

文章编号: 1001-0920(2006)05-0589-04

基于小波神经网络的电梯交通流预测

黄敏¹, 崔宝同¹, 顾树生²

(1. 江南大学 控制科学与工程研究中心, 江苏 无锡 214122; 2 东北大学 信息科学与工程学院, 沈阳 110004)

摘要: 小波神经网络随着输入维数的增加, 网络参数将呈指数倍增加, 导致收敛速度下降。在研究统计学理论的基础上, 提出了以结构风险最小化为目标的训练方法。该方法最大限度地保证了网络的泛化能力。将该网络应用于电梯交通流的预测, 得到了比传统BP神经网络更优的效果。

关键词: 小波神经网络; 统计学习理论; 结构风险最小化; 电梯交通流

中图分类号: TP183

文献标识码: A

Elevator Traffic Flow Prediction Based on Wavelet Neural Networks

HUANG Min¹, CUI Baotong¹, GU Shusheng²

(1. Control Science and Engineering Research Center, Southern Yangtze University, Wuxi 214122, China;

2 College of Information Science and Engineering, Northeastern University, Shenyang 110004, China

Correspondent: HUANG Min, E-mail: huangmzqb@163.com)

Abstract: The number of parameters of wavelet neural networks (WNN) increases by exponential form with input dimension and the convergence speed decreases. An algorithm is presented through using structural risk minimization (SRM) based on statistical learning theory. The novel algorithm can ensure great probability for global optimization. WNN based on SRM is also used to solve the problem of traffic flow prediction of elevator system, more optimal results than typical BP network are obtained.

Key words: Wavelet neural networks; Statistical learning theory; Structural risk minimization; Elevator traffic flow

1 引言

电梯是现代高楼中不可缺少的垂直代步设备, 其重要性已与平面交通中的汽车相同。研究高效的电梯群控系统越来越受到国际电梯界的重视。交通流预测是电梯控制系统的重要组成部分, 对交通流进行预测可使控制系统跟随交通流的变化调节控制策略。而由于电梯交通流具有高度的复杂性、随机性和较强的非线性, 使其很难有特定的函数表达形式, 因此对电梯系统交通流预测的研究是一项有意义的工作^[1-4]。其中, 灰色模型和神经网络模型^[5]用于时间序列的预测发展最快。但研究表明, 灰色模型较适合于“指数增长型”的时间序列; 而传统的神经网络

方法往往因难以科学地确定其网络的结构且学习训练参数易陷入局部极小, 而影响预测的精度和可靠性。

小波神经网络 (WNN)^[6]是建立在小波分析理论基础上的—种新型神经网络。由于其兼容了小波分析与神经网络的优点, 因此它具有以下特点:

WNN的基元和整个结构是依据小波分析理论确定的, 可以避免BP、RBF网络等结构设计上的盲目性;

由于小波神经网络学习时调整参数少, 加之小波基函数具有紧支性, 神经元之间的相互影响小, 因此学习速度快; 由于小波神经网络的学习过程是对一个凸问题的优化逼近过程, 所以能够最终找到—

收稿日期: 2005-02-23; 修回日期: 2005-06-20

基金项目: 国家自然科学基金项目 (60274024)。

作者简介: 黄敏 (1974—), 女, 辽宁铁岭人, 讲师, 博士, 从事小波分析、神经网络等研究; 崔宝同 (1960—), 男, 山东淄博人, 教授, 博士生导师, 从事小波分析、滑动模控制等研究。

个全局的最优解,不存在局部最小点,因此在非线性函数逼近等方面得到了广泛的应用

本文应用WNN来建立电梯交通流的预测模型,并运用统计学习理论中的结构风险最小化原则来训练网络,得到了比传统预测方法更优的预测效果

2 交通流预测模型

2.1 交通流时间序列

根据对某类办公大楼电梯系统交通流长期历史数据的分析可知,工作日的交通模式十分相似且重复出现,大约90%的交通流密度变化可解释为周期变化^[1]。由于预测周期短,所以可采用时间序列预测方法对交通流进行预测。交通流是指由乘客数、乘客出现的周期及乘客分布情况来描述的状态量,可以采用单位时间间隔内进入门厅人数、离开门厅人数、建筑物内总的客流量、层间客流最大层的比例以及层间客流次大层的比例来表示^[4]。按照一定的统计方法采集一天中每个时间间隔的交通流数据构成交通流时间序列,便可将时间序列的预测理论应用到交通流预测中。即根据序列 $\{x(t_i)\}$ 的历史观测值 $x(t_i-1), x(t_i-2), \dots, x(t_i-m)$ 建立预测模型,对未来时刻 t_i+k (k 为正整数)时的值 $x(t_i+k)$ 进行预测^[4]。

2.2 小波神经网络

考虑采用基于小波框架的小波神经网络,这是因为它的数学理论概念清楚,实现方便,应用较广。而基于连续小波变换建立的WNN基函数的定位不局限于有限的离散值,展开式不唯一,冗余度高,不容易实现;基于正交小波变换建立的WNN网络学习算法较复杂,网络抗干扰能力较差

考虑到函数 $f(x)$ 在时频空间的分布区域,实际只需要在无穷的小波框架中选取有限个小波基函数就可以较精确地逼近原函数 $f(x)$,同时为了能在有限区域内处理非零均值函数,因此离散小波神经网络可写为

$$\hat{f}(x) = \sum_{i=1}^L w_i \psi_i(x) + \hat{f}. \quad (1)$$

2.3 基于小波神经网络的预测模型

采用离散小波神经网络建立的交通流预测模型如图1所示

模型采用3层的小波神经网络,输入层节点为“全通”节点,其输出即为 x ,由同一天中前 k 个时间段内的交通量和 p 个工作日内同一个时间段内的交通量两部分组成。系数58(40+18)表示每个工作日数据采集的次数,18表示高峰模式的数据采集次数,即对高峰模式(上高峰、下高峰)采用5min作为




图1 基于小波神经网络的交通流预测模型

采样周期40表示工作时交通模式和空闲交通模式的数据采集次数,对工作交通模式和空闲交通模式采用15min作为采样周期,因为此时的交通流密度要小于高峰模式的交通流密度。隐含层单元的非线性函数采用张量积形式的小波基函数

$$\psi(x) = x \cdot 1x \cdot 2e^{-\frac{x_1^2 + x_2^2}{2}}$$

单元的个数由自适应算法来确定。输出层由一个线性单元构成,表示下一时间间隔内交通流的预测值

3 基于统计学习理论的网络优化算法

对于高维小波神经网络来说,其训练是一个相当麻烦的问题。一方面随着输入维数的增加,小波神经元的个数和网络权值的数目将呈指数倍增加;另一方面,在高维的情况下,无法得到足够的学习数据来完成高维小波神经网络的训练。统计学习理论为解决有限样本学习问题提供了一个统一的框架,其核心概念是VC维。依据该理论,学习机器的实际风险由经验风险(训练误差)和置信范围两部分组成,即

$$R(a) = R_{\text{emp}}(a) + \Phi_p/h. \quad (2)$$

式中: $R_{\text{emp}}(a)$ 为经验风险, Φ 为置信范围, h 为VC维, p 为训练样本数, Φ 随 p/h 的增大而减小。对于一个特定的学习问题,当样本数 p 固定时,如果 h 越高,则 Φ 越大,从而导致实际风险与经验风险之间的差就越大。因此,在学习时,要使经验风险和置信范围都尽可能的小,从而使期望风险最小,这就是结构风险最小化原则(SRM)。

根据统计学习理论,下式中的风险上界以概率 $1-\eta$ 成立:

$$R \leq \left[\frac{R_{\text{emp}}}{1 - c \sqrt{\frac{h(\ln(an/h) + 1) - \ln \eta}{n}}} \right]_+ \quad (3)$$

式中: R 为实际风险; R_{emp} 为经验风险; h 为VC维; c 和 a 为常数; η 为一个小的正数,用以定义风险上界成立的概率。操作符 $(\cdot)_+$ 表示

$$(x)_+ = \begin{cases} x, & x > 0, \\ 0, & x \leq 0 \end{cases}$$

采用结构风险最小化的原则来优化网络,就是根据预先设定的函数集嵌套结构,通过最小化式(3)的风险上界来优化选择函数集 具体步骤如下:

1) 函数集合的确定

由采集到的交通流数据构成 n 组输入、输出数据对作为训练样本集,根据小波时频局部特性确定时频定位中心和其有效的时频支撑区间,并根据样本数据的最大观测范围和奈奎斯特采样定理求得尺度范围 在每个尺度范围内,选取对逼近有作用的小波基,从而得到有限小波框架集 $B_\tau = \{\psi_1, \psi_2, \dots, \psi_L\}$.

2) 函数嵌套的安排

函数嵌套的安排是利用结构风险最小化原则优化网络时需要解决的一个重要问题 通常都是依据基函数对逼近函数的重要程度来安排嵌套结构 根据 Parseval 能量积分等式和连续小波变换,可以认为 $|W T_f(a, b)|^2$ 具有能量单位,它能衡量每个小波基函数 $\psi_{a,b}$ 对 $f(x)$ 重构的贡献大小^[7]. 同样,离散小波 $\psi_{j,k}$ 的小波变换 $|W T_f(j, k)|^2$ 的大小也表示了其在网络中的重要性,其值越大,说明该基函数在网络中的地位越重要,因此,可依据这条原则安排小波基函数嵌套 将 $|W T_f(j, k)|^2$ 用单变量 W_k 表示,即对应于 $B_\epsilon = \{\psi_1, \psi_2, \dots, \psi_L\}$ 的 W_1, W_2, \dots, W_L 有下列关系:

$$W_1 \quad W_2 \quad \dots \quad W_L \quad (4)$$

根据这个排序方式,在设计嵌套时,对于相邻的子集,使得前一个子集完全被后一个子集所包含,且满足 VC 维按照从小到大顺序排列

3) VC 维的计算

设 $B_\epsilon = \{\psi_1, \psi_2, \dots, \psi_L\}$ 为重新排列后的小波基函数集合 对于离散小波网络,可定义下列向量 v_j :

$$v_j = \begin{bmatrix} \psi_j(x_1) \\ \vdots \\ \psi_j(x_n) \end{bmatrix}, \quad (5)$$

其中 $\psi_j \in B_\epsilon, j = 1, \dots, L$.

设 $V = [v_1, v_2, \dots, v_L]$, 则由 $\psi_j \in B_\epsilon$ 构成的嵌套结构就转变为 $V = [v_1, v_2, \dots, v_L]$ 构成的嵌套结构 对 ψ_j 的选择就转变为选择 v_j , 使得结构风险最小 而 v_j 可以进行正交归一化处理,从而转变为线性情况 对于包含 k 个 v_j 向量的函数集,其 VC 维是 $k + 1$.

4) 网络训练

网络的训练就是不断增加网络隐含层节点,训练权值,并计算实际风险误差(3)的过程 如果实际风险误差小于达到规定的要求,则停止增加网络节点 权值的训练可采用梯度下降算法或正交最小二乘法 考虑到实际训练过程中只需要训练权值,故正

交最小二乘法的训练效率较高

4 仿真研究

4.1 样本数据处理

从某办公大厦采集了 40 天的交通流数据,取 30 天交通流数据作为小波神经网络的学习样本,10 天的数据作为测试样本,对训练好的网络模型进行测试 采用 Matlab 软件进行仿真

4.2 小波神经网络模型优化结果

交通流预测模型采用一个输入层、一个隐含层和一个输出层的 WNN 结构 经初始化学习确定 $k = 6, p = 5$, 即输入层单元为 11 个,输出层单元为一个 利用历史数据中的学习样本对模型进行学习训练,模型优化后的隐层单元数为 32 个,所以最佳模型结构为 11-32-1.

4.3 仿真结果

对采集的历史数据进行分析,发现该大厦内无明显的最大客流层和次大客流层,因此只对一天中时间段内进门厅人数、出门厅人数和总客流量进行




图 2 实际进门厅人数




图 3 实际出门厅人数




图 4 实际总客流量

预测 为了对比,同时采用了指数平滑法(ES)进行预测,仿真结果如图2~图4所示

从图中可以看出,本文建立的交通流预测模型具有很强的泛化能力,其预报结果明显优于指数平滑法的预报结果 表1给出了各种交通模式在各个时间段所占比例的情况

表1 交通模式在各个时间段内所占的比例

时间段	交通模式			
	上高峰 交通 /%	下高峰 交通 /%	层间交 通 /%	空闲交 通 /%
7:00 ~ 7:40	2	1.2	1.5	95.3
7:40 ~ 8:00	98.1	0.5	1	0.4
8:00 ~ 11:30	7.3	4.4	87.6	0.7
11:30 ~ 12:00	0.6	97.6	1.4	0.4
12:00 ~ 13:10	4.1	3	2.8	90.1
13:10 ~ 13:30	97.8	0.4	1.6	0.2
13:30 ~ 17:00	6.2	4.2	89.1	0.5
17:00 ~ 17:40	2.1	91.7	4.8	1.4
17:40 ~ 18:30	0.3	1.2	0.8	97.7

为了与传统的BP神经网络作比较,采用均方根误差来评价预测的精度^[4]

$$e_n = \sqrt{\frac{1}{N} \sum_{i=1}^N (f_i - \hat{f}_{di})^2} \quad (6)$$

其中: e_n 为网络的均方根误差, \hat{f}_i 为网络的第 i 个预测值, f_{di} 为序列的第 i 个实际值, N 为序列的总数 两种网络预测模型的预测精度如表2所示

表2 WNN 预测模型与 BP 网络预测模型的预测精度比较

	进门厅人数 预测误差	出门厅人数 预测误差	总客流人数 预测误差
WNN 预测模型	$e_n = 5.73$	$e_n = 6.02$	$e_n = 7.82$
BP 网络预测模型	$e_n = 6.61$	$e_n = 7.94$	$e_n = 9.35$

由表2可知,基于小波神经网络的预测模型的预测精度高于神经网络的预测精度 这是因为本文对小波神经网络所采用的训练算法同时考虑了网络的复杂度和网络的经验误差,从而使得网络具有良好的泛化能力

5 结 语

本文在研究统计学习理论的基础上,提出了以结构风险最小化为目标的多维小波神经网络训练方

法,并应用于电梯交通流的预测,得到了比传统的BP神经网络更优的预测精度

本文建立的交通流预测模型在应用于实际系统时,要进行周期性的学习,即对每个工作日预测效果进行评价 当预测误差超出允许范围时,在选取训练样本的同时应修改网络的参数 本模型只适用于办公大厦工作日的情况,对于节假日或其他类型的建筑物(如商场),则应根据不同的交通环境调整模型的输入量

参考文献(References)

- [1] Siikonen M L. *Elevator Group Control with Artificial Intelligence* [R]. Helsinki: Helsinki University of Technology, 1997.
- [2] 李中华,毛宗源,邬依林. 一种新的基于模糊控制的电梯群控策略[J]. *控制与决策*, 2004, 19(8): 857-861.
(Li Z H, Mao Z Y, Wu Y L. A Novel Strategy for Elevator Group Supervisory Control Based on Fuzzy Control [J]. *Control and Decision*, 2004, 19(8): 857-861.)
- [3] 宗群,童玲,薛丽华. 电梯群控系统智能优化调度方法的研究[J]. *控制与决策*, 2004, 19(8): 939-942.
(Zong Q, Tong L, Xue L H. Research on Intelligent Optimal Dispatching Method in Elevator Group Control Systems [J]. *Control and Decision*, 2004, 19(8): 939-942.)
- [4] 宗群,岳有军. 电梯群控系统交通流的预测方法[J]. *系统工程与电子技术*, 2001, 23(7): 103-105.
(Zong Q, Yue Y J. A Traffic Flow Forecasting Method of Elevator Group Control System [J]. *System Engineering and Electronics*, 2001, 23(7): 103-105.)
- [5] 卢学强. 神经网络方法及其在非线性时间序列预测中的应用[J]. *系统理论与实践*, 1997, 17(6): 97-99.
(Lu X Q. Neural Network and Its Application to Prediction of Nonlinear Time Sequence [J]. *System Engineering Theory and Practice*, 1997, 17(6): 97-99.)
- [6] Delyon B, Judilsky A, Benvenisie A. Accuracy Analysis for Wavelet Approximations [J]. *IEEE Trans on Neural Network*, 1995, 6(2): 332-348.
- [7] 丁宇新,沈雪勤. 基于能量密度的小波神经网络[J]. *计算机学报*, 1997, 20(9): 832-838.
(Ding Y X, Shen X Q. Wavelet Neural Network Based on Energy Density [J]. *Chinese J Computers*, 1997, 20(9): 832-838.)