第 26 卷第 12 期
2009 年 12 月

控 制 理 论 与 应 用
Control Theory & Applications

Vol. 26 No. 12
Dec. 2009

文章编号: 1000−8152(2009)12−1358−07

电梯交通需求的显著性评价及未知分布的交通需求预测

杨祯山[1], 邵　诚[2], 马海丰[2]

(1. 渤海大学 信息科学与工程学院, 辽宁 锦州 121013; 2. 大连理工大学 先进控制技术研究所, 辽宁 大连 116024)

摘要: 有效的交通需求预测是电梯交通模式识别的一个重要前提, 而传统的交通需求预测建模往往依赖于交通需求的分布. 本文定义了交通需求的显著性评价指标$x^{ev}_{n\alpha}$及φ_0–显著, 并基于上述指标给出了关于交通需求分布显著水平的一种评价方式; 在此基础上, 研究了在不服从Poisson 分布且交通需求显著时的一种交通需求预测方法. 仿真实验表明了该方法的有效性.

关键词: 电梯交通需求; 显著性指标; 置信区间; 预测方法; 支持向量机

中图分类号: TP273　　　**文献标识码**: A

Significance-evaluation and forecasting for elevator traffic-demand under unknown distribution

YANG Zhen-shan[1], SHAO Cheng[2] , MA Hai-feng[2]

(1. College of Information Science and Engineering, Bohai University, Jinzhou Liaoning 121013, China;
2. Institute of Advanced Control Technology, Dalian University of Technology, Dalian Liaoning 116024, China)

Abstract: The efficient forecasting of the elevator traffic demand is essential to the pattern recognition of the elevator traffic. The classical traffic demand forecasting generally depends on the specific traffic demand distribution. We define the significance-evaluation indices $x^{ev}_{n\alpha}$ and φ_0, and present the distribution of the significance-evaluation mode of elevator traffic in terms of those evaluation indices. On that basis, an elevator traffic demand forecasting method under strong significance and non-Poisson distribution is developed. Simulation experiments show the validity of the proposed method.

Key words: elevator traffic demand; significance evaluation indices; confidence interval; forecasting method; support vector machine

1 引言(Introduction)

电梯交通需求预测效果的好坏直接影响交通模式识别准确性与合理性, 进而影响电梯群控系统的优化调度[1,2]. 通常电梯交通需求预测方法的前提是假定交通需求满足Poisson分布[3], 因而使得预测效果不稳定, 有时结果误差较大. 原因是交通需求具有很大的不确定性, 并且往往不满足Poisson分布. 研究表明[4]: 在总体满足Poisson分布且交通需求显著性水平比较高的观测样本上, 多数模型表现出较好的预测效果. 这说明采用的预测方法在一定程度上依赖于观测样本的分布状态. 因此, 判别交通需求的样本是否服从Poisson分布或近似服从Poisson分布就显得非常重要. 对于不服从Poisson分布的交通需求, 如何建立预测效果较好的模型是一个具有重要意义的研究课题. 本文主要引入两个显著性评价指标$x^{ev}_{n\alpha}$及φ_0–显著, 判别交通需求的显著性水平以及是否服从Poisson分布或近似服从Poisson分布. 其意义在于交通需求显著性水平反映客流的规律性, 通过判别交通需求的显著水平, 可有效地选择和调整电梯交通需求的预测方法, 为交通模式的有效识别提供准确的交通预测信息[5,6]. 例如, 若确知某时段交通需求显著性水平较高, 则可依据所得到的交通特征, 选择合适的交通需求预测方法, 并依此进行交通模式识别, 依据模式识别的结果, 设计相应的电梯群的调度策略[7,8]; 相反, 若发现某时段交通需求几乎无规律可循, 因为客流没有明显特征, 便难以找到有效的预测方法, 此时, 电梯群一般采用自主运行方式. 基于此, 文章针对电梯交通需求的特点, 对其进行显著性评价, 对于交通需求不服从Poisson分布的情况, 给出一种不依赖于分布规律的小样本建模预

收稿日期:2008−05−21; 收修改稿日期: 2009−03−06.
基金项目: 国家重点基础研究发展计划973项目(2007CD714006);国家科技攻关计划项目(2001BA204B01);国家自然科学基金项目(69874026).

测方法.

2 电梯交通需求显著性分析(Analysis of elevator traffic demand significance)

经典的电梯交通理论认为[3,9,10], 单位时间内到达电梯前厅的乘客数近似服从Poisson分布. 但是并非所有情况都如此, 正如BARNEY G C 所说[11]: "乘客到达按照泊松过程这一假设没有经过证实, 需要在各类电梯系统中进行广泛的数据积累". 这表明了对交通需求显著性进行分析的重要性. 我们知道, Poisson分布的一个重要特征是均值$\overline{X}$等于方差S^2. 那么, 就可以基于交通观测数据的这两个数字特征初步判别乘客到达模式是否符合Poisson分布. 即, 若给定一小的正数ε, 使得$|\overline{X}-S^2|\leqslant\varepsilon$, 则从工程应用的角度, 就可以认为其近似服从Poisson分布. 以下分2种情况进行讨论, 在置信度给定的前提下, 求解$[t, t+\Delta t)$时间段内到达乘客数的置信区间, 并基于置信区间构造判别交通需求显著性水平的指标.

2.1 基于Poisson分布的μ置信区间估计(Confidence interval estimation of μ based on Poisson distribution)

设$I_k=[t_k, t_{k+1}+\Delta t)$是电梯交通需求的观测区间, $T_{nk}=\{x_{1k}, x_{2k}, \cdots, x_{nk}\}$是由前$n$个周期第$k$个时间段$I_k$内随机到达的乘客数构成的观测数据集. 在Poisson到达模式中, 时间段I_k内到达的乘客数目可以看作随机变量, 若Δt给定, 则发生m个乘客到达的概率服从参数为$\mu=\lambda\Delta t$的Poisson分布[12,13]. 即

$$\mathrm{P}\{X=M(t+\Delta t)-M(t)=m\}=\frac{\mu^m}{m!}\mathrm{e}^{-\mu}. \quad (1)$$

上式中$m=0,1,2,\cdots, M(t)$为t时刻到达的乘客数; λ为Δt时间内平均到达的乘客数, 即平均到达率, μ为Δt时间内到达乘客的均值. 由Poisson分布的性质有: $\mathrm{E}X=\mathrm{D}X=\mu=\lambda\Delta t$. 因此, 确定参数$\lambda$等价于确定$\mathrm{E}X, \mathrm{D}X$.

假设 1　不同周期的$(t, t+\Delta t]$时间段内到达乘客数服从独立同分布, 且均为Poisson分布;

假设 2　将所有周期的同一时段$[t, t+\Delta t)$内到达的人数看成一个总体X, 且满足$X\sim P(\mu)$, 即

$$\mathrm{P}\{X=m\}=\frac{\mu^m}{m!}\mathrm{e}^{-\mu}. \quad (2)$$

假设 3　前n个周期第k个时间段$[t_k, t_k+\Delta t)$内的乘客人数, 构成总体X的一个容量为n的样本, 记为$\{x_{1k}, x_{2k}, \cdots, x_{nk}\}$.

由上述假设, 采用矩法估计, 可得

$$\mathrm{E}\hat{X}_k=\hat{\lambda}_k\Delta t=\hat{\mu}=\overline{X}_k=\frac{1}{n}\sum_{i=1}^{n}x_{ik}. \quad (3)$$

命题 1　若$X\sim P(\mu)$, 则有如下关系式成立:

$$\lim_{n\to\infty}\mathrm{P}\{\hat{\mu}+\frac{\varepsilon^2}{2n}-\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}}\leqslant\mu\leqslant \hat{\mu}+\frac{\varepsilon^2}{2n}+\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}}\}=2\Phi(\varepsilon)-1. \quad (4)$$

其中$\hat{\mu}=\overline{X}$. 由命题1可得到如下推论:

推论 1　当n充分大时

$$\mathrm{P}\{\hat{\mu}+\frac{\varepsilon^2}{2n}-\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}}\leqslant\mu\leqslant \hat{\mu}+\frac{\varepsilon^2}{2n}+\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}}\}\approx2\Phi(\varepsilon)-1. \quad (5)$$

由上述推论知: 若给定置信度为$2\Phi(\varepsilon)-1$, 便可以得到μ的置信区间的估计. 不妨令μ的置信区间为$[a_p, b_p]$, 则

$$[a_p, b_p]= [\overline{x}+\frac{\varepsilon^2}{n}-\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}}, \overline{x}+\frac{\varepsilon^2}{n}+\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}}]. \quad (6)$$

2.2 分布未知前提下μ置信区间估计(Confidence interval estimation of μ based on unknown distribution)

命题 2　令

$$\mathrm{E}X=\mu,\ \mathrm{D}X=\sigma^2,\ \overline{X}=\frac{1}{n}\sum_{i=1}^{n}X_i,$$

$$S_n^2=\frac{1}{n-1}\sum_{i=1}^{n}(X_i-\overline{X})^2,\ \lim_{n\to\infty}\sqrt{S_n^2}=\sigma.$$

则有:

1)

$$\Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}})=\Phi(\frac{\sqrt{n}\varepsilon}{\sigma})-\frac{1}{\sqrt{2\pi}}\mathrm{e}^{-\frac{n\varepsilon^2}{2S_n^2}}\times\frac{\sqrt{n}\varepsilon}{S_n^2}(\sqrt{S_n^2}-\sigma)+ \mathrm{o}(|\sqrt{S_n^2}-\sigma|), \quad (7)$$

且

$$|\Phi(\frac{\sqrt{n}\varepsilon}{\sigma})-\Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}})|\leqslant \frac{2}{\sqrt{2\pi n\varepsilon e}}|(\sqrt{S_n^2}-\sigma)|\to0,\ n\to\infty. \quad (8)$$

2)

$$\mathrm{P}\{|\hat{\mu}-\mu|\leqslant\varepsilon\}\approx2\Phi(\frac{\sqrt{n}\varepsilon}{\sigma})-1,\ n\text{充分大}. \quad (9)$$

这里$\hat{\mu}=\overline{X}$, 式(9)表明若给定置信度为$2\Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}})-1$, 则可以得到$\mu$的置信区间的估计. 不

妨令μ的置信区间为$[a_u, b_u]$, 则$[a_u, b_u] = \{\overline{x}-\varepsilon, \overline{x}+\varepsilon\}$, 这里$\overline{x}$为$\overline{X}$的观测值.

2.3 构造电梯交通需求分布的显著性指标(Construction of significance evaluation indices of elevator traffic demand)

对于实际的工程问题, 往往不知道总体的分布信息, 但能知道来自总体的样本信息. 于是可以针对已知样本构造一个指标, 判别该样本交通需求显著性水平, 并基于这些显著性指标指导预测建模.

1) 定义显著性评价系数$x_{n\alpha}^{ev}$及φ_0-显著.

定义 1 已知样本$\{x_i|i = 1, 2, \cdots, n\}$, $\overline{x} = \frac{1}{n}\sum\limits_{i=1}^{n} x_i$, $[a_p^\alpha, b_p^\alpha]$, $[a_u^\alpha, b_u^\alpha]$分别是已知Poisson分布和未知分布时置信度为$(1-\alpha)$的$\overline{x}$置信区间.

令

$$x_{n\alpha}^{ev} = \max\{\frac{\overline{x}}{b_p^\alpha - a_p^\alpha}, \frac{\overline{x}}{b_u^\alpha - a_u^\alpha}\}, \tag{10}$$

则称$x_{n\alpha}^{ev}$为样本$\{x_i|i = 1, 2, \cdots, n\}$在置信度为$(1-\alpha)$时的显著性评价系数, 这里, 参数$\alpha \in (0, 1]$.

定义 2 已知样本$\{x_i|i = 1, 2, \cdots, n\}$, 在置信度为$(1-\alpha)$时的显著性评价系数为$x_{n\alpha}^{ev}$, 若$x_{n\alpha}^{ev} \in [0, \varphi_0]$, 则称该样本为$\varphi_0$-不显著, 否则称为$\varphi_0$-显著. 这里, 参数$\varphi_0(>0)$为事先给定的一个阈值.

2) 阈值φ_0的意义及估计方法.

a) $x_{n\alpha}^{ev}$的意义.

当样本给定时, $\overline{x}$为已知常量. 因此$x_{n\alpha}^{ev}$与$b_{(\cdot)}^\alpha - a_{(\cdot)}^\alpha$成反比. 显然$b_{(\cdot)}^\alpha - a_{(\cdot)}^\alpha$越小, 样本波动越小, 交通需求越显著. 这说明$x_{n\alpha}^{ev}$的大小直接反映了样本显著性水平, 这里$[a_{(\cdot)}^\alpha, b_{(\cdot)}^\alpha]$为置信区间.

b) φ_0的工程意义及估计方法.

在工程应用意义上: φ_0越大, 相当于显著性判别的门槛越高. φ_0是与工程背景密切相关的约束参数. 具体地说, φ_0的取值由某一类建筑物的约定客流参数确定. 研究者基于大量的工程统计数据, 已经取得了为业界公认的约定客流参数, 其中CIBSE以业界标准的形式收录了这些数据[14]. 下面给出基于约定客流参数来估计φ_0值的一个方法.

前已述及, 具有某种共性的一类建筑物, 在交通需求分布未知的前提下有: $[a_u, b_u] = \{\overline{x}-\varepsilon, \overline{x}+\varepsilon\}$, 且满足:

$$\mathrm{P}\{|\hat{\mu} - \mu| \leqslant \varepsilon\} \approx 2\Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}}) - 1, n\text{充分大}.$$

这里$\hat{\mu} = \overline{X}$, $2\Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}}) - 1$为给定的置信度. 基于此, 设约定客流参数为$\lambda_5(\%)$, Q为电梯总使用基数[4]. 不妨取$\mathrm{E}X = Q \times \lambda_5$, 则:

令$\mathrm{E}X = \overline{x}$, 则有

$$\frac{\overline{x}}{b_{(\cdot)}^\alpha - a_{(\cdot)}^\alpha} \geqslant \frac{\mathrm{E}X}{2\varepsilon}. \tag{11}$$

因此, 可由$\frac{\mathrm{E}X}{2\varepsilon}$来估计$\varphi_0$. 不妨令

$$\varphi_0 = \frac{\mathrm{E}X}{2\varepsilon}. \tag{12}$$

这里ε满足: $2\Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}}) - 1 = 1 - \alpha$, α已知.

显然, φ_0的取值只依赖于一类具有共性的建筑物的约定客流参数.

2.4 第k个时间段I_k处的交通需求显著性评价(Significance evaluation of elevator traffic demand of I_k for the kth time slicing)

令第k个时段I_k处前n个周期的交通需求为$\{x_{ik}|i = 1, 2, \cdots, n\}$, 包括上行交通观测样本$\{x_{ik}^u|i = 1, 2, \cdots, n\}$, 和下行交通观测样本$\{x_{ik}^d|i = 1, 2, \cdots, n\}$(人/5min).

根据定义1, 该样本的显著性评价系数为$x_{n\alpha}^{ev}(k)$. 其中

$$\overline{x}_{nk} = \frac{1}{n}\sum_{i=1}^{n} x_{ik}.$$

其置信度为$(1-\alpha)$, 即$1-\alpha = 2\Phi(\cdot) - 1$, $\alpha = 2(1-\Phi(\cdot))$.

根据定义2, 若$x_{n\alpha}^{ev}(k) \in [0, \varphi_0]$, 则称该样本为$\varphi_0$-不显著, 否则称为$\varphi_0$-显著.

因此, 依据$x_{n\alpha}^{ev}(k)$和φ_0-显著(或φ_0-不显著)对上行与下行交通需求显著性水平做出评价, 并基于显著性水平选择合理的预测技术进行预测建模.

显然, 对任意时间段I_k, 利用观测数据集$\{x_{ik}|i = 1, 2, \cdots, n\}$可以求得数据集$T_n^{ev} = \{(I_k, x_{nk\alpha}^{ev})|k = 1, 2, \cdots, l\}$. 若给定阈值$\varphi_0$, 则可依据$T_n^{ev}$及$\varphi_0$给出预测模型的一个选择方案. 具体分析如下:

1) 若$x_{nk\alpha}^{ev} \in (\varphi_0, \infty)$, 且

$$x_{nk\alpha}^{ev} = \frac{\overline{x}}{b_{pk}^\alpha - a_{pk}^\alpha},$$

则认为在不同周期同一个时间段I_k上, 交通需求显著且可用某个恰当的Poisson分布对电梯交通需求进行预测;

2) 若$x_{nk\alpha}^{ev} \in (\varphi_0, \infty)$, 且

$$x_{nk\alpha}^{ev} = \frac{\overline{x}}{b_{uk}^\alpha - a_{uk}^\alpha},$$

则可认为在不同周期同一个时间段I_k上, 交通需求虽然显著性强, 但已不再服从Poisson分布, 这时应该选择不依赖于分布的预测建模方案;

3) 若$x_{nk\alpha}^{ev} \in [0, \varphi_0]$, 则说明在不同周期同一个时间段$I_k$上, 交通需求不显著, 通常的预测方法很难取得良好的效果. 研究表明, 在这种情况下采用灰色预测模型可以得到近似的预测结果, 详见文献[15,16].

综上所述, 就实际交通状况而言, 某一种交通模式可能是上述3种情况的集合. 就其中1)的情况而言, 用Poisson模型能得到在随机特征范围内较好的预测效果. 以下给出针对上述2)情况的交通需求预测建模方法.

3 建立不服从Poisson分布的交通需求预测模型(Modeling of the elevator traffic demand forecasting under non-Poisson distribution)

由于交通需求不服从Poisson分布, 因此选择不依赖分布的技术建立交通需求预测模型是十分重要的. 又因为交通需求具有小样本非线性特征, 于是考虑用小样本建模方法来建立预测模型. 20世纪90年代出现的支持向量机(support vector machine, SVM)技术正是不依赖分布的小样本建模方法, 它的基础是Vapnik创建的统计学习理论. 经过研究人员多年的不懈努力, 其技术已日趋成熟, 特别是基于最小二乘支持向量机(least square support vector machine, LS–SVM), 已经成为支持向量机应用领域的主流技术. 传统支持向量机的最优化问题要通过二次型求解. Suykens在标准支持向量机的目标函数中增加误差平方项, 提出了最小二乘支持向量机, 它是支持向量机的一种修正和扩展. LS–SVM 优化问题转化为求解线性方程组问题, 因具有运算简便、速度快、计算成本低的优点, 具有更好的使用性和推广性. 因此, 利用LS–SVM对电梯交通需求不服从Poisson分布的情况下, 进行预测建模不失为一种恰当的选择.

3.1 LS–SVM支持向量机回归原理(Principle of the least squares support vector machine regression)

LS–SVM是标准支持向量回归机的一种扩展[17], 其模型为:

$$\begin{aligned}&\min_{w,b,e} \frac{1}{2}w^{\mathrm{T}}w + \frac{C}{2}\sum_{i=1}^{l} e_i^2, C > 0,\\ &\text{s.t. } y_i = w^{\mathrm{T}}\varphi(x_i) + b + e_i, i = 1, 2, \cdots, l.\end{aligned} \tag{13}$$

其中: 训练样本$T = \{(x_1, y_1), (x_2, y_2), \cdots, (x_l, y_l)\} \in (X \times Y)^l$, l为样本总数, $x_i \in X = \mathbb{R}^n$, $y_i \in Y = \mathbb{R}$, n为空间的维数, C为正则化参数. 相应的Lagrange函数为

$$\begin{aligned}&L(w, b, \xi, \alpha) =\\ &\frac{1}{2}w^{\mathrm{T}}w + \frac{C}{2}\sum_{i=1}^{l} e_i^2 -\\ &\sum_{i=1}^{l} \alpha_i\{w^{\mathrm{T}}\varphi(x_i) + b + e_i - y_i\}.\end{aligned} \tag{14}$$

式中α为Lagrange乘子, 从而可知KKT条件为:

$$\begin{cases}\dfrac{\partial L}{\partial w} = 0 \Leftrightarrow w = \sum\limits_{i=1}^{l} \alpha_i\varphi(x_i),\\ \dfrac{\partial L}{\partial b} = 0 \Leftrightarrow \sum\limits_{i=1}^{l} \alpha_i = 0,\\ \dfrac{\partial L}{\partial e_i} = 0 \Leftrightarrow \alpha_i = Ce_i,\\ \dfrac{\partial L}{\partial \alpha_i} = 0 \Leftrightarrow w^{\mathrm{T}}\varphi(x_i) + b + e_i - y_i = 0,\\ i = 1, 2, \cdots, l.\end{cases} \tag{15}$$

上式可以表示成线性关系式:

$$\begin{bmatrix} 0 & \Theta^{\mathrm{T}} \\ \Theta & K + \dfrac{1}{C}\boldsymbol{I} \end{bmatrix} \begin{bmatrix} \boldsymbol{b} \\ \boldsymbol{a} \end{bmatrix} = \begin{bmatrix} 0 \\ \boldsymbol{Y} \end{bmatrix}. \tag{16}$$

其中 $\boldsymbol{Y} = [y_1, y_2, \cdots, y_l]^{\mathrm{T}}$, $\boldsymbol{a} = [\alpha_1, \alpha_2, \cdots, \alpha_l]^{\mathrm{T}}$, $\Theta = [1, 1, \cdots, 1]^{\mathrm{T}}$, $\boldsymbol{I}$为$l \times l$阶的单位矩阵. 这样, 原回归问题便可以通过最小二乘法求解, 所得回归函数为

$$y = \sum_{i=1}^{N} \alpha_i K(x_i, x) + b. \tag{17}$$

这里$K(x_i, x) = \varphi(x_i)^{\mathrm{T}}\varphi(x)$.

3.2 用LS–SVM建立交通需求预测模型(Modelling of the traffic demand forecasting using LS–SVM)

假设在时间段I_k上交通需求虽然很显著但不服从Poisson分布, 不妨令该时间段上已知一个训练集为: $\{(n_i, x_{ik})|i = 1, 2, \cdots, l\}$, 其中$n_i$为已知的周期序号, x_{ik}为第n_i个周期的I_k上对应的交通需求. 将上述训练集代入LS–SVM模型, 给出恰当的参数及核函数选取方法, 便得到预测函数

$$x_{nk} = \sum_{i=1}^{N} \alpha_i K(n_i, n) + b.$$

具体算法步骤如下:

1) 给定一个 $k(\in \{1, 2, \cdots, 144\})$, 确定训练集$\{(n_i, x_{ik})|i = 1, 2, \cdots, l\}$;

2) 选择参数 $C(>0)$ 及核函数

$$K(x', x) = \varphi(x')^{\mathrm{T}}\varphi(x);$$

3) 求解线性关系式

$$\begin{bmatrix} 0 & \Theta^{\mathrm T} \\ \Theta & K+\dfrac{1}{C}\boldsymbol I \end{bmatrix}\begin{bmatrix} \boldsymbol b \\ \boldsymbol a \end{bmatrix}=\begin{bmatrix} 0 \\ \boldsymbol Y \end{bmatrix},$$

得到解$\begin{bmatrix} \boldsymbol b^* \\ \boldsymbol a^* \end{bmatrix}$; 其中:

$$\boldsymbol Y=[x_{1k},x_{2k},\cdots,x_{lk}]^{\mathrm T},$$

$$\boldsymbol a=[\alpha_1,\alpha_2,\cdots,\alpha_l]^{\mathrm T},\ \Theta=[1,1,\cdots,1]^{\mathrm T},$$

$\boldsymbol I$ 为$l\times l$阶的单位矩阵.

4) 给出回归函数, 即获取交通需求预测模型

$$x_{nk}=\sum_{i=1}^{N}\alpha_i^*K(n_i,n)+b^*.$$

这里, LS–SVM常用的核函数有多项式核函数、RBF核函数和Sigmoid函数等. 其中RBF核函数当参数在有效范围内改变时, 空间复杂度变化小, 易于实现. 因此, 本文用于交通需求预测的LS–SVM采用RBF核函数$K(x,x')=\exp(-\dfrac{x-x'}{\sigma^2})$, 其中$\sigma$为核宽度, 反映了边界封闭包含的半径.

3.3 预测模型优劣的评价指标(Assessment indices of the forecasting model)

通常验证一个预测模型的预测结果的优劣, 引用模型在测试集上的均方误差为评价指标. 这个评价指标没有考虑显著性水平对模型误差的影响. 例如, 若当测试集的数据特征不显著, 那么无论何种预测都很难有较小的均方误差, 但这并不能说明该模型一定不好. 因此, 反映模型好坏的指标应该建立在显著性水平较高的数据集上, 这样比较客观. 因此, 采用相对误差构造新的模型优劣评价指标是合理的. 因此引入以下两种模型优劣评价指标.

1) 均方根相对误差(mean square relative error, MSRE)

$$\mathrm{MSRE}=\sqrt{\frac{1}{n}\sum_{k=0}^{n}(\frac{x_{i,k+1}-\hat x_{i,k+1}}{x_{i,k+1}})^2}\times 100\%. \quad (18)$$

2) 平均相对误差(mean relative error, MRE)

$$\mathrm{MRE}=\frac{1}{n}\sum_{k=0}^{n}|\frac{x_{i,k+1}-\hat x_{i,k+1}}{x_{i,k+1}}|\times 100\%. \quad (19)$$

这里$x_{i,k+1}$为第$k+1$个时间段的观测值, $\hat x_{i,k+1}$预测值, 且该时间段交通需求φ_0–显著.

4 仿真试验(Simulation experiment)

通过仿真实验主要验证: 交通需求显著时, 交通需求预测模型精度对分布的依赖性. 仿真条件为: 建筑物的使用功能为行政机关办公楼, 数据观测时间间隔为$\Delta t=5$ min, 观测时长为每天7:00到19:00, 每天采集 144 组数据(即 $l=144$), 数据采集时间为每周的周1至周5. 基于试验研究, 取参数$\sigma^2=0.005$, $C=500$. 用周1至周4的观测数据作为训练集, 来预测周5的交通需求状况, 用来评估预测模型的推广能力. 电梯总使用基数$Q=1200$, 根据文献[4], 确定该类建筑的约定客流参数为$\lambda_5=17\%$. 取置信度为95%, 则可求得φ_0=3.6. 由于$\Delta t=5$ min, 因此k, I_k, $x_{n\alpha}^{ev}(k)$有如下关系: $I_k=[7+\dfrac{1}{12}(k-1),7+\dfrac{1}{12}(k))$,$k=1,2,\cdots,l_0$; 即$\forall I_k$有唯一的$[a_\alpha(k),b_\alpha(k)]$与之对应, 所以$x_{n\alpha}^{ev}(k)$为$k$的函数. 依据本文提出的方法, 应用MATLAB7.01进行了仿真试验. 交通需求显著性判别的目的, 在于根据所得到的判别结果, 选择不同的预测方法预测上的电梯交通需求, 进而有效地识别交通模式. 下面仅对φ_0–显著且不满足Poisson分布的交通流, 对两种建立预测模型的方法, 即LS–SVM模型(简称模型1)和Poisson模型(简称模型2, 详见文献[18]), 进行比较. 根据所提出的判别指标, 共有87个观测区间的交通需求属于φ_0–显著, 且大部分不服从Poisson分布, 与2.4之2)相对应. 下面分别用模型1和模型2以上行交通需求为例进行预测, 并通过定义的误差指标比较这两个模型的优劣. 图1, 图2为依据模型1分别得出的预测结果与预测的相对误差曲线. 其中平均相对误差和均方根相对误差分别为: MRE $=25.38\%$, MSRE $=11.04\%$. 图3, 图4为依据模型2分别得出的预测结果与预测的相对误差曲线. 其中平均相对误差和均方根相对误差分别为: MRE $=40.66\%$, MSRE $=27.09\%$.

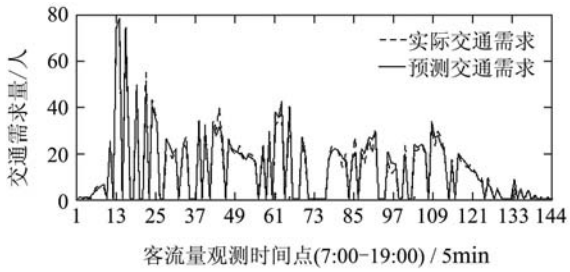

图 1 应用模型1对φ_0–显著的观测点的预测结果

Fig. 1 Forecasting results by model 1 for φ_0–in relief

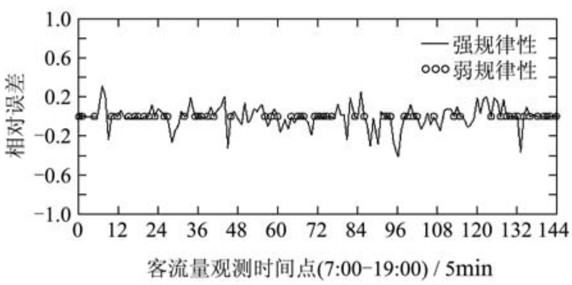

图 2 应用模型1对φ_0–显著的观测点预测的相对误差曲线

Fig. 2 Relative prediction error curve by model 1 for φ_0–in relief

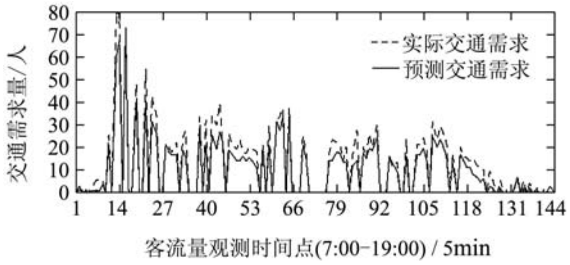

图 3　应用模型2对φ_0–显著的观测点的预测结果

Fig. 3　Forecasting results by model 2 for φ_0–in relief

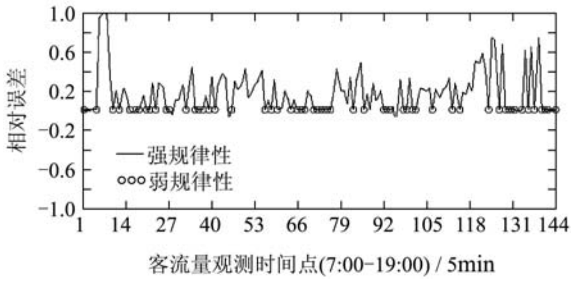

图 4　应用模型2对φ_0–显著的观测点预测的相对误差曲线

Fig. 4　Relative prediction error curve by model 2 for φ_0–in relief

表 1　应用两种方法所得的预测误差比较

Table 1　Error comparison between model 1 and 2

预测模型	MRE/(%)	MSRE/(%)
模型 1	25.38	11.04
模型 2	40.66	27.09

结果分析: 从表 1 可以看出, 在φ_0–显著且不服从Poisson的情况下, 从预测结果的均方根相对误差和平均相对误差看, 基于LS–SVM的模型1有较好的预测结果, 而基于Poisson预测的模型2预测结果较差. 与用神经网络方法对电梯交通需求的预测结果比较表明[16]: LS–SVM的预测结果要优于神经网络的预测结果(详见文献[16]). 这是因为: 传统预测方法采用经验风险最小化准则, 不可避免地出现过拟合现象, 使模型的泛化能力受到限制. 而LS–SVM技术采用结构风险最小化准则, 在最小化样本点的同时, 缩小模型泛化误差的上界, 即最小化模型的结构风险, 从而提高了模型的泛化能力, 这在小样本的学习中尤为突出. 因此, LS–SVM技术是处理不依赖具体分布的具有非线性小样本特征的交通需求的有效预测工具. 因此, 事实上, 在φ_0–显著且服从Poisson的情况下, 模型1也可得到较好的预测效果; 而Poisson方法的应用前提是观测样本服从Poisson分布, 并且对于大样本问题有较好效果, 换句话说该方法强依赖于数据的分布状态.

5　结论(Conclusion)

本文结合电梯交通系统的特点, 提出一种对电梯垂直交通需求显著性的评价指标, 对电梯交通需求显著性进行量的刻画. 并依据显著性评价指标提供的信息, 指导交通需求预测模型的建模方式. Poisson模型预测效果不稳定的原因, 主要在于该方法强依赖于观测样本的分布状态, 而实际上的观测样本并不严格服从Poisson分布. 这说明发掘不依赖分布的或对分布依赖较弱的预测模型是十分重要的. 本文探讨了在交通需求显著但不服从Poisson分布时, 如何用LS–SVM技术对电梯交通需求进行预测建模, 并进行了仿真验证, 结果表明LS–SVM预测模型优于传统的Poisson模型.

参考文献(References):

[1] STRANG T, BAUER C. Context aware group elevator scheduling [J]. *Elevator World*, 2006, 54(11): 58 – 66.

[2] DAVID J, SIRAG J. Elevator traffic control: US, 2007/0007086A1 [P]. Jan. 2007.

[3] BARNEY G C. *Elevator Traffic Handbook*[M]. London: Spon Press, 2003.

[4] 朱德文. 电梯交通系统的智能控制与应用[M]. 长春: 吉林大学出版社, 2002.

[5] YANG Z S, SHAO C, MA H F. LS-SVM based determination of critical time ranges for elevator traffic patterns[J]. *Elevator World*, 2006, 56(5): 110 – 115.

[6] 许玉格, 罗飞. 新型电梯群控系统交通模式识别方法[J]. 控制理论与应用, 2005, 22(6): 900 – 904.
(XU Yuge, LUO Fei. Traffic pattern recognition method for novel elevator system[J]. *Control Theory & Applications*, 2005, 22(6): 900 – 904.)

[7] YANG Z S, SHAO C. An improved PSO algorithm for the multi-objective optimization of EGCS[J]. *Elevator World*, 2008, 56(6): 72 – 83.

[8] 李中华, 谭洪舟, 张雨浓, 等. 基于免疫算法的午饭时期层际高峰交通电梯群控制的动态优化[J]. 控制理论与应用, 2007, 24(2): 177 – 182.
(LI Zhonghua, TAN Hongzhou, ZHANG Yunong, et al. Dynamic optimization of elevator group control based on artificial immune algorithm for inter-floor peak traffic during lunch-time[J]. *Control Theory & Applications*, 2007, 24(6): 177 – 182.)

[9] MARKON S A, KITA H, KISE H, et al. *Control of Traffic Systems in Buildings*[M]. New York: Springer, 2006.

[10] LEE Y, KIMB T S, CHO H S, et al. Performance analysis of an elevator system during up-peak[J]. *Mathematical and Computer Modelling*, 2009, 49(3-4): 423 – 431.

[11] BARNEY G C, DOS SANTOS S M. *Elevator Traffic Analysis: Design and Control*[M]. London: IEE Peter Peregrinus Ltd, 1985.

[12] CORTS P, MUUZURI J, ONIEVA L. Design and analysis of a tool for planning and simulating dynamic vertical transport[J]. *Simulation*, 2006, 82(4): 255 – 274.

[13] 朱德文, 杨祯山, 张筠莉. 智能控制电梯工程系统[M]. 北京: 中国电力出版社, 2007.

[14] CIBSE Guide D: 2005. *Transportation Systems in Buildings*[S]. London: Charter Institute of Building Service Engineers (CIBSE), 2005.

[15] LU M, WEVERS K. Grey system theory and applications: A way forward[J]. *Journal of Grey System*, 2007, 10(1): 47 – 53.

[16] 杨祯山. 电梯垂直交通系统的配置与优化调度问题研究[D]. 大连: 大连理工大学, 2008.

[17] SUYKENS J, CAMERON A K, VANDEWAKE J. Recurrent least squares support vector machines[J]. *IEEE Transactions on Circuits and Systems*, 2000, 47(7): 1109 – 1114.

[18] CAMERON A C, TRIVEDI P K. *Regression Analysis of Count Data*[M]. New York: Cambridge University Press, 1998.

附录 命题1, 命题2的证明(Appendix Demonstrations of proposition 1, 2)

命题1证明 若$X \sim P(\mu)$, 则$\mathrm{E}X = \mu, \mathrm{D}X = \mu$, 由Lindberg-Levy中心极限定理

$$\lim_{n\to\infty} \mathrm{P}\{\frac{\overline{X}-\hat{\mu}}{\sqrt{\mu}/\sqrt{n}} \leqslant \varepsilon\} = \int_{-\infty}^{\varepsilon} \frac{1}{\sqrt{2\pi}} \mathrm{e}^{\frac{-t^2}{2}} \mathrm{d}t = \Phi(\varepsilon),$$

所以 $\lim_{n\to\infty} \mathrm{P}\left\{\left|\frac{\overline{X}-\hat{\mu}}{\sqrt{\mu}/\sqrt{n}}\right| \leqslant \varepsilon\right\} = 2\Phi(\varepsilon) - 1.$

又因为

$$|\frac{\overline{X}-\hat{\mu}}{\sqrt{\mu}/\sqrt{n}}| \leqslant \varepsilon \Leftrightarrow \overline{X} + \frac{\varepsilon^2}{2n} - \varepsilon\sqrt{\frac{\overline{X}}{n} + \frac{\varepsilon^2}{4n^2}} \leqslant \mu \leqslant \overline{X} + \frac{\varepsilon^2}{2n} + \varepsilon\sqrt{\frac{\overline{X}}{n} + \frac{\varepsilon^2}{4n^2}}.$$

所以取$\hat{\mu} = \overline{X}$, 则

$$\lim_{n\to\infty} \mathrm{P}\{\hat{\mu}+\frac{\varepsilon^2}{2n}-\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}} \leqslant \mu\leqslant\hat{\mu}+\frac{\varepsilon^2}{2n}+\varepsilon\sqrt{\frac{\hat{\mu}}{n}+\frac{\varepsilon^2}{4n^2}}\} = 2\Phi(\varepsilon-1).$$

推论 1 当n充分大时,

$$\mathrm{P}\{\hat{\mu} + \frac{\varepsilon^2}{2n} - \varepsilon\sqrt{\frac{\hat{\mu}}{n} + \frac{\varepsilon^2}{4n^2}} \leqslant \mu \leqslant \hat{\mu} + \frac{\varepsilon^2}{2n} + \varepsilon\sqrt{\frac{\hat{\mu}}{n} + \frac{\varepsilon^2}{4n^2}}\} \approx 2\Phi(\varepsilon) - 1.$$

在给出了在置信度为$2\Phi(\varepsilon) - 1$的条件下, 便可以得到μ的置信区间的估计. 不妨令μ的置信区间为$[a_p, b_p]$, 则

$$[a_p, b_p] = [\hat{\mu} + \frac{\varepsilon^2}{2n} - \varepsilon\sqrt{\frac{\hat{\mu}}{n} + \frac{\varepsilon^2}{4n^2}}, \hat{\mu} + \frac{\varepsilon^2}{2n} + \varepsilon\sqrt{\frac{\hat{\mu}}{n} + \frac{\varepsilon^2}{4n^2}}].$$

命题2证明 1) 令$x(t)$在t_0的某个领域内连续可微, 则由一阶Taylor公式展开, 有

$$\Phi(x(t)) = \Phi(x(t_0)) + \Phi'_x(x(t_0))x'_t(t_0)(t-t_0) + o(|t-t_0|).$$

由Heine定理知

$$\lim_{t_n\to t_0} x(t_n) = x(t_0).$$

即$\Phi(x(t_n)) = \Phi(x(t_0)) + \Phi'_x(x(t_0))x'_t(t_0)(t_n - t_0) + o(|t_n - t_0|)$.

令$x(t) = \frac{\sqrt{n}\varepsilon}{t}, t_n = \sqrt{S_n^2}, t_0 = \sigma$, 则有: $x(t)$在$\mathbb{R}\backslash\{0\}$处连续可微.

所以 $$\Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}}) = \Phi(\frac{\sqrt{n}\varepsilon}{\sigma}) + \frac{1}{\sqrt{2\pi}}\mathrm{e}^{\frac{n\varepsilon^2}{2S_n^2}} \times (\frac{\sqrt{n}\varepsilon}{S_n^2})(\sqrt{S_n^2}-\sigma) + \mathrm{o}(|\sqrt{S_n^2}-\sigma|),$$

所以 $$|\Phi(\frac{\sqrt{n}\varepsilon}{\sigma}) - \Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}})| = |\frac{1}{\sqrt{2\pi}}\mathrm{e}^{\frac{n\varepsilon^2}{2S_n^2}} \times (\frac{\sqrt{n}\varepsilon}{S_n^2})(\sqrt{S_n^2}-\sigma) + \mathrm{o}(|\sqrt{S_n^2}-\sigma|)| \leqslant \frac{\sqrt{n}\varepsilon}{\sqrt{2\pi}}\mathrm{e}^{\frac{n\varepsilon^2}{2S_n^2}} \times \frac{1}{S_n^2} \times |\sqrt{S_n^2}-\sigma| + |\mathrm{o}(|\sqrt{S_n^2}-\sigma|)|.$$

令$f(x) = x\mathrm{e}^{\frac{-n\varepsilon^2}{2}x}$, 则有$f'(x) = \mathrm{e}^{\frac{-n\varepsilon^2}{2}x}(1 - \frac{n\varepsilon^2}{2}x)$, 所以$f'(x) = 0 \Leftrightarrow x = \frac{2}{n\varepsilon^2}$.

又因为

$$\lim_{x\to 0^+} f(x) = 0, \lim_{x\to\infty} f(x) = \lim_{x\to\infty} \frac{1}{\frac{n\varepsilon^2}{2}\mathrm{e}^{\frac{n\varepsilon^2}{2}x}} = 0,$$

$$f(\frac{2}{n\varepsilon^2}) = \frac{2}{n\varepsilon^2 e},$$

所以 $$\frac{1}{S_n^2}\mathrm{e}^{-n\varepsilon^2/2S_n^2} \leqslant \frac{2}{n\varepsilon^2 e}.$$

即 $$|\Phi(\frac{\sqrt{n}\varepsilon}{\sigma}) - \Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}})| \leqslant \frac{\sqrt{n}\varepsilon}{\sqrt{2\pi}}\frac{2}{n\varepsilon^2 e}|\sqrt{S_n^2}-\sigma| + \mathrm{o}(|\sqrt{S_n^2}-\sigma|)| = \frac{2}{\sqrt{2\pi n}\varepsilon e}|\sqrt{S_n^2}-\sigma| + |\mathrm{o}(|\sqrt{S_n^2}-\sigma|)|.$$

又因为 $$\lim_{n\to\infty}\sqrt{S_n^2} = \sigma,$$

所以

$$|\Phi(\frac{\sqrt{n}\varepsilon}{\sigma}) - \Phi(\frac{\sqrt{n}\varepsilon}{\sqrt{S_n^2}})| \leqslant \frac{2}{\sqrt{2\pi n}\varepsilon e}|\sqrt{S_n^2}-\sigma| \to 0, n\to\infty.$$

2) 由Lindberg-Levy中心极限定理:

$$\lim_{x\to\infty} \mathrm{P}\{\frac{\overline{X}-\mu}{\sqrt{\mu}/\sqrt{n}} \leqslant \varepsilon\} = \Phi(\varepsilon),$$

所以

$$\mathrm{P}\{|\overline{X}-\mu| \leqslant \varepsilon\} = \mathrm{P}\{|\frac{\overline{X}-\mu}{\sigma/\sqrt{n}}| \leqslant \frac{\sqrt{n}\varepsilon}{\sigma}\} = \mathrm{P}\{\frac{\overline{X}-\mu}{\sigma/\sqrt{n}} \leqslant \frac{\sqrt{n}\varepsilon}{\sigma}\} - \mathrm{P}\{\frac{\overline{X}-\mu}{\sigma/\sqrt{n}} \leqslant -\frac{\sqrt{n}\varepsilon}{\sigma}\} \approx 2\Phi(\frac{\sqrt{n}\varepsilon}{\sigma}) - 1.$$

这里n充分大, $\hat{\mu} = \overline{X}$.

3) 由1)2)知3)显然成立.

证毕.

作者简介:

杨祯山 (1965—), 男, 博士, 教授, 研究领域为复杂系统建模与控制、建筑智能化及先进控制技术在电梯交通控制系统中的应用研究, E-mail: ydlut@163.com;

邵 诚 (1958—), 男, 博士, 教授, 博士生导师, 研究领域为复杂系统的建模与控制、自适应控制、鲁棒控制等研究;

马海丰 (1976—), 男, 博士研究生, 从事优化理论及智能控制理论与应用的研究.