

改进 RBF 神经网络的轨道交通客流预测

徐凤 金辉 赵明旭

辽宁工业大学汽车与交通工程学院, 辽宁 锦州 121000

[摘要]我国城市轨道交通的客流预测是轨道交通运营管理工作的重中之重, 客流预测会给城市轨道交通工作提供便利。使用粒子群算法对 RBF 神经网络的参数进行优化, 进而改进 RBF 神经网络, 以对城市轨道交通客流进行预测。并以成都地铁交通网络作为案例进行预测分析。结果表明, 使用优化后的 RBF 神经网络预测的更加接近实际值。

[关键词]轨道交通; 客流预测; RBF 神经网络; 粒子群优化算法

DOI: 10.33142/sca.v4i4.4301

中图分类号: TS4;TP2

文献标识码: A

Rail Transit Passenger Flow Forecasting Based on Improved RBF Neural Network

XU Feng, JIN Hui, ZHAO Mingxu

School of Automobile and Traffic Engineering, Liaoning University of Technology, Jinzhou, Liaoning, 121000, China

Abstract: passenger flow forecast of urban rail transit in China is the top priority of rail transit operation and management. Passenger flow forecast will provide convenience for urban rail transit. Particle swarm optimization algorithm is used to optimize the parameters of RBF neural network, and then improve RBF neural network to predict the passenger flow of urban rail transit. Taking Chengdu metro transportation network as a case, this paper makes a prediction and analysis. The results show that the prediction using the optimized RBF neural network is closer to the actual value.

Keywords: rail transit; Passenger flow forecast; RBF neural network; Particle swarm optimization algorithm

引言

城市轨道交通准确地客流预测对地铁运行有着十分重要的作用。第一, 客流预测可以为运营管理部门提供合理的分配调度方案, 以保证地铁正常运转。第二, 为城市居民提供合适的出行意见。第三, 客流预测为日后城市建设规划提供战略价值。

常见客流的预测方法大致可以分为以下四种: 基于线性理论的方法、基于非线性理论的方法、基于混合理论的方法和其他预测方法^[1]。

目前, 中外学者对客流预测方面的研究也颇多。冯诚^[2]等提出了将灰狼优化算法与小波神经网络结合进行客流预测, 结果表明, 此模型提高了预测精度。李科君^[3]等构建了一种非线性自回归神经网络模型, 结果验证其预测精度优于线性时间序列预测精度。傅晨琳^[4]等构建了基于 EEMD-BP 方法的客流预测模型, 验证了该组合模型的有效性。何蔼琳^[5]等提出了基于长短时记忆网络 (LSTM) 模型的变长度客流序列数据预测, 最后表明改进 LSTM 模型预测准确性更高。徐熠明^[6]采用 Holt 双参数指数平滑法优化了传统的灰色新陈代谢预测模型, 实验结果表明, 在预测精度上高于传统灰色预测模型。王秋雯^[7]等提出了深度学习模型 k-ConvLSTM 进行城轨交通短时客流预测, 结果表明, 其优于其他模型。因此, 本文将引入粒子群算法对 RBF 神经网络进行改进, 对成都轨道交通客流进行预测。

1 RBF 神经网络

RBF^[8] (Radial Basis Function, 径向基函数) 神经网络是一种有单隐藏层的三层前向神经网络。输入层由一个信号源节点组成, 输入向量为 $X = [x_1, x_2, \dots, x_m]^T$, 隐含层是单神经元层, 隐含层神经元的变换函数是 RBF, 输出层对输入的作用做出反馈。输入层到隐含层的变换是非线性的, 通常采用高斯径向基函数 $\varphi = [\varphi_1, \varphi_2, \dots, \varphi_N]^T$ 实现, 即

$$\varphi_i = (\|X - C_i\|) = \exp\left(-\frac{\|X - C_i\|^2}{2\sigma_i^2}\right), i = 1, 2, \dots, N \quad (1)$$

其中 $C_i = [C_{i1}, C_{i2}, \dots, C_{iN}]^T$ 表示第 i 个隐藏层节点的中心向量, 与输入向量 X 具有相同的维数; $\sigma_i = [\sigma_{i1}, \sigma_{i2}, \dots, \sigma_{iN}]^T$ 为径向基函数的宽度。 $\|X - C_i\|$ 为二者之间的欧氏距离; 从隐含层到输出层的变换是线性的。隐含层到输出层的输出可以由式 (2) 表示

$$y_j = \sum_{i=1}^p \omega_{ij} h_i, j = 1, 2, \dots, N \quad (2)$$

其中： ω 为输出层的权值； p 为输出节点的个数。RBF神经网络的结构如图1所示。

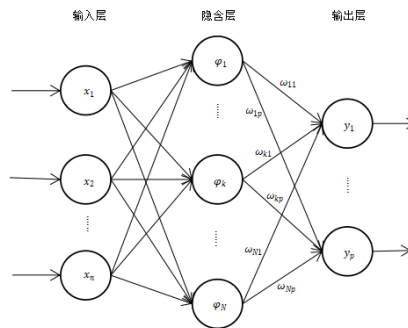


图1 RBF神经网络结构图

2 改进 RBF 神经网络

2.1 粒子群优化算法

粒子群优化算法^[9] (Particle Swarm Optimization, PSO) 是通过模拟鸟群觅食行为而发展起来的一种群体协作的随机搜索算法。粒子群优化算法是由 Eberhart 博士和 Kennedy 博士发明。PSO 模拟鸟群的捕食行为。一群鸟随机搜索食物，在这个区域内只有一块食物，并且所有的鸟都不知道食物在哪里。但是它们知道当前的位置距离食物还有多远。最简单的方法就是寻找距离食物最近的鸟的周围区域。PSO 从这种模型中得到启发并用于解决优化问题。PSO 中，每个优化问题的解是搜索空间中的一只鸟，称之为“粒子”。所有的粒子都有一个由被优化的函数决定的适应值 (fitness value)，每个粒子还有一个速度来确定它们飞行的方向和距离。然后粒子们就跟随当前的最优粒子在解的空间中搜索。

粒子群算法的具体过程如图所示：

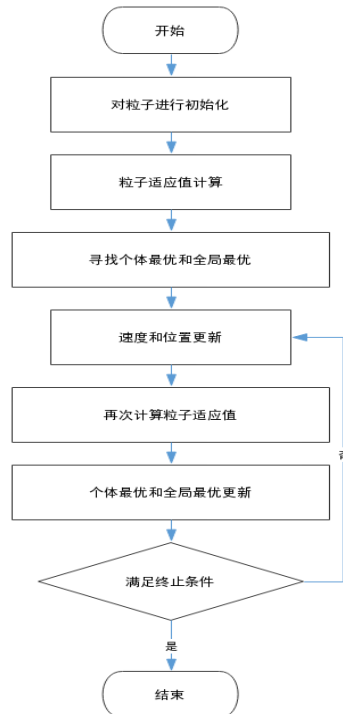


图2 粒子群算法流程图

PSO 算法是从随机解出发，通过在每一次迭代时跟踪个体最优值 $pbest$ 和全局最优值 $gbest$ 调整自己的速度和位置，根据如下公式进行更新迭代：

$$v_{ij}^{m+1} = \omega v_{ij}^m + c_1 r_1 (pbest_{ij}^m - x_{ij}^m) + c_2 r_2 (gbest_{ij}^m - x_{ij}^m) \quad (3)$$

$$x_{ij}^{m+1} = x_{ij}^m + v_{ij}^{m+1} \quad (4)$$

式中： ω 为网络权重；

m 为迭代次数；

x_{ij}^m 为第 i 个粒子在第 j 维搜索空间的位置；

v_{ij}^m 为第 i 个粒子在第 j 维搜索空间的飞行速度；

c_1 和 c_2 为学习因子，用来平衡pbest和gbest之间的相对重要性；

r_1 和 r_2 为介于 0~1 之间的随机数。

2.2 PSO-RBF 神经网络

粒子群算法优化 RBF 神经网络流程图如图所示

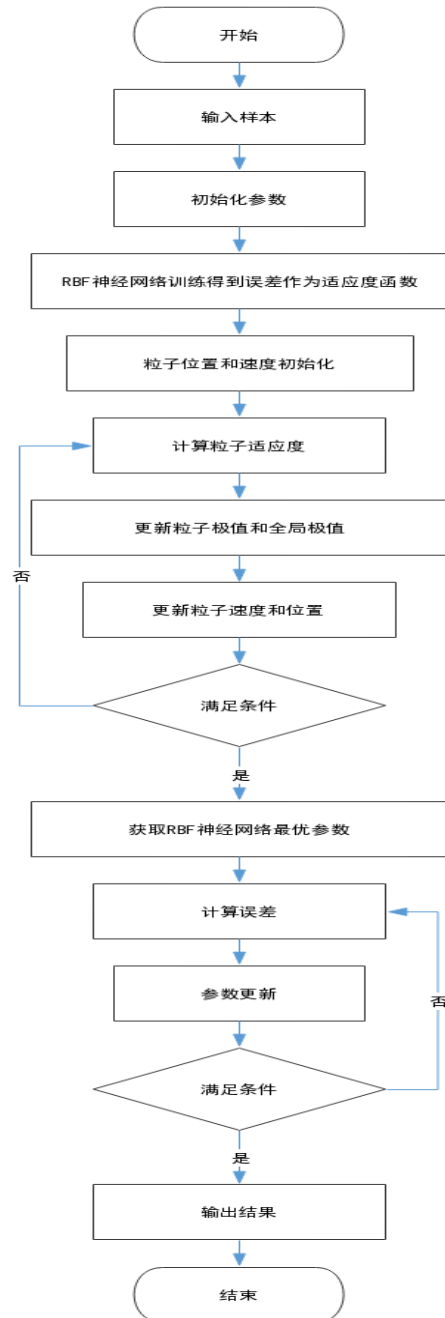


图3 PSO-RBF 神经网络流程图

3 实例分析

3.1 数据预处理

案例以成都轨道交通中2号线东门大桥站2020年1月6日-2020年1月10日和2020年1月13日-2020年1月17日7:00-23:00, 5分钟进站客流量作为研究对象, 数据本身会对模型产生影响, 所以对数据进行预处理。使用min-max归一化算法对数据进行预处理。根据下面的公式:

$$y = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (5)$$

式中, x 表示转换前客流量的值, y 表示转换后客流量的值, x_{\max} 表示最大客流量值, x_{\min} 表示最小客流量值。归一化处理可以减小最大值和最小值对程序的影响, 保证小的输入值不被吞食。

3.2 预测模型

研究采用MATLAB进行建模设计, newrb用于RBF网络训练, newrb(P, T, goal, spread)构造径向基函数, P为训练集的输入, T为训练集的输出, goal为均方误差值, spread为函数的扩展速度。

数据采用2020年成都地铁2号线东门大桥站1月6日-1月10日和1月13日-1月16日7:00-23:00的5分钟进站客流量, 共1920组数据作为训练集, 1月17日7:00-23:00的5分钟进站客流量作为测试集。

数据处理前客流趋势变化如图4所示。可以很直观地看出客流周期性变化。图5则为归一化处理后的数据变化图。




图4 进站客流量趋势图

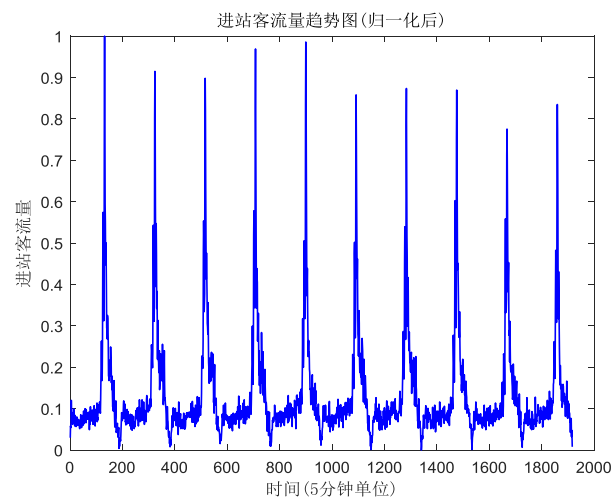


图5 归一化后客流量变化趋势图

3.3 误差指标定义

采用了 3 种评价指标进行模型性能的评价，分别为均方根误差（RMSE）、平均绝对误差（MAE）、和平均绝对百分比误差（MAPE），表达式分别为：

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_{test}^{(i)} - \hat{y}_{test}^{(i)})^2} \quad (6)$$

$$MAE = \frac{1}{m} \sum_{i=1}^m |y_{test}^{(i)} - \hat{y}_{test}^{(i)}| \quad (7)$$

$$MAPE = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_{test}^{(i)} - \hat{y}_{test}^{(i)}}{y_{test}^{(i)}} \right| \quad (8)$$

式中： $y_{test}^{(i)}$ 和 $\hat{y}_{test}^{(i)}$ 分别为客流真实值和预测值； m 为客流数据的样本个数。

3.4 结果分析

训练后的 RBF 神经网络模型和 PSO-RBF 神经网络分别对 1 月 17 日的进站客流进行预测，并与实际值比价，结果如图 6 所示。




图 6 RBF 神经网络与 PSO-RBF 神经网络改进结果对比




图 7 RBF 神经网络与 PSO-RBF 神经网络改进误差比较

由图 6 图 7 可以看出，改进后的模型优于传统的神经网络模型。改进前和改进后的误差对比如下表所示。

表 1 误差比较

	R^2	MSE	RMSE	MAPE	MAE
PSO-RBF	0.812913	726.8019	26.95926	15.82518	16.30512
RBF	0.799971	820.8308	28.82414	16.70294	17.16693

表中显示,采用粒子群算法改进 RBF 神经网络要明显优于 RBF 神经网络,并且优化后的 RBF 神经网络拟合度更好。

4 结语

本文采用粒子群算法对 RBF 神经网络优化,进而对客流量进行预测。城市轨道交通客流量是非常复杂的非线性问题,使用粒子群算法优化 RBF 神经网络不仅克服了局部最优的问题,而且预测精度高。通过实验可以看出,本文所提出的方法可以解决一些复杂情况下的非线性预测问题。

[参考文献]

- [1] 陆海亭,张宁,黄卫,夏井新.短时交通流预测方法研究进展[J].交通运输工程与信息学报,2009,7(4):84-91.
- [2] 冯诚,杨静,周浪雅,张红亮.基于 GWO-WNN 模型的城市轨道交通短时进站客流预测[J].铁道运输与经济,2019,41(8):97-102.
- [3] 李科君,高瑾瑶,宋建华,等.基于 NARNN 的城市轨道交通短时进站客流预测[J].武汉理工大学学报(交通科学与工程版),2020,44(1):103-107.
- [4] 傅晨琳,黄敏,沙志仁.基于 EEMD-BP 方法的城市轨道交通进站客流短期预测[J].铁道运输与经济,2020,42(3):105-111.
- [5] 何蔼琳,王豹.基于改进 LSTM 算法的城市轨道交通 OD 客流预测方法[J].综合运输,2021,43(4):67-87.
- [6] 徐熠明.基于灰色改良模型的城市轨道交通客流预测研究[J].软件导刊,2021,20(4):135-140.
- [7] 王秋雯,陈彦如,刘媛春.基于卷积长短时记忆神经网络的城市轨道交通短时客流预测[J].控制与决策,2021(5):1-10.
- [8] Powell,MJD.Radial Basis Functions for Multivariable Interpolation[C].Oxford:Carendon Press,1985.
- [9] 赵乃刚,邓景顺.粒子群优化算法综述[J].科技创新导报,2015,12(26):216-217.

作者简介:徐凤(1995-),辽宁工业大学,学生。