经网络和自回归求和滑动平均(ARIMA)两种方法,建立了各自的单项预测子模型,并利用RBF神经网络对两个单项预测子模型结果进行组合预测,得到最终的预测值.将该模型应用于长沙市某路段的交通流量预测,实验结果证明了该预测模型的有效性,采用组合预测模型比单一预测模型的预测精度有了较大提高.

关键词: 组合预测模型;最近邻聚类算法;径向基;RBF神经网络;交通流量

中图分类号: TP 183 **文献标识码:** A

0 引言

在研究社会经济问题时,人们常常需要对未来的情况进行预测,然而事先无法确定哪一种预测方法是最佳的.因为每种预测方法的适用条件不同,预测前很难准确判断出适用条件.不过,每种方法都有其独特的信息特征,能从不同的角度反映未来的情况.为了尽可能多地利用有用信息,Bates和Granger(B-G)在1969年提出了组合预测的理论^[1].组合预测方法是将各种不同的单项预测子模型各取所长,显著改进了预测效果.它在有效提高预测准确性方面,受到了国内外预测工作者的重视.组合预测模型大体上分为:线性组合预测,如最优加权系数向量算法^[2]、变权组合预测模型^[3];非线性组合预测,如神经网络组合预测模型.文献[4-5]采用BP神经网络来进行非线性组合预测的模拟,取得了较好的效果.但是BP神经网络不可避免地存在收敛速度慢、易陷入局部最优以及初始网络参数不易确定等缺点.而径向基(Radial Basis Function, RBF)神经网络很好的解决了上述BP网络存在的问题.为此,笔者建立了一种基于RBF网络的非线性组合预测模型,提高预测的精度.

1 组合预测法

设某一预测对象拥有 m 个时段的历史数据 $Y = (\tilde{y}_1, y_2, \dots, y_m)^T$, y_t 为某一时段 t 的实际值.利用 n 种预测法或预测模型进行预测,预测值为 F_t ,

$= (f_{1t}, f_{2t}, \dots, f_{nt})^T$; $t = 1, 2, \dots, m$. 组合预测的目的就是找到一个映射 $\phi: E^n \rightarrow R^1$, 这里 E^n 为 n 维向量空间, R^1 为1维向量.即通过映射 ϕ 把 n 维向量 F_t 投影到一个点 $\phi(F_t)$ 上,使得 $\|C - Y\|^2$ 最小.其中, $C = (\phi(F_1), \phi(F_2), \dots, \phi(F_m))^T$, $\|\cdot\|$ 为欧式范数.

B-G将 ϕ 定义为线性组合函数,即

$$\phi(F_t) = f_1 w_1 + f_2 w_2 + \dots + f_n w_n \quad (1)$$

式中: w_i 为第 i 种预测方法的加权系数,且 $\sum w_i = 1, w_i \geq 0$.不难看出,B-G线性组合预测法精度的提高存在约束条件.首先,预测对象的实际值要介于所有预测方法得到的预测值的最大值与最小值之间.其次,由于权系数是固定不变的,也会导致预测精度的降低.

为了克服B-G组合预测法的不足,可以将 ϕ 定义为非线性函数.对于人工神经网络来说,它具有很强的鲁棒性和容错性,以及很强的学习能力.可以采用神经网络对组合预测中的映射函数 ϕ 模拟,即可以通过对样本 $F_t = (f_{1t}, f_{2t}, \dots, f_{nt})^T$ 及目标值 y_t 的训练学习,最终达到逼近非线性映射 ϕ 的目的.

2 组合预测模型的结构

笔者的前期单项预测子模型采用基于最近邻聚类算法的RBF神经网络(NNCA-RBF)和自回归求和滑动平均(ARIMA)两种方法.子模型的预测结果作为RBF神经网络的输入值,网络的输出

收稿日期:2008-06-14;修订日期:2008-07-11

作者简介:姚亚夫(1962-),男,湖南岳阳人,中南大学副教授,硕士,主要从事汽车电子、交通工程研究.

则是最终的预测值.其结构拓扑图见图 1. RBF 神经网络有 3 个网络层:

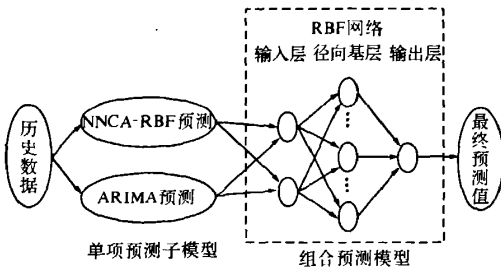


图 1 组合预测模型拓扑图

Fig. 1 The topology of combined forecast model

输入层节点只传递输入信号到隐层,隐层节点由辐射状作用基函数构成,而输出层节点是对隐层的输出进行线性加权.隐层节点中的基函数,一般取高斯函数

$$R_i(x) = \exp(-\|x - c_i\|^2 / (2\sigma_i^2)), \quad (i=1, 2, \dots, m) \quad (2)$$

式中: x 是 n 维输入向量; c_i 是第 i 个基函数的中心, n 维向量; σ_i 是第 i 个基函数围绕中心点宽度; m 是隐层节点数. $\|x - c_i\|$ 是向量 $x - c_i$ 的范数;对于给定的输入 $x \in R_n$,只有一部分靠近中心的被激活.该组合预测模型综合了 NNCA-RBF 和 ARIMA 子模型的优点,把二者的预测结果有机结合到组合预测模型中,并利用神经网络的函数逼近特性,实现预测值和实际值的最佳逼近.

3 单项预测子模型

3.1 基于最近邻聚类的 RBF(NNCA-RBF)神经网络预测子模型

文献[6]采用的神经网络参数初始化方法要求事先获得充分的样本输入,且选定合理的隐单元数,需要大量的“试凑”试验才能确定合理的网络结构.针对这一问题,笔者使用基于最近邻聚类的算法确定 RBF 网络的结构.最近邻聚类算法是一种在线自适应聚类学习算法,不需要事先确定隐单元的个数,完成聚类所得到的 RBF 网络是最优的,并且此算法可在线学习.具体过程如下:

第 1 步:选择一个的高斯函数宽度 σ ,定义一个矢量 $A(l)$ 用于存放属于各类的输出矢量之和,定义一个计数器 $B(l)$ 用于统计属于各类的样本个数,其中 l 为已获得的类别数.

第 2 步:从第一个数据对 (x^1, y^1) 开始,形成一个聚类中心,令 $c_1 = x_1, A(1) = y^1, B(1) = 1$. 该隐单元到输出层的权矢量为 $w_1 = A(1)/B(1)$.

第 3 步:对于第 k 个未参加过聚类计算的样本数据对 $(x^k, y^k), k=2, 3, \dots$. 在上述建立的 RBF 网络中已有 M 个隐单元.再分别求出到这 M 个聚类中心的距离 $\|x^k - c_i\|, i=1, 2, \dots, M$, 设 $\|x^k - c_j\|$ 为这些距离中的最小距离,即 c_j 为 x^k 的最近邻聚类,则:

若 $\|x^k - c_j\| > \sigma$, 则 x^k 作为 1 个新聚类中心,增加 1 个隐单元,令 $c_{M+1} = x^k, M = M + 1, A(M) = y^k, B(M) = 1$, 保持 $A(i), B(i)$ 的值不变, $i=1, 2, \dots, M-1$. 该隐单元到输出层的权矢量为 $w_M = A(M)/B(M)$.

若 $\|x^k - c_j\| \leq \sigma$, 则: $A(j) = A(j) + y^k, B(j) = B(j) + 1$. 当 $i \neq j$ 时, $i=1, 2, \dots, M$, 且保持 $A(i), B(i)$ 的值不变. 权矢量为 $w_i = A(i)/B(i), i=1, 2, \dots, M$.

第 4 步:通过以上的最近邻聚类,得到了一系列聚类中心 c_M . 则网络输出为

$$f(x^k) = \frac{\sum_{i=1}^M w_i \exp(-\|x^k - c_i\|^2 / \sigma^2)}{\sum_{i=1}^M \exp(-\|x^k - c_i\|^2 / \sigma^2)} \quad (3)$$

宽度 σ 的大小决定了动态自适应 RBF 网络的复杂程度. 由于 σ 是一个一维参数,通常可以通过实验和误差信息找到一个适当的值,这比同时确定隐单元的数量和一个合适的范数要方便得多. 每一个输入输出数据对都有可能产生一个新的聚类,因此,这种动态自适应 RBF 网络,实际上同时在进行参数和结构两方面的自适应调整. 当此 NNCA-RBF 网络结构确定之后,便能根据历史数据利用较小的网络结构进行预测,得到较好的预测精度.

3.2 ARIMA 子模型^[7]

按时间顺序排列的观测值的集合称为时间序列. 它最主要的特征就是承认观测值之间的依赖关系和相关性,它是一种动态模型,能够应用于动态预测. ARIMA 模型是由博克斯 (Box) 和詹金斯 (Jenkins) 于 70 年代初提出的时间序列预测方法. ARIMA(p, d, q) 称为差分自回归移动平均模型,AR 是自回归, p 为自回归项;MA 为移动平均, q 为移动平均项数, d 为时间序列成为平稳时所做的差分次数. ARIMA 模型的基本思想是:将预测对象随时间推移而形成的数据序列视为一个随机序列,用一定的数学模型来近似描述这个序列. 这个模型一旦被识别后就可以从时间序列的过去值及现在值来预测未来值.

4 模型的仿真实验

笔者采用短时交通流量预测来对组合预测模型进行仿真实验. 短时交通流量预测一般认为是预测时间跨度不超过 15 min 的预测,用于交叉路口信号优化、交通控制、诱导等. 但是短期交通流预测一直是一个比较活跃但结果却不令人满意的研究领域^[8]. 常见的预测方法有基于统计方法的预测、灰度预测、人工神经网络预测等^[9-12].

通过前期在长沙市交通指挥中心进行的车流量调查,并折算成标准小客车当量(PCU). 条形图 2 描述的是 2008 年 3 月 11 日 6:00 至 19:00 点长沙市五一东路某路段每 10 min 的交通流量,共采集了 72 个数据. 模型仿真实验过程如下:

首先,用前 51 个数据来训练建立两个单项预测子模型. 并各自预测随后的 21 个数据. 并按预测时间一一对应组成 21 组数据,每组的 2 个预测值各来自于一个子模型.

其次,用单项预测子模型的前 15 组预测值作为输入样本,实际值作为输出样本来训练组合预测模型,并达到期望误差.

最后,用单项预测子模型的最后 6 组预测值

作为训练后网络输入,得到组合预测模型的预测值,并把各自的预测值与实际值进行分析比较.

表 1 是 3 种预测模型对交通流量的预测结果以及实际流量. 通过比较不难发现,从预测结果与实际值的贴近程度看,组合预测模型整体上优于另外两种模型,在预测精度上也优于其他两种预测模型,预测误差对于交通流量的短时预测是可以接受的.




图 2 交通流量曲线
Fig. 2 The traffic flow curve

表 1 路口交通流量历史数据及相应模型的预测值

Tab. 1 Historical data of the traffic flow and prediction results of three forecast models

序号	实际值 /辆	组合预 测/辆	绝对误 差/辆	相对误 差/%	NNCA-RBF /辆	绝对误 差/辆	相对误 差/%	ARIMA /辆	绝对误 差/辆	相对误 差/%
1	126.96	127.39	-0.43	-0.34	118.51	8.45	6.67	119.57	7.39	5.82
2	127.18	123.54	3.64	2.86	117.29	9.89	7.78	115.65	11.53	9.07
3	121.49	119.10	2.39	1.97	113.44	8.05	6.63	112.56	8.93	7.35
4	122.35	122.12	0.23	0.19	119.23	3.12	2.55	113.54	8.81	7.20
5	139.22	136.38	2.84	2.04	135.36	3.86	2.77	144.65	-5.43	-3.90
6	125.73	125.43	0.30	-0.24	127.90	-2.17	-1.73	115.64	10.09	8.03

因此,应用该组合预测模型能够实现交通流量在线、实时、不间断的短时预测. 据此做成短时交通流预测模块,为十字路口交通信号的控制模型提供了可靠有益的数据,能够实现道路交叉口信号灯的智能控制,大大提高了车辆通过率,减少了车辆在交叉路口的延误.

5 结束语

笔者提出了一种基于 RBF 网络的非线性组合预测模型,该模型综合了 NNCA-RBF 和 ARIMA 两种预测子模型的预测值. 并且进行了道路交通流量的预测实验,与单项预测模型相比的结果表

明,组合预测模型有较高的精度. 但是,基于 RBF 神经网络的非线性组合预测模型还存在一些需要注意的问题:

- (1)组合预测模型成功的关键在于前期子模型的选取.
- (2)采用的子模型并非越多越好.
- (3)调试过程中发现,过多历史数据的使用反而会导致预测精度大为降低.

由于影响非线性系统的外在因素很多,在以后的工作中,还要在该方法的基础上附加一定的定性分析,以弥补完全数据分析的不足. 并且可以考虑用预测精度更高的前期预测子模型,来提高

组合预测的精度。

参考文献:

- [1] BATES J M, GRANGER C W J. Combination of forecasts [J]. Operations Research Quarterly, 1969, 20 (4): 319 - 325.
- [2] 于晓秋, 葛家麒, 刘长海. 组合预测方法在黑龙江垦区大豆产量预测中的应用[J]. 数学的实践与认识, 2007, 37 (24): 27 - 31.
- [3] 臧淑英, 梁欣, 冯仲科. 变权组合预测模型的建立及其在区域生态风险预测中的应用[J]. 北京林业大学学报, 2007, 29 (增刊2): 203 - 208.
- [4] 李国柱, 王亚鸽, 杨金伟. 我国居民消费的组合预测模型[J]. 当代经济管理, 2007, 29 (6): 7 - 10.
- [5] 文新辉, 牛明洁. 一种基于神经网络的非线性组合预测方法[J]. 系统工程理论与实践, 1994 (12): 66 - 72.
- [6] 殷勇, 邱明. 一种基于高斯核的 RBF 神经网络学习算法[J]. 计算机工程与应用, 2002, 38 (21): 118 - 119.
- [7] 姚亚夫, 曹锋. 基于 ARIMA 的交通流量短时预测[J]. 交通科技与经济, 2006, (3): 105 - 107.
- [8] DAVIS G A, NIHAN N L. Nonparametric regression and short term freeway traffic forecasting [J]. Journal of Transportation Engineering, 1991, 117 (2): 178 - 188.
- [9] 郭彬生, 刘伟铭, 姜山. 基于遗传神经网络的道路交通量预测[J]. 广西交通科技, 2003, 28 (2): 24 - 26.
- [10] 刘静, 关伟. 交通预测方法综述[J]. 公路交通科技, 2004, 21 (3): 82 - 85.
- [11] 胡洁. BP 和 RBF 神经网络短时交通流预测结果比较[J]. 长江大学学报: 自然科学版, 2007, 4 (3): 74 - 75.
- [12] 马寿峰, 贺国光, 刘豹. 智能交通系统中短时交通流预测系统的研究[J]. 预测, 2004, 23 (2): 28 - 34.
- [13] 王海龙, 孟令启, 马金亮, 等. 基于 RBF 神经网络的热轧碳钢变形抗力预测[J]. 郑州大学学报: 理学版, 2007, 39 (3): 131 - 135.

Combined Forecasting Model Based on RBF Neural Network

YAO Ya - fu, PENG Hao

(College of Electromechanical Engineering, Central South University, Changsha 410083, China)

Abstract: Forecasting models are established by using radial basis function (RBF) neural network based on nearest neighbor clustering algorithm (NNCA) and autoregressive integrated moving average (ARIMA). Then the two individual predictions are mixed by the RBF neural network and the result is the final prediction. The simulation results show that it works well in the prediction of a Changsha road's traffic flow. The prediction of the combined forecasting model is precise.

Key words: combined forecasting model; nearest neighbor clustering algorithm; radial basis function; neural network; traffic flow