

文章编号: 1000-5641(2017)02-0061-08

## 改进 BP 神经网络在交通事故预测中的研究

陈海龙<sup>1</sup>, 彭伟<sup>2</sup>

(1. 华东师范大学 计算中心, 上海 200062; 2. 华东师范大学 信息化办公室, 上海 200062)

**摘要:** 交通事故严重程度受多种因素的影响, 适合用人工神经网络来建模预测. 因为标准 BP(Back Propagation, BP)神经网络具有收敛较慢的缺陷, 所以在自适应学习和附加动量因子改进 BP 神经网络<sup>[1]</sup>基础上做了进一步的优化改进, 使附加动量因子也具有自学习性. 利用改进后的 BP 神经网络算法, 选取英国利兹市的公开交通事故数据集, 用影响交通事故严重程度的多种影响因素和事故严重程度构建并训练神经网络, 并对最新数据进行预测. 通过大量的实验对比收敛速度和预测结果, 验证了改进后的算法具有更快的收敛速度和更高的预测准确率.

**关键词:** BP 神经网络; 动量因子; 自学习; 交通事故

**中图分类号:** TP183 **文献标志码:** A **DOI:** 10.3969/j.issn.1000-5641.2017.02.008

## Research on improved BP neural network in forecasting traffic accidents

CHEN Hai-long<sup>1</sup>, PENG Wei<sup>2</sup>

(1. *Computer Center, East China Normal University, Shanghai 200062, China;*

2. *Information Technology Services Center, East China Normal University, Shanghai 200062, China)*

**Abstract:** The traffic accident severity is affected by many factors. It is suitable for modeling and forecasting by using the artificial neural network (ANN). Because standard BP(back propagation) neural network has the defect of slow convergence, based on the improved BP neural network with adaptive learning and additional momentum factor<sup>[1]</sup>, so the additional momentum factor was made to be self-learning for further optimization and improvement. Using the improved BP neural network algorithm, the public traffic accident data set in Leeds of England was selected to construct and train the neural network to predict the latest records. The data set includes many kinds of influencing factors and accident severity. After a lot of experiments, by comparing the convergence rate and prediction results, it has been proved that the improved algorithm has faster convergence rate and higher forecasting accuracy rate.

**Key words:** BP neural network; momentum factor; self-learning; traffic accident

## 0 引 言

收稿日期: 2016-03-08

第一作者: 陈海龙, 男, 硕士研究生, 研究方向为物联网. E-mail: 861137526@qq.com.

通信作者: 彭伟, 男, 高级工程师, 硕士生导师, 研究方向为计算机网络、Web 应用技术及计算模拟.  
E-mail: wpeng@admin.ecnu.edu.cn.

交通事故会引发不同程度的灾难性后果, 对人的生命和财产造成严重影响. 交通事故预测建模对预测交通事故严重程度具有重大预防意义, 以便在事故可能发生前及时对驾驶员发出提醒, 使其采取相应的应对措施, 这对减少交通事故的发生有相当大的作用.

时间序列法、回归模型法<sup>[2]</sup>、贝叶斯网络<sup>[2]</sup>、灰色预测法<sup>[3]</sup>等是交通事故预测模型常用的方法, 也有神经网络法<sup>[4]</sup>、决策树法<sup>[5]</sup>、灰色马尔可夫链模型法<sup>[6]</sup>和灰色神经网络组合<sup>[6]</sup>等较新的预测方法. 在一般问题上, 与常用的经典预测方法相比, 神经网络预测建模并不具有特别的优势, 而在常用的经典建模预测方法很难解决或者预测准确率等指标不理想时, 神经网络建模预测就显示出其出色的特性; 尤其是对交通事故诱导因素的重要程度不甚了解时, 神经网络建模预测就表现出极大的灵活性和有效性. 非线性和随机性是交通事故发生的两大特点, 不适合用线性回归预测分析方法对其建模预测. 神经网络由于其独特的优点, 非常适合用于多输入非线性复杂关系建模预测, 因此能够很好地应对交通事故发生的严重程度与导致因素的预测模型问题.

针对交通事故发生的多因素和非线性特点, 在综合研究相关建模预测方法后, 本文对基于自适应学习和动量因子改进 BP 神经网络<sup>[1]</sup>(Back Propagation Neural Network, 简称 BP 神经网络)做了进一步的优化改进, 使动量因子也具有自学习性, 避免不当的动量因子初始值对结果收敛的较大影响. 大量试验结果表明, 自学习动量因子改进的 BP 神经网络收敛速度不受其动量因子初始值大小的影响, 能够更快更好地预测交通事故的严重程度.

## 1 BP 神经网络

### 1.1 标准 BP 神经网络

人类大脑信息的传递以及对外界刺激产生的反应都是由一个个小神经元联合控制的, 人类的大脑就是由这样的上百亿个的小的神经元构成. 人工神经网络(Artificial Neural Network, ANN), 是对给定的训练样本, 经过多次迭代训练, 逐渐调整神经元间互连权值, 最终使系统达到误差收敛或达到最小误差要求的算法.

BP 神经网络是一种按误差反向传播的多层(至少 3 层)前馈网络. 由于其自身所具有的特性——非线性映射特性、多输入多输出特性和自组织自学习特性等, 使得 BP 神经网络能够更适合处理非线性多输入多输出的复杂问题.

BP 神经网络模型是由输入层、隐藏层(可以有多层, 但至少一层)和输出层构成的, 每层由许多并列的神经元组成, 同层内神经元之间不相互连接, 相邻层的神经元之间是全互连的方式连接. 神经元模型如图 1 所示, 标准的 BP 神经网络结构如图 2 所示. 图 1 中激活函数是将输入值乘以权值求和后的值转化为该节点的输出. 常用的激活函数是 Sigmoid 函数, 其数学形式为

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (1)$$

在构建完神经网络的拓扑结构后, 还需要对网络进行学习和训练, 才能使网络具有智能特性. 对于 BP 神经网络, 学习过程是由正向传播和反向修正传播两部分组成. 在正向传播过程中, 输入层到隐藏层的传递关系为

$$y_{hk} = f\left(\sum_{i=1}^N \omega_{hi} \cdot x_i + b_{hk}\right). \quad (2)$$

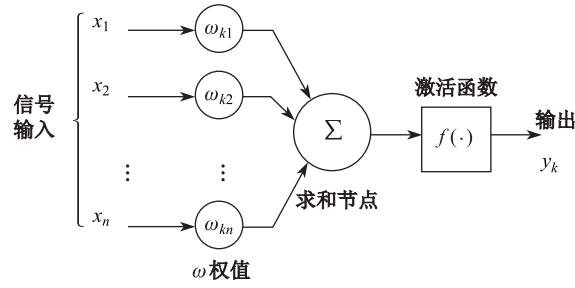


图 1 神经元模型

Fig. 1 Neuron model




图 2 标准 BP 神经网络

Fig. 2 Standard BP network

公式(2)中  $y_{hk}$  为隐藏层神经元的值, 作为输出层的输入,  $\omega_{hi}$  为输入层到隐藏层的权值,  $x_i$  为输入层的输入值,  $b_{hk}$  为隐藏层神经元的偏置, 函数  $f$  是激活函数.

输入样本从输入层经过隐含层神经元的传递函数(又称激活函数、转换函数)运算后, 传向输出层, 传递关系为

$$y_{ok} = f\left(\sum_{i=1}^M \omega_{oi} \cdot x_i + b_{ok}\right). \quad (3)$$

公式(3)中  $y_{ok}$  为隐藏层神经元的值, 作为输出层的输入,  $\omega_{oi}$  为输入层到隐藏层的权值,  $x_i$  为输入层的输入值,  $b_{ok}$  为隐藏层神经元的偏置, 函数  $f$  是激活函数.

在输出层计算实际输出, 如果得不到期望输出, 则转入反向传播. 反向传播修改权值的规则是根据当前网络的误差的变化来修改的, 迭代是否继续是根据当前网络误差均方差与要求迭代次数决定的, 误差均方差计算公式为

$$E = \frac{1}{S} \sum_{i=1}^S (Y_i - y_i)^2. \quad (4)$$

公式(4)中  $y_i$  为输出层神经元的输出值,  $Y_i$  为数据中的实际值.

标准 BP 神经网络权值修改方向是选择当前误差减小的梯度方向, 其公式为

$$\omega' = \omega + \Delta\omega = \omega - \eta \frac{\partial E}{\partial \omega}, \quad (5)$$

$\omega'$  为新的  $\omega$ , 其中  $\frac{\partial E}{\partial \omega}$  表示误差的梯度方向. 此时误差(实际输出与期望输出之差值)信号从输出层向输入层反向传播并沿途调整各层连接权值和阈值, 以使误差不断减小, 直到达到精度要求. 反向权值修正实际上是通过多个样本的反复训练, 并采用最速梯度下降法使得权值沿着误差函数负梯度方向改变, 并收敛于最小点或达到要求最小误差值或迭代次数达到最大值.

## 1.2 改进 BP 神经网络

由于标准 BP 神经网络有收敛速度慢和有可能陷入局部最小的缺点, 很多学者提出了相应的改进方法. 为了加快收敛, 在网络中引入共轭梯度法<sup>[7]</sup>、Levenberg-Marquardt<sup>[8]</sup>、遗传算法<sup>[9-11]</sup>、粒子群算法<sup>[12-14]</sup>和自适应学习<sup>[15]</sup>等; 为了防止陷入局部最小, 加入了动量因子法<sup>[15]</sup>等. 本文在对上述算法深入研究后, 针对动量因子初始值对网络收敛速度的影响提出了自学习的动量因子法, 其基本思想是在原有的梯度自学习的基础上再根据每次迭代误差的方差减小(增大), 来自适应增大(减小)动量因子的大小, 以消除动量因子初始值大小对收敛速度的影响, 在防止陷入局部最小值的同时, 加快网络的收敛速度.

附加动量项是当前时刻的上时刻权值参数, 并给出一个动量因子作为调整(经验值为 0 至 1 之间). 不同的动量因子结果收敛速度不同, 初始值设置不合适就会严重影响训练时间, 因此有必要让动量因子具有自学习的特性. 改进后的权值更新方法为

$$\omega'(N) = \omega(N) - \alpha \frac{\partial E(N)}{\partial \omega} + \eta \omega(N-1), \quad (6)$$

其中,  $\omega'(N)$  为新的  $\omega(N)$ ,  $\omega(N)$ 、 $\omega(N-1)$  为第  $N$  次和第  $(N-1)$  次连接权值,  $\alpha$  为网络学习率,  $\eta$  为动量因子,  $E(N)$  为第  $N$  次迭代时误差的均方差. 网络学习率  $\alpha$  和动量因子  $\eta$  的自学习是根据当前时刻误差均方差与上一时刻误差均方差的变化而做出的相应变化, 具体方式为

$$\Delta p(N) = \begin{cases} a \cdot p(N-1), & E(N) \downarrow, \\ -b \cdot p(N-1), & E(N) \uparrow, \\ 0, & E(N) \text{ 不变}, \end{cases} \quad (7)$$

$$p'(N) = p(N) + \Delta p(N). \quad (8)$$

式(7)、式(8)中  $a$  和  $b$  均大于 0,  $p'(N)$  为新的  $p(N)$ ,  $p$  代表  $\alpha$  和  $\eta$ ,  $E(N)$  为第  $N$  次迭代网络误差均方差,  $p$  根据当前时刻误差方差与前时刻相比变化而变化的. 第一次迭代时  $\alpha$  和  $\eta$  为设定的初始值. 第  $N(N > 1)$  次迭代时, 若误差  $E(N)$  变化小于 0, 说明当前方向是正确的方向, 增大  $\alpha$  和  $\eta$ ; 相反, 说明当前方向不是正确方向, 适当减小  $\alpha$  和  $\eta$ . 当  $E(N)$  不变, 保持  $\alpha$  和  $\eta$  不变. 网络学习率  $\alpha$  和动量因子  $\eta$  通常在 0 到 1 之间, 因此在  $\alpha$  和  $\eta$  变化时不应超出这个范围, 以避免出现大的波动和不收敛的情况.

## 2 改进 BP 神经网络在交通事故预测模型中的应用

### 2.1 样本数据的选取和预处理

导致交通事故的原因有多种, 如天气、道路、能见度、车辆、司机、行人、温度、光照和拥挤程度等. 交通事故与起因之间是一个复杂非线性关系, 对于其中的关系很难找到某种数学模型, 而神经网络建模预测对此类问题具有更好的有效性.

本文选取英国利兹市 2009 年到 2015 年 7 年间的公开交通事故数据集, 共计 18 886 条记录. 原始数据包括发生事故的环境因素、地理坐标、时间和事故严重程度等. 删除原始数据

集中无用的属性, 最终本文选取道路类别、道路表面、光照、天气、事故严重等级和车辆类别等 8 个属性的数据. 道路表面分为干燥、潮湿、积雪、冰霜和积水; 伤亡性别为男和女; 事故严重程度分为轻微、严重和致命; 其他不作详细描述. 属性类型为离散的文字描述或者数值. 对以上离散的描述属性进行数字化, 另外, 为了提高准确率, 对保留下来的属性做了归一化处理.

## 2.2 神经网络的构建

根据交通事故数据集中的属性, 考虑交通事故导致因素, 选取道路类别、道路表面、光照和天气等 7 个属性作为神经网络的输入, 事故严重程度作为神经网络的输出, 隐藏层神经元数目设定为 5 个, 构建单隐藏层的交通事故 BP 神经网络, 如图 3 所示. 考虑到双曲正切(tanh)函数与 Sigmoid 函数相比在该问题上有更好的效果, 激活函数采用双曲正切函数, 其形式为

$$f(x) = \tanh(x). \quad (9)$$

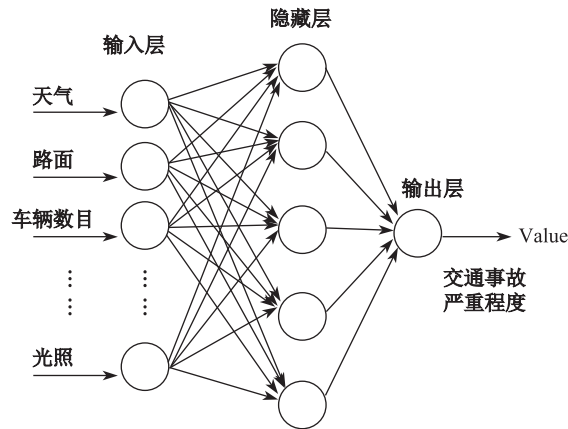


图3 交通事故的BP网络模型

Fig. 3 BP network model of traffic accidents

神经网络构建完成后, 并不具有预测功能, 还需要通过大量的计算来训练神经网络. 改进 BP 神经网络交通事故预测模型训练步骤如下.

- (1) 从文件中加载数据.
- (2) 初始化网络, 初始化权值.
- (3) 将训练样本提供给网络.
- (4) 逐条将样本数据提供给输入层, 用公式计算隐藏节点的值, 然后通过公式(2)计算隐藏层各节点的输出.
- (5) 将隐藏层的输出用公式(3)计算输出节点的输出值.
- (6) 用公式(4)计算期望值和实际输出值的误差  $E$ .
- (7) 按误差  $E$  变化更新隐藏层到输出层的权值, 并计算隐藏层各节点的误差  $E'$ , 按误差  $E'$  变化更新输入层到隐藏层的权值.
- (8) 计算每次迭代误差均方差, 按照公式(7)、公式(8)自适应调整网络学习率  $\alpha$  和动量因子  $\eta$ , 用公式(6)修改网络的权值.

(9) 进行下一次迭代, 返回到步骤 (3), 直至网络误差均方差  $E(N)$  小于预先设定的值  $\epsilon$ (精确度), 或者迭代次数  $N$  大于某个给定的值.

(10) 在未达到预先设定的迭代次数时收敛, 结束训练.

### 3 试验结果与分析

#### 3.1 改进方法后网络训练收敛速度的保障

根据上述交通事故神经网络模型构建训练方法, 用 python 编程语言编码实现, 并经过多次试验, 最终训练完不同神经网络模型. 其中,  $\alpha$  的初始值为 0.3,  $\eta$  的初始值为 0.4, 实验中为了避免波动过大, 对于  $\alpha$  和  $\eta$  的范围都限制在一定的范围内, 用已选的测试数据集进行预测验证, 改进后 BP 神经网络对比收敛效果如图 4、图 5 和图 6 所示.

在图 4 中, 黑色实曲线(normal\_BPNN)为标准 BP 神经网络误差均方差随迭代次数下降的曲线; 虚直线( $y = 0.031$ )为实验要求的均方差值, 下述图中所示的虚直线均同此.




图 4 标准BP神经网络

Fig. 4 The standard network

在图 5 中, 各不同线型的曲线为动量因子取固定值 0.1、0.3 和 0.4 时的误差均方差随迭代次数下降的曲线. 从图中曲线下降趋势明显可以看出, 固定动量因子的初始值对结果收敛的速度有很大影响.




图 5 动量因子取固定值为 0.1、0.3 和 0.4 的网络

Fig. 5 Network with fixed momentum 0.1, 0.3 and 0.4

在图 6 中, 黑色实曲线为自学习动量因子初始值取 0.4 时, 误差均方差随迭代次数下降的曲线; 黑色点划曲线为固定动量因子初始值取 0.4 时, 误差均方差下降的曲线, 曲线有很明

显的收敛速度差异, 说明了改进后 BP 神经网络在动量因子为 0.4 时具有更快的收敛速度.




图6 自学习动量因子为 0.4 和固定值 0.4

Fig. 6 Self-learning momentum factor 0.4 and fixed value 0.4

为了验证不同动量因子初始值在自学习情况下都有更快的收敛速度, 取动量因子  $\eta$  初始值为 0 到 1 之间等距 19 种情况进行试验, 其平均收敛情况如图 7 所示. 图 7 中, 黑色实曲线为改进后 BP 神经网络误差均方差随迭代次数下降的曲线; 黑色点划曲线为固定动量因子 BP 神经网络误差均方差随迭代次数下降的曲线, 误差均方差大小已取 19 种情况的平均值. 两曲线有明显的收敛速度差异, 验证了改进后 BP 神经网络有更快的收敛速度.




图7 自学习动量因子和固定值在0到1之间

Fig. 7 Self-learning momentum factor and fixed value between 0 and 1

### 3.2 改进方法后预测结果准确率的提升

为了验证改进方法预测准确率, 选取迭代次数为 1 200 次、网络学习率初始值  $\alpha$  为 0.3、动量因子  $\eta$  为 0 到 1 之间等距 19 种情况, 完成对标准神经网络、固定动量因子和自学习动量因子神经网络方法预测模型的训练, 然后对测试数据集进行预测验证.

将测试数据集输入到已经训练的模型中, 不同预测模型就会得到不同的预测结果, 也就是网络对应输入的输出值(不同的事故严重程度值) 分别对应轻微、严重和致命. 与实际严重程度进行对比, 标准 BP 神经网络、固定动量因子神经网络和自学习动量因子神经网络的模型预测结果如表 1 所示.

表 1 不同方法的预测准确率

Tab. 1 The prediction accuracy of different methods	
网络类别	平均准确率(动量因子 $\eta$ 取 0 到 1 之间)
标准网络	0.87
固定动量因子	0.9
自学习动量因子	0.913

由表 1 可以明显看出, 在网络训练相同的迭代次数情况下, 改进后网络预测的准确率要比标准网络和固定动量因子法的准确率高一点. 准确率平均仅提升为 1.3 个百分点, 是因为交通事故诱导因素的不确定性以及原数据集并没有包含全部诱导因素, 这正是决定算法准确率的上限值. 但这仅有的提升对于交通事故对人的生命财产造成的重大损失也是很有意义的.

由预测结果的准确率也可以看出, 预测模型中神经网络输入层所输入的道路表面、光照、天气等因素与交通事故严重程度关联很大, 可以考虑在以上因素上采取措施以减少交通事故的发生.

#### 4 结束语

本文在深度研究加快 BP 神经网络收敛速度的改进方法后, 提出了一种消除动量因子初始值对收敛速度的影响的自学习动量因子法, 并通过大量的交通事故预测实验验证了该算法的有效性. 预测模型综合考虑了交通事故的多种导致因素, 构建了自学习动量因子改进 BP 神经网络. 由于神经网络在非线性、不易建数学模型的问题上的优越性, 改进后的网络能够很好地收敛到一定值, 并且能够很好地预测事故的严重程度.

对交通事故严重程度的预测不是真正的目的, 最根本的目的是在出现相同环境时, 能够及时给出预防策略, 在事故发生前把损失降到最低, 确保交通网络不受交通事故影响而阻塞, 保障人的生命和财产不受损失. 由于本实验受数据集影响, 未能充分考虑交通事故发生的所有诱发因素, 将来可以在更换数据集方面进一步提高预测准确率.

#### [参 考 文 献]

- [1] ZHU P, LIN C Y, WU P, et al. Permeability prediction of tight sandstone reservoirs using improved BP neural network[J]. The Open Petroleum Engineering Journal, 2015, 8(1): 288-292.
- [2] ZONG F, XU H G, ZHANG H Y. Prediction for traffic accident severity: Comparing the Bayesian network and regression models[J]. Mathematical Problems in Engineering, 2013(3): 206-226.
- [3] 李铃铃, 仇蕾. 基于灰色神经网络组合模型的水上交通事故预测[J]. 交通信息安全, 2014, 32(3): 110-118.
- [4] 唐秋生, 杜营营. 基于 BP 神经网络的交通事故预测模型及仿真[J]. 交通信息安全, 2011, 29(1): 68-70.
- [5] ABELLÁN J, LÓPEZ G, OÑA J D. Analysis of traffic accident severity using decision rules via decision trees[J]. Expert Systems with Applications, 2013, 40(15): 6047-6054.
- [6] 赵玲, 许宏科. 基于改进的灰色马尔可夫链模型的交通事故预测[J]. 数学的实践与认识, 2013, 43(20): 92-98.
- [7] 邢晓敏, 商国敬. 基于改进共轭梯度理论神经网络优化算法研究[J]. 电器与仪表, 2014, 51(19): 36-40.
- [8] 张峤, 邓贵仕. Levenberg-Marquardt 神经网络在煤矿作业人员人因可靠性评价中应用研究[J]. 大连理工大学学报, 2015, 55(4): 424-430.
- [9] 焦纲领, 王士星. 基于遗传算法的神经网络参数优化研究[J]. 数学的实践与认识, 2012, 42(11): 176-183.
- [10] 刘春艳, 凌建春, 寇林元, 等. GA-BP 神经网络与 BP 神经网络性能比较[J]. 中国卫生统计, 2013, 30(2): 173-181.
- [11] 高玉明, 张仁津. 基于遗传算法和 BP 神经网络的房价预测分析[J]. 计算机工程, 2014, 40(4): 187-191.
- [12] 许榕, 周东, 蒋士正, 等. 自适应粒子群神经网络交通流预测模型[J]. 西安交通大学学报, 2015, 49(10): 103-109.
- [13] 张德慧, 张德育, 刘清云, 等. 基于粒子群算法的 BP 神经网络优化技术[J]. 计算机工程与设计, 2015, 36(5): 1321-1326.
- [14] 江丽, 王爱平. 基于粒子群优化与 BP 算法的协同神经网络学习方法[J]. 计算机应用与软件, 2013, 30(9): 19-20.
- [15] 刘卫宁, 王鹏, 孙德华, 等. 基于改进 BP 神经网络的道路交通事故预测[J]. 计算机系统应用, 2010, 19(10): 177-181.

(责任编辑: 李 艺)