

城市轨道交通客流预测算法设计与仿真

李少伟^{1,2} 陈永生¹

(同济大学电子与信息工程学院 上海 201804)¹ (上海海事大学商船学院 上海 201306)²

摘要 为了更好地解决城市轨道交通的客流预测问题,提出了基于混合神经网络与卡尔曼滤波器的客流预测多层次模型。首先采用 ELAN 神经网络实现客流量的初步预测;然后采用卡尔曼滤波器对神经网络预测结果进行修正,以进一步提高预测结果精度;最后为了验证模型的正确性,以上海地铁交通作为研究对象,进行了客流观测和预测模拟。实验结果表明,所提出的多层次模型比单纯其中一种算法能减少约 0.8% 的误差,并且具有更好的实际效果。

关键词 轨道交通,客流预测,ELAN 神经网络,卡尔曼滤波器,系统仿真

中图分类号 U293.5 **文献标识码** A

Design and Simulation of Passenger Flow Forecast Algorithm for Urban Rail Transit

LI Shao-wei^{1,2} CHEN Yong-sheng¹

(School of Electronics and Information, Tongji University, Shanghai 201804, China)¹

(Merchant Marine College, Shanghai Maritime University, Shanghai 201306, China)²

Abstract To forecast exactly the passenger flow of the urban rail transit, a hierarchical framework based on neural network and Kalman-filter model was presented. First, ELAN neural network model is employed to implement the prediction of the passenger flow. Then the Kalman-filter was used to refine the forecast data of the passenger flow so as to advance the accuracy of the predicted results. Finally, in order to validate the proposed model, the passenger flow of Shanghai subway transport hub was observed and simulated. Experimental results show that the proposed hierarchical model reduces error about 0.8% and has better effects in contrast with any single algorithm.

Keywords Rail transit, Passenger flow forecast, ELAN neural network, Kalman filter, System simulation

随着我国城市化建设的不断加快,大量人口涌入城市,特别是北京、上海、广州等特大城市人口增长迅速。这些城市由于经济比较发达,机动车保有量已大大超出城市道路能够承受的容量。这种情况带来的最直接后果就是路面交通拥堵,出行成本上升,资源浪费严重。而轨道交通因其具有运量大(4~6 万人次/小时)、单位运量资源消耗少(采用电气化方式驱动)、运行准点率高(拥有独立的运行轨道)等优势,已然成为了解决大城市交通问题最理想、最有效的方法^[1]。

据统计,我国各大城市地铁日均客流已达到数百万,为了满足大量乘客的出行需求,轨道交通系统需要制定一套高效的调度策略来保证轨道交通的运行效率。而轨道交通的客流量可以说就是决定轨道交通调度策略的最主要因素^[2]。

由于客流预测算法直接影响着轨道交通的运行效率,相关研究人员在此领域进行了大量的研究,并采用不同的算法建立了相应的模型进行了实现。吕慎、过秀成提出了一种基于四阶段法改进的轨道交通客流预测方法^[3],这种方法主要运用管理学手段,对市民的生活水平、出行特点以及交通发展现状等因素进行了分析,从而对轨道交通客流进行预测,从宏观角度考虑了客流的分布;Zhang Dongquan、Wang Lina 采用

BP 神经网络对轨道交通客流进行预测^[4],文章以历史客流数据以及影响客流的相关因素作为训练样本,实现对轨道交通客流的预测;鲁明旭、叶银忠、马向华将 ELAN 神经网络应用到轨道交通客流预测中,预测精度较传统 BP 神经网络有所提高,平均误差较传统 BP 神经网络预测算法减少了约 2 个百分点^[5];陈大伟、肖为周、李旭宏等人提出了基于迭代反馈约束的城市轨道交通客流预测模型框架,并以改进的四阶段法作为模型框架算法^[6]。

由于轨道交通客流组成比较复杂,以上模型在预测算法以及精度方面并未达到较高的可信度,主要表现:1. 缺乏有效的实验数据或实验数据不够完整,仅仅在理论上提出了算法的结构与框架;2. 理论与实验之间有脱节的感觉,无法获知理论支撑是如何应用到实验中的,实验结果无法令人信服。

为了提高轨道交通客流的预测精度,满足实际需求,本文在参考已有算法的基础上^[7-13],提出了一种基于混合 ELAN 神经网络和卡尔曼滤波器的客流预测算法^[14]。

1 客流预测模型

为了实现轨道交通的客流预测,文章首先建立了基于

到稿日期:2013-04-27 返修日期:2013-06-22 本文受国家科技支撑计划(2009BAG18B04),上海市重点学科建设项目(S30602)资助。

李少伟(1982-),男,博士生,主要研究方向为智能轨道交通、计算机系统结构,E-mail:swli@shmtu.edu.cn;陈永生(1966-),男,博士,研究员,主要研究方向为计算机体系结构、计算仿真。

ELAN 神经网络的数学模型,并列出了影响轨道交通客流的若干主要因素作为神经网络的训练样本;同时为了提高客流预测模型的精度,模型中引入卡尔曼滤波器算法,实现对神经网络客流输出的修正。

1.1 神经网络模型建立

神经网络是一种大规模并行分布处理的非线性系统,具有高度的非线性运算能力和自学习、自组织、联想记忆、并行处理能力,神经网络的信息分布式存储在权系数中,具有集体运算和自适应学习的能力。由于轨道交通客流是一个非平稳随机过程,且客流量相对时间具有非线性特性,因此采用神经网络算法能够较好地处理客流预测这类问题^[15,16]。

1.1.1 ELAN 神经网络模型

ELAN 神经网络模型在普通前馈网络的隐藏层中增加一个承接层作为一步延时算子,以达到记忆的目的,从而使系统具有适应时变特性的能力,能直接反映动态过程系统的特性。图 1 所示为 ELAN 神经网络结构,从图中可以看出,相比普通前馈网络,ELAN 神经网络在输入层多出了承接层,并且其输入与隐藏层神经元的输出相关。




图 1 ELAN 神经网络结构

ELAN 神经网络的运算规则由以下 4 个等式组成:

$$H_i(k) = [C(k), X(k)] + B^i W^{1,2} \quad (1)$$

$$H_o(k) = f_1(H_i(k) + B^2) \quad (2)$$

$$Y(k) = f_2(H_o(k) W^{2,3} + B^3) \quad (3)$$

$$C(k) = H_o(k-1) \quad (4)$$

其中, $X(k)$ 为网络的输入, $Y(k)$ 为网络的输出, $W^{i,i+1}$ 为连接第 i 层与第 $i+1$ 层神经元的权值矩阵, B^i 为第 i 层神经元的偏置输入, $C(k)$ 为承接层的输入, $H_i(k)$ 、 $H_o(k)$ 分别为隐藏层的输入、输出。式(1)中的 $[C(k), X(k)]$ 表示连接向量 $C(k)$ 与向量 $X(k)$ 。

1.1.2 神经网络训练

反向传播算法(Back-Propagation Algorithm)具有算法简单、运算速度快等特点,是神经网络训练中最常用的算法。采用 BP 算法进行神经网络训练,需要用到如下信息:

$$\{X, T, n_j^i, A^0, A^1, \dots, A^M\} \quad (5)$$

其中, X 为网络输入, T 为网络期望输出, n_j^i 为第 j 层标号为 i 的神经元诱导局部域, A^i 为第 i 层神经元的输出, M 表示神经网络总的层数, A^M 为网络输出。权值矩阵及偏置输入的更新过程如下:

I 输入的前向传播

$$A^0 = X \quad (6)$$

$$A^{i+1} = f^{i+1}(W^{i,i+1} A^i + B^{i+1}) \quad (7)$$

II. 反向传播

$$s^M = -2F^M(n^M)(T - A^M) \quad (8)$$

$$s^m = F^m(n^m)(W^{m,m+1})^T s^{m+1} \quad (9)$$

III. 权值和偏置值的更新

$$W^{m,m+1}(K+1) = W^{m,m+1}(K) - \eta s^m (A^{m-1})^T \quad (10)$$

$$B^m(K+1) = B^m(K) - \eta s^m \quad (11)$$

其中

$$F^m(n^m) = \begin{bmatrix} f^m(n_1^m) & 0 & \dots & 0 \\ 0 & f^m(n_2^m) & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & \dots & f^m(n_{n^m}^m) \end{bmatrix} \quad (12)$$

η 表示学习率,它可以是一个常数,也可以按一定的规则,在每次样本训练中取不同的值。

需要注意的是,权值矩阵初值的选择可能造成神经网络最终收敛的局部最小点并非是全局最小点。

1.1.3 训练样本选取

为了对神经网络进行有监督的训练,必须要选定训练样本的输入与输出。训练样本的输入即影响轨道交通客流的各种外部环境因素,样本的输出为轨道交通客流的观测值。表 1 详细列出了本算法选取的神经网络输入样本,包括天气因素、国家政策、重大节假日等等;同时,为了方便神经网络和计算机对上述各项信息的处理,在将上述信息作为训练样本输入到神经网络以前,对其进行了数字化处理,如表 1 第 2 列所列。

表 1 影响轨道交通客流分布的若干关键因素及数字化结果

影响因素	数字化结果
星期(一周内)	1~7 分别代表周一到周日
日期	取 6 位数年月日
国家政策	1. 汽油平均零售价格 2. 大型活动的举办
节假日	休息天数 n 、休息前 n 天以及休息后 n 天, 春节假期 $\times 1.5$
天气	雨量: 0~4 风力: 0~12 气温: 实测温度均值
天气	雨量: 0~4 风力: 0~12 气温: 实测温度均值

1.2 卡尔曼滤波器模型

卡尔曼滤波器是一种由卡尔曼(Kalman)提出的用于时变线性系统的递归滤波器。在本算法中,我们应用卡尔曼滤波器对神经网络的输出结果进行修正,使得预测结果更加精确^[17]。卡尔曼滤波器由如下所列的预测及更新方程组成:

$$\hat{x}_k^- = A \hat{x}_{k-1} + B u_k \quad (13)$$

$$P_k^- = A P_{k-1} A^T + Q_k \quad (14)$$

$$K_k = P_k^- H^T (H P_k^- H^T + R_k)^{-1} \quad (15)$$

$$\hat{x}_k = \hat{x}_k^- + K_k (z_k - H \hat{x}_k^-) \quad (16)$$

$$P_k = (I - K_k H) P_k^- \quad (17)$$

其中,方程组(13)、(14)为预测方程组,方程组(15)~(17)为更新方程组; A 是作用在 $x_k - 1$ 上的状态变换模型; B 是作用在控制器向量 u_k 上的输入-控制模型; Q_k 是过程噪声协方差

矩阵, R_k 是观测噪声协方差矩阵。

卡尔曼滤波器模型详细推导过程以及各参数的详细意义可以参考文献[20]。

1.2.1 观测噪声方差

卡尔曼滤波器假设观测噪声满足高斯分布:

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} \quad (18)$$

对观测噪声方差的求解, 可以很自然地认为是对高斯分布中未知参数进行估计。根据概率论的基本知识, 采用最大似然估计法来对分布函数中的未知量进行估计。

高斯分布的最大似然函数为:

$$\max L(\mu, \sigma^2) = \max \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2\sigma^2}(x_i-\mu)^2} \quad (19)$$

为了便于算法的求解, 将最大似然函数转换为对数最大似然函数:

$$\ln L = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \quad (20)$$

对等式(20)求一阶及二阶微分, 令等式为零, 计算极值点:

$$\frac{\partial}{\partial \mu} \ln L = \frac{1}{\sigma^2} [\sum_{i=1}^n x_i - n\mu] = 0 \quad (21)$$

$$\frac{\partial}{\partial \sigma^2} \ln L = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{i=1}^n (x_i - \mu)^2 = 0 \quad (22)$$

求解方程组(21)(22), 得到高斯分布最大似然估计值:

$$\hat{\mu} = \bar{X} \quad (23)$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \quad (24)$$

由于观测噪声分布函数均值为零, 在此令 O_i 表示第 i 日客流统计数据, P_i 表示第 i 日的预测客流数据, 以客流预测误差作为分布函数的均值, 即

$$\hat{\mu} = \sum_{i=1}^n (O_i - P_i) \quad (25)$$

$$X_i = O_i - P_i \quad (26)$$

将式(25)、式(26)代入式(24)中, 可计算得到观测噪声分布函数方差。需要注意的是, 按上述方法求出的方差并非一个常数, 而是随着新的统计数据不断加入, 呈现出相应的变化。

1.2.2 其他参数的确定

n 天内, 轨道交通的观测客流量与预测客流量比例的期望为:

$$E = \frac{1}{n} \sum_{i=1}^n \frac{O_i}{P_i} \quad (27)$$

增益 A 可采用如下形式表示:

$$A = E \quad (28)$$

A 的值随着观测数据的加入, 呈现动态变化。

记 P_0 为误差估计协方差 P 的初值, 其取值通常并不关键, 因为几乎任何 $P_0 \neq 0$ 都会使滤波器最终收敛。在这里我们令 $P_0 = 1$ 。

由于轨道交通的日客流量统计由机器直接完成, 其统计误差可由观察数据得到。通常情况下, 我们认为客流统计误差接近于零, 可以忽略不计。在此我们直接将过程激励噪声的方差 Q 设定为零。

2 模型仿真实验

为了验证模型算法的正确性与实用性, 我们选择上海轨道交通作为研究对象。首先, 将轨道交通的历史统计数据作为训练样本输入到神经网络, 使得网络具有客流预测能力; 然后, 用神经网络预测一段时间内的客流数据, 并应用卡尔曼滤波器对预测结果进行修正; 最后, 计算预测数据与实际数据之间的误差, 并量化预测精度。

2.1 输入样本数据

在本次样本数据中, 我们选取了 2012 年 7—10 月, 共计 123 天的样本数据。这 4 个月刚好涵盖了季节的变迁、重大节假日以及汽油价格波动等情况, 这样可以便于网络对各种环境的适应。在横跨 4 个月的时间内, 部分数据由于官方渠道未发布, 算法在处理时直接采取丢弃样本的策略, 以保证算法能够正常进行, 有效样本数量为 117 个。

按照表 1 所述方法, 以各种环境因素, 包括: 天气、日期、星期、经济环境等, 作为神经网络训练样本的输入, 并对输入样本做数字化处理, 最终形成神经网络的训练样本的输入。

2.2 输出样本数据

图 2 实线所标示曲线为采样时间内的客流走势, 是神经网络训练中的期望输出。从图中可以明显看到轨道交通客流的几个特征: 1. 客流量大体呈现出以一周为一个循环周期; 2. 随着时间的推移, 客流量有一种上升趋势, 这是由于城市的发展、汽油价格的上升等因素, 导致了更多的市民选择乘坐轨道交通出行; 3. 9 月 29 日的客流呈现出明显的下降现象, 这是由于 10 月 1 日为国庆长假, 从另一方面也正好说明了重大节假日对轨道交通的客流的影响。

2.3 模型仿真

利用 Matlab 工具箱中的函数对 ELAN 神经网络进行建模仿真^[18-20]。选取学习率可变的动量 BP 算法, 设定不同的参数对网络进行训练, 训练结果如表 2 所列。

表 2 训练结果

训练回合	隐藏神经元	目标误差	运行时间	实际误差
300	200	1e-3	2 秒	0.0198
300	400	1e-3	6 秒	0.0096
600	200	1e-3	4 秒	0.055
600	400	1e-3	12 秒	0.0012
1000	200	1e-3	8 秒	0.007
1000	400	1e-3	20 秒	0.009

从表 2 中可以看到, 隐藏神经元的数目会对运行时间造成较大的影响, 而过多的隐藏神经元反而会会造成误差的增加。根据表中的数据, 我们选取第 4 行数据作为神经网络的训练参数。图 2 所示为神经网络训练完毕后, 对历史客流数据的拟合。其中实线部分代表实际客流, 虚线则表示神经网络的客流数据输出。




图 2 客流数据拟合

接下来我们选取上海轨道交通 2012 年 11 月 1 日至 11 月 5 日的客流作为预测对象,对 ELAN 神经网络预测模型进行检验,得到如图 3 所示的结果。




图 3 预测结果

2.4 误差修正

将神经网络预测得到的数据通过卡尔曼滤波器进行修正,修正算法已在第 2 部分详细介绍,数据修正结果如表 3 所列。

表 3 数据修正

预测客流	实际客流	滤波器增益	滤波器方差 P	修正结果
661.3	682	1.01	1.0	668
698.3	733.4	1.01	0.99	706.7
588.4	566.7	0.98	0.99	578.1
510.9	526.9	0.99	0.98	505.8
700.6	682.8	0.99	0.98	692.5

从表 3 可以看到,经过卡尔曼滤波器修正后,预测数据与真实数据之间的误差有所减少。同时可以看到,卡尔曼滤波器方差 P 在计算过程中不断向零趋近,这也验证了其初值的选取并不会影响滤波器的计算。在表 4 中列出了神经网络预测误差与卡尔曼滤波器修正后的误差对比。

表 4 误差对比

实际客流	神经网络预测客流	预测误差	修正客流	修正后的误差
682	661.3	-3.03%	668	-2.05%
733.4	698.3	-4.8%	706.7	-3.6%
566.7	588.4	3.8%	578.1	2.01%
526.9	510.9	-3.03%	505.8	-4.0%
682.8	700.6	2.6%	692.5	1.42%

3 实验结论与展望

从实验中我们可以看到,单纯采用神经网络算法对轨道交通客流进行预测,最大绝对误差为 4.8%,经过卡尔曼滤波器修正后,最大绝对误差减小到 4.0%。这是由于卡尔曼滤波器会将历史误差信息加入到计算中,从而实现预测精度的提高。

下一步的研究主要围绕以下目标展开:1. 为了进一步提高神经网络的预测精度,神经网络的训练样本应覆盖更多的情况,也就是说,神经网络需要更大的训练样本。2. 由于轨道交通各站点客流数量不均衡,可以对单独站点的客流进行预测,以实现特定站点的管理。

结束语 本文提出了一种基于混合神经网络与卡尔曼滤波器的轨道交通客流预测算法。该算法以神经网络作为客流预测手段,并辅助以卡尔曼滤波器,实现了对轨道交通客流的预测与修正,提高了客流预测精度。通过仿真实验表明,这种

混合层次模型在客流预测精度上优于单一客流预测算法。

参考文献

- [1] 黄树森,宋瑞,陶媛.大城市居民出行方式选择行为及影响因素研究-以北京为例[J].交通标准化,2008,38(9):124-128
- [2] Li Shao-wei, Chen Yong-sheng. Dynamic schedule strategy for urban rail transit[J]. International Journal of Digital Content Technology and its Applications, 2012, 6(3): 86-92
- [3] 吕慎,过秀成.轨道线网客流预测方法研究[J].系统工程理论与实践,2001,33(8):106-110
- [4] Zhang Dong-quan. Passenger Flow Forecast of Urban Rail Transit Based on BP Neural Networks[C]// Intelligent Systems and Applications. Qingdao: IEEE, 2011: 1-4
- [5] 鲁明旭,叶银忠,马向华.神经网络在地铁客流预测中的应用[J].机械研究与应用,2012,25(3):86-89
- [6] 陈大伟,肖为周,李旭宏,等.迭代反馈约束下的城市轨道交通客流预测分析[J].华南理工大学学报:自然科学版,2011,39(8):99-103
- [7] 顾杨,韩印,方雪丽.基于 ARMA 模型的公交枢纽站客流量预测方法研究[J].交通信息与安全,2011,29(2):5-9
- [8] Zhu Hai-yan. N days average volume based ARIMA forecasting model for Shanghai metro passenger flow[C]// International Conference on Artificial Intelligence and Education, ICAIE. Hangzhou: IEEE, 2010: 631-635
- [9] Ghosh B, Basu B, O'Mahony M. Multivariate Short-Term Traffic Flow Forecasting Using Time-Series Analysis[J]. IEEE Transactions on Intelligent Transportation Systems, 2009, 10(2): 246-254
- [10] 张春辉,宋瑞,孙杨.基于卡尔曼滤波的公交站点短时客流预测[J].交通运输系统工程与信息,2011,11(4):154-159
- [11] 姜平,黄志鹏.基于神经网络的公交客流预测[J].交通标准化,2008,38(12):28-31
- [12] 刘凯,李文权,赵锦焕.短时公交客流小波预测方法研究[J].交通运输工程与信息学报,2010,8(2):111-117
- [13] 任崇岭,曹成铉,李静,等.基于小波神经网络的短时客流量预测研究[J].科学技术与工程,2011,11(21):5099-5110
- [14] 张余生,夏秀渝,杨莎.基于神经网络和卡尔曼滤波算法的说话人识别[J].成都信息工程学院学报,2008,23(4):384-388
- [15] Haykin S. Neural Networks Principle, 2nd Edition[M]. Beijing: China Machine Press, 2004
- [16] Hagan M T. Design Neural Network [M]. Beijing: China Machine Press, 2002
- [17] Welch G, Bishop G. An Introduction to the Kalman Filter[R]. Carolina: Department of Computer Science University of North Carolina, 2006
- [18] Hanselman D, Littlefield B. Mastering Matlab 7 [M]. Beijing: Tsinghua University Press, 2006
- [19] 葛哲学,孙志强.神经网络理论与 MATLAB R2007 实现[M].北京:电子工业出版社,2007
- [20] 周开利,康耀红.神经网络模型及 MATLAB 仿真程序设计[M].北京:清华大学出版社,2005