

基于神经网络的城市道路交通诱导算法设计

张扬永

(中共福建省委党校, 福建 福州 350001)

摘 要:针对道路交通信息化管理的问题,考虑到基于神经网络的城市道路交通诱导算法有助于提升高峰时段通行效率,本文利用传统的 BP(back propagation)神经网络,迭代计算 20 次。结果表明,在城市道路交通诱导方面可取得较好的效果,高峰时段提升近 15% 的通行效率。

关键词:智能交通系统;神经网络;道路交通;诱导算法

中图分类号:U495 **文献标志码:**A **文章编号:**2095-4824(2021)06-0071-06

随着 21 世纪科学的发展,我国经济与社会等方面取得了飞跃式的发展,汽车已成为现代文明与进步的象征和标志,而且是城市和乡村的社会生活中不可缺少的重要组成部分,给城乡面貌带来巨大的变化,尤其是城市规模和道路发展^[1-2]。道路交通是社会和经济活动的关键纽带,在促进城市和区域经济发展以及提高人民生活水平方面都有着极其重要的作用,其信息化管理水平也伴随着社会经济的发展而不断提高。然而,现实中城市规模的不断扩大,交通参与人及机动车数量剧增,带来了一系列的交通管理问题。同时,与大力度投入建设道路相比,现代化的技术手段能进一步发挥道路网络的潜在功能,全面提高运输效率,缓解道路交通紧张局面,其投入少、见效快,更具有现实意义^[3-4]。因此,智能交通系统(intelligent traffic system, ITS)应运而生,它是运用先进的计算机信息技术、计算机通讯技术、物联网技术,建立适合城市范围内,实时、准确、高效的综合运输和管理系统,有效地集成运用于整个交通运输管理体系^[5]。鉴于 ITS 在道路交通管理中的应用有很大成效,前期也有很多学者研究卫星技术、信息技术、数据通讯传输技术、电子传感技术、电子控制技术和计算机处理技术等,在 ITS 中的综合应用,也借鉴了国外 ITS 应用^[6]。然而,我国道路

交通信息化一方面存在管理认识模糊、不到位,信息孤岛现象突出、队伍素质不够高、管理体制不适应和无经济保障等问题,另一方面,国外道路设计、人口分布、交通量、变化规律等与我国有较大区别,因此,我国学者在 ITS 方面的研究逐步转向动态全球定位系统(global positioning system, GPS)诱导、路段速度估算、人工智能应用等道路交通诱导技术上,涉及诱导改进算法和模型有 KNN((K-nearest neighbor)、BP、CNN(convolutional neural network)、LSTM(long-short term memory)等,从而强调了计算机算法提升在道路交通中的应用^[2,7]。跟以往强调大规模的基础建设投入相比,本文更加强调运用科学技术和计算机算法改进智能交通方面的应用,针对现有道路交通诱导技术,应用神经网络技术改善道路交通,提高道路交通人工智能应用水平。

1 道路交通诱导技术

1) 动态 GPS 诱导技术。GPS 是为了在全球范围内,向用户提供精确的、连续的三维位置和速度信息,与 GPS 密切相关的信息技术还有地理信息系统(geographic information system, GIS)是在计算机硬、软件系统支持下,分析和处理海量地理数据的通用技术,主要针对地理分布的数据进

收稿日期:2021-09-03

作者简介:张扬永(1964-),男,福建永泰人,中共福建省委党校副教授。

行采集、储存和相关处理的技术系统。GPS/GIS系统在ITS中应用,尤其是交通管理方面日益显示出巨大能力,将动态GPS技术引用到我国各大城市道路交通管理当中,设计城市道路交通诱导系统,缓解交通拥堵现象,减轻交通压力,提高城市道路交通运输效率,成为提高道路交通管理的重要手段^[8-9]。动态GPS诱导技术应用有如下两方面。

路线优化模块:交通信息服务子系统是交通诱导系统的重要组成部分,它把主机运算出来的交通信息(包括预测的交通信息)通过各种传播媒体传送给公众。这些媒体包括有线电视、联网的计算机、收音机、路边的可变信息标志和车载的信息系统等。

行车路线优化子系统:依据车辆定位子系统所确定的车辆在网络中的位置和出行者输入的目的地结合交通数据采集子系统传输的路网交通信息,为出行者提供能够避免交通拥挤、减少延误及高效率到达目的地的行车路线。在车载信息系统的显示屏上给出车辆行驶前方道路的路网状况图,并用箭头线及各种颜色标示建议的行驶路线和最佳路线。

2) 路段速度估算技术。该技术(部分学者使用路段流量估算研究,都是交通流最基本也是最重要的参数,其估算基本思想相似)是利用路段部分车辆的平均行驶速度代表实际路段速度,同时也体现了道路服务水平^[10-11]。然而准确估计路段速度不仅非常关键,而且有一定技术难度,受采样时间、GPS点数、路段距离干扰较大,如采样时间间隔越长,速度估算越不准确;GPS点数越少,速度估算也越不准确。当前研究热点在不同的时间段(同时区分工作日和周末)以及相邻路段的速度预测,部分研究表明路段估算速度与路段真实速度(一般取实际速度的平均值)之间的误差越少,其模型越好,而模型效果大多依赖于现有数据集集中的数据成分,如车辆数量越多则误差越少,数据偏少时则会出现相邻路段数据与当前路段的数据预测不符^[12-13]。通常情况下,GPS点数、路段分布和不同的计算时间均会影响预测结果,因此单一的路段速度估算技术,往往只能适用其中的一类数据集效果,应用到其他数据集则效果变差。路段节点之间交通流的影响规律本身就比较复杂,如路段节点之间拥堵可能会影响其他多个路段节点的交通流,不仅停留在与相邻路段节点之

间,而且,要考虑相对路段信息的随机、动态特征在路段速度估算技术中的应用,开始结合神经网络和数据融合技术,也逐渐发展到人工智能在ITS中的应用。

3) 人工智能应用技术。人工智能(artificial intelligence, AI)技术日益成熟,应用领域也不断扩大,从计算机科学的一个分支发展到十分广泛、复杂的科学,其中以神经网络为基础发展起来的机器学习模型成为长期研究热点。机器学习的基础理论为统计学、信息论和控制论,对历史数据(也称经验)有着重要的依赖,如神经网络模型中的输入端均为历史数据已经发生过的信息,输出端为历史数据发生的结果,在不断的学习(多次迭代的学习称“深度学习”)中调整网络中的权重,从而减少拟合值与实现值的误差^[14]。近年来,人工智能各类算法层出不穷,模型的验证方式并不统一,为检验人工智能各类算法的效率、准确率等,国内外大数据相关机构逐步完善了各类数据集(一般分为训练集和测试集),在智能交通领域上,最为典型的开放数据集为美国的交通部数据(<https://www.its.dot.gov>)。深度学习在道路流量预测主要包括短期交通流量和中长期交通流量等的预测,由于ITS应用更偏向于时效性,因此更加注重短期交通流量预测,相关预测有交通流量,交通速度,交通密度等^[15-16]。较早人工智能模型是基于传统数学方法和时间序列,如:最近邻算法(KNN)、自回归模型(autoregressive, AR)、滑动平均模型(moving average, MA)、自回归滑动平均模型(auto-regressive and moving average, ARMA)等,随着研究的深入,更高预测精度的方法逐渐转向支持向量机模型(support vector machine, SVM)、人工神经网络模型(artificial neural network, ANN)等,其中神经网络模型具有良好适应性的预测优势,以及随着训练样本不断累积,其性能表现越优,因此受到学者们的热捧,如:深度信任网络模型(deep belief network, DBN)、卷积神经网络(CNN)、递归神经网络(recurrent neural network, RNN)等常用于流量预测的通用基本网络模型^[14-18]。

2 算法设计

当前,随着深度学习技术在各行各业的应用,相关的方法及变形越来越多,本文以BP神经网络在城市道路交通诱导路线应用进行算法设计,

从而提升 ITS 的道路交通诱导能力。根据选取的实验道路的数据集,以路况起始时间、结束时间对行车方向、车道数、车流量、平均速度、车道占有率、视频信号状态、车辆信息等数据作为输入,输入节点以随机权重传输至隐藏层,然后通过神经网络中间隐藏层不定层数和节点数(均大于等于 1),训练其输出与交通路况(1-顺畅,2-缓慢,3-拥堵)预期是否一致,不一致的误差进行反向修正权重,不断训练以期获得较理想的结果,BP 神经网络传递过程如图 1 所示。




图 1 神经网络模型

BP 神经网络模型包括信息的前向传播和误差的反向权重修复传播两个过程,通过不断迭代进行修复权重信息,该模型首先读取道路交通数据集,获得输入矩阵 I ,设置学习率、迭代次数等信息,以下步骤分前向传播和误差反向传播进行说明:

1)前向传播

Step 1. 初始化权重矩阵 W_{ij} , i 表示网络中每层的节点数, j 为当前层节点传到下一层的节点数,最后一层节点数即为输出层的节点数

$$X = W \cdot I \quad (1)$$

Step 2. 应用激活函数传输给下一层

x 是组合后的数据,还需要对 x 进行激活,激活形式多样化,其效果也不一样,本研究采用 ReLU 激活函数。

$$O = f(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{if } x < 0 \end{cases} \quad (2)$$

Step 3. 如果隐藏层多层则重复执行公式(1)和公式(2)的操作步骤,直至输出到最后一层即输出层。

2)误差反向传播。

Step 1. 计算总误差 error,即输出层与目标值之间的差值。

$$e_{output} = target \cdot O_{output} \quad (3)$$

Step 2. 反向传播误差,根据输入权重分配各自的误差是当前神经网络中最普遍的一种做法,反向传播时需要将输入的权重矩阵 W_{ij} 进行转置即 W^T ,重复传播误差直至网络的第一层。

$$e_{n-1} = e_n \cdot W^T \quad (4)$$

Step 3. 权重修正,通过误差来修正权重,在此引入神经网络的学习率 a 即梯度下降

$$W_{ij} = W_{ij}(\text{old}) - a \cdot \frac{\partial E}{\partial W_{ij}} \quad (5)$$

重复前向传播和误差反向传播直至迭代完成才退出网络,BP 前向传播和反向传播误差的训练过程的算法如下:

算法 1 BP 前向传播和反向传播误差(Python)

```

Inputs: self:BP 网络模型含 lr 学习率、weights 权重矩阵、level 隐藏层数、activation_function 激活函数,
        inputs_list:输入列表(集合),交通流信息
        targets_list:输出列表(集合),交通状况

Outputs: self: 训练后的 BP 模型

1  inputs = numpy.array(inputs_list, ndmin=2).T # 分别对输入和输出进行矩阵运算
2  targets = numpy.array(targets_list, ndmin=2).T
3  ins = [(0 * 2) for i in range(self.level + 1)]
4  outs = [(0 * 2) for i in range(self.level + 1)]
5  errors = [(0 * 2) for i in range(self.level + 1)]
6  ins[0] = numpy.dot(self.weights[0], inputs) # 第一层节点的初始化
7  outs[0] = self.activation_function(ins[0]) # 激活函数
8  for i in range(1, self.level + 1):
9      ins[i] = numpy.dot(self.weights[i], outs[i - 1]) # 隐藏层的输入等于输入层链接权重矩阵 * 输入矩阵
10     outs[i] = self.activation_function(ins[i]) # 隐藏层的输出要对计算的【隐藏层的输入】进行 S 函数激活
11     pass # 以上为对各层节点的输入与输出进行权重矩阵 * 输入矩阵计算,这为前向操作
    
```

算法 1 BP 前向传播和反向传播误差(Python)(续)

```

12 final_outputs = outs[self.level] # 最后一个输出即为最终结果
13 errors[self.level] = targets - final_outputs # 输出误差 = 目标 - 网络输出
14 for i in range(self.level, 0, -1): # 循环倒序, 第一个错误从上面获得, 因此不考虑最后一个错误
15     errors[i-1] = numpy.dot(self.weights[i].T, errors[i]) # 误差获取完成后开始修正权重, 这两步操作
    均为反向操作
16 for i in range(self.level, 1, -1): # 循环倒序, 权重更新不需要考虑最后一层, 规则每层分摊都一样, 但要
    考虑第一层, 因为第一层的输入即为第二层的输入
17     self.weights[i] += self.lr * numpy.dot((errors[i] * outs[i] * (1.0 - outs[i])), numpy.transpose
    (outs[i-1])) # 前馈误差 = 输出层链接权重转置矩阵 * 输出误差
    self.weights[0] += self.lr * numpy.dot((errors[0] * outs[0] * (1.0 - outs[0])), numpy.transpose
18 (inputs)) # 更新输入层链接权重: 学习率 * [隐藏误差 * 隐藏输出结果的求导, 再与隐藏输入的转置矩阵
    相乘]

```

3 效果分析

1) 实验数据及场景说明。本研究在软件上使用 MyEclipse 2017 CI 开发工具相结合, 开发语言为 Python3.7, 训练模型为 BP 神经网络。研究选取了安徽省黄山市徽州区黄山路段进行测试, 实

验时间为 2016 年 6 月 22 日至 2016 年 6 月 30 日, 测试路段信息包括了地磁检测数据(81.1 万条记录)和路口交通流检测数据(15.3 万条记录), 实验数据说明如表 1 所示, 测试路段样例如图 2 和图 3 所示, 图 2 为路段全景示意图, 图 3 为黄山路西的信号控制的交叉口。

表 1 实验数据

NO	类型	样本数	说明
1	地磁检测数据	811081	设备及检测器编号
2	交通流检测数据	153379	地磁检测对应的车流量(辆)、车辆平均速度、车辆密度、交通路况、车辆类型等交通流检测数据



图 2 测试路段展示

为了让采集的数据在神经网络的训练更加稳定、有效, 由于道路交通数据中以时间序列为主, 没有负值, 实验数据规范化采用比较简单的数据自归一化处理(列的归一化), 以时速为例, $Speed_i = Speed_i / Speed_{max}$, 即当前时速值除以时速的最大值。实验过程, 主要以车流量(辆)、车辆平均速度(km/h), 车辆密度(辆/km)展开训练, 这三项指标标志着道路交通的交通路况(1-顺畅, 2-缓慢, 3-拥堵流量), 在工作日以早高峰、晚高峰尤其明显, 车流量变大, 容易造成拥堵, 车流量高峰时段每天的变化如图 4 所示。




图 3 信号控制交叉口




图 4 晚高峰车流量变化趋势

2) 结果分析。由于现实中车流量存在不稳定因素, 在交通要素中很难被调控, 然而可以在早晚

高峰时段,车流量、车辆密度平均比非高峰时段高一倍,除非工作日外(2016年6月25日、26日分别为星期六、星期天),车辆密度在非工作日有较大下降,如图5和图6所示。而车速指标则相反,在高峰时段明显低于非高峰时段,由于在道路路口时速为零的信息较多,因此统计出来的平均时速与实际有所偏离,如图7所示。




图5 交流平均车流量对比




图6 交流平均车辆密度对比




图7 交流平均车速对比

在BP神经网络的训练中,以提升早高峰、晚高峰通行效率(即减少车辆密度)和提升平均车速为主要目标,具体训练参数见表2,以2016年6月22日到29日为训练集,2016年6月30日为测试集,训练结果的高峰时段和非高峰时段分别如图8、图9所示。




图8 高峰时段平均车速和密度训练效果




图9 非高峰时段平均车速和密度训练效果

通过人工智能算法干预的道路信号变化,确实提升了车辆通行速度,减少了车辆密度,在高峰时段的效果比较明显,可提升近15%的通行效率($efficiency_i = speed_i \times diffdensity_i$,路口单位车道通行效率(辆/时)),有效减少了拥堵的时长,非高峰时段改进不如高峰时段明显,因此,BP神经网络在城市道路交通的诱导系统中的应用确实有效。

表2 BP神经网络模型的参数

NO	参数	值	说明
1	输入层	15	地磁检测和交通流检测数据
2	输出层	4	车流量(辆)、车辆平均速度、车辆密度、交通路况
3	隐藏层数	2	
4	激活函数	ReLU	
5	学习率	0.01	可调整更小
6	迭代次数	10, 20, 50, 100	不同迭代比较准确率

4 结语

伴随着城市规模的扩大和人口、车辆增多,城市的发展受到城市交通问题严重困扰,交通拥堵、

交通事故以及交通带来的环境污染问题等已经严重制约了城市的发展步伐。尽管经过多年的软硬件投入,各种诱导技术都取得了显著的进步,然而面对城市经济和社会发展而带来的客运、货运的

需求越来越大,道路交通管理信息化及诱导技术仍不能够满足现代交通运输业发展的实际需求。跟以往强调大规模的基础建设投入相比,基于神经网络的城市道路交通诱导算法研究更加强调人工智能技术和算法方面的应用,以期实现某道路子系统的高效率运行,从而提升整个城市道路交通系统效率。后续道路交通诱导技术问题,还可以从两方面入手去改善道路交通环境:一方面提高管理水平、推进道路交通信息化管理,如ITS人工智能;另一方面将新型科技应用到道路交通信息化管理当中,如车联网。

[参 考 文 献]

- [1] 许卫华,郭海峰.不同交通流状况下车辆分布式协同调度仿真[J].计算机仿真,2020,37(7):178-182.
- [2] 张立立,王力,张玲玉.城市道路交通控制概述与展望[J].科学技术与工程,2020,20(16):6322-6329.
- [3] 贾鹏,胡燕,袁爽,等.中国省域综合交通运输效率及空间关联性研究[J].科研管理,2020,41(9):219-229.
- [4] 刘旷,马良,范炳全.综合交通运输方式协调发展评价实例研究[J].上海理工大学学报,2009,31(4):392-395.
- [5] 高柯夫,孙宏彬,王楠,等.“互联网+”智能交通发展战略研究[J].中国工程科学,2020,22(4):101-105.
- [6] 赵娜,袁家斌,徐盼.智能交通系统综述[J].计算机科学,2014,41(11):7-11.
- [7] 杨坤,张大为.城市片区智能交通系统方案设计[J].交通标准化,2014,42(19):28-33.
- [8] 张扬永.基于动态GPS的城市道路交通诱导系统设计与实现[J].湖北工程学院学报,2015,35(6):38-44.
- [9] 孔庆杰,史文欢,刘允才.基于GPS轨迹的矢量路网地图自动生成方法[J].中国科学技术大学学报,2012,42(8):623-627.
- [10] 韩直,徐冲聪,韩嵩乔.基于短时交通流预测的广域动态交通路径诱导方法[J].交通运输系统工程与信息,2020,20(1):117-123.
- [11] 丁栋,朱云龙,庠涛,等.基于影响模型的短时交通流预测方法[J].计算机工程,2012,38(10):164-167.
- [12] 曾伟良,聂佩林,何兆成,等.结合神经网络和数据融合技术的城市路段速度估计[J].计算机应用研究,2011,28(12):4459-4462.
- [13] 沈国江,王啸虎,孔祥杰.短时交通流量智能组合预测模型及应用[J].系统工程理论与实践,2011,31(3):561-568.
- [14] 马焱棋,林群,赵昱程,等.基于深度学习LSTM对交通流状态的预测[J].数学的实践与认识,2021,51(4):47-56.
- [15] 林浩,李雷孝,王慧.支持向量机在智能交通系统中的研究应用综述[J].计算机科学与探索,2020,14(6):901-917.
- [16] 满春涛,康丹青.考虑上下游的LSTM短时交通流量预测[J].哈尔滨理工大学学报,2019,24(5):101-107.
- [17] 龙其,叶晨,张亚英.动态路网中基于实时路况信息的分布式路径生成算法[J].计算机科学,2014,41(9):259-263.
- [18] 朱荀,刘国强,丁华平,等.一种通过支持向量机对交通拥堵情况进行分类的方法[J].南京大学学报(自然科学版),2020,56(2):278-283.

(责任编辑:熊文涛)