

基于 AB 神经网络模型的车牌定位方法

章晔炜, 官宁生

(南京工业大学 电子与信息工程学院, 江苏 南京 211816)

摘 要: 提出了一种基于 AB 神经网络模型的车牌定位方法, 利用区域直方图和矩形滑动窗口法进行车牌的第一次定位, 再利用区域均值法和均值跳变法进行车牌的精确定位。实验证明, 该方法速度快, 准确度高。

关键词: AB 神经网络; BP 神经网络; 直方图; 车牌定位

中图分类号: TP29

文献标识码: A

文章编号: 1000-7180(2014)08-0001-04

License-plate Positioning Method Based on AB Neural Network Model

ZHANG Ye-wei, GONG Ning-sheng

(College of Electronics and Information Engineering, Nanjing University of Technology, Nanjing 211816, China)

Abstract: This paper proposes a license plate positioning method based on AB neural network model. The regional histogram method and rectangular sliding window method have been used for the first-time positioning of license plate, and the regional average method and average beep method have been used for the fine positioning part. The experiment shows that this method is fast and highly accurate.

Key words: AB neural network; BP neural network; histogram; license-plate positioning

1 引言

随着经济的快速发展, 现实生活中很多场合需要方便快速地获取车牌信息。人工方法记录车牌信息往往会出现笔误, 车牌识别系统作为智能交通系统的重要组成部分已经被广泛应用。

车牌识别系统主要分为三大部分, 即车牌定位、字符分割、字符识别。其中车牌定位是车牌识别系统中至关重要的一个环节, 本文提出了一种基于 AB 神经网络模型的车牌定位方法, 能够快速准确地定位到汽车图像中的车牌区域。

2 AB 神经网络

2.1 AB 神经网络模型

人工神经网络是一种模拟生物神经元工作方式

的方法, 具有很强的学习能力和自适应能力, 同时具有很强的容错性和鲁棒性。BP 神经网络是众多神经网络模型之一, 它是一种多层前馈网络, 使用梯度下降法按照误差反向传播算法进行训练, 调整网络的权值和阈值, 从而使误差绝对值最小。由于使用时的计算速度很快, BP 神经网络得到了广泛的应用^[1]。

标准 BP 神经网络的收敛速度一直不容乐观, 这是其很大的缺陷。本文改进了传统的 BP 算法^[2], 使用 AB 神经网络模型, 加快 BP 算法的收敛速度。AB 神经网络模型如图 1 所示。

AB 神经网络模型由 A 网和 B 网两个 BP 神经网络构成。其中 B 网是工作网, 负责实际应用中样本的训练, A 网是控制网, 根据 B 网的反馈动态地调整 B 网训练时所需的参数, 从而减少 B 网的训练时间。

收稿日期: 2013-10-11; 修回日期: 2013-12-01

基金项目: 国家重点基础研究发展计划(“九七三”计划)(2005CB321901); 软件形式发环境国家重点实验室开放课题(BUAA-SKLSDE-09KF-03)




图1 AB神经网络模型

标准的BP训练算法采用固定的学习步长,步长的选取影响网络的收敛速度.步长过大容易使网络误差震荡过大,过小网络的收敛速度则过慢.BP网络的权值调整公式为

$$\Delta\omega_{ji}(n+1) = \lambda\delta_{kj}o_{kj}$$

$$\omega_{ji}(n+1) = \omega_{ji}(n) + \lambda\delta_{kj}o_{kj}.$$

为了加快BP神经网络收敛速度同时使其不易陷入局部极小,本文使用AB神经网络模型,用A网根据B网每次训练后的误差与上一次训练后误差的差值动态地调整B网的学习步长 λ .

2.2 AB网络的构造

B网的输入层和输出层节点数根据实际情况确定.本文B网的隐层选取单层隐层,隐层节点数根据经验公式选取: $h = \sqrt{a+b} + m$,其中, h 为隐层节点数, a 为输入层节点数, b 为输出层节点数, m 为1到10之间的整数.

A网的输入层节点数为1,表示B网每次训练后本次误差 E_i 与上一次误差 E_{i-1} 的差值 ΔE ,输出层节点数也为1,表示B网下一次训练所采用的步长 λ ,隐层节点数根据上述经验公式选取.

2.3 B网误差的改进

标准BP算法中,对于每个样本 p ,误差计算公式为

$$E_p = \frac{1}{2} \sum_{j=1}^n (T_j - o_j)^2,$$

式中, n 为输出层节点数, o_j 为输出层第 j 个节点的输出.对于 m 个样本的总误差公式为

$$E = \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n (T_j^i - o_j^i)^2.$$

每个样本训练时,都会修改权矩阵.由于每次权矩阵修改后都没有考虑修改后的权值对其他样本的输出误差是否也减小,因此迭代次数将增加.本文使用均方误差,减少训练迭代次数,均方误差公式如下:

$$MSE = \sum_{i=1}^m \sum_{j=1}^n (d_{ij} - y_{ij})^2 / (m \cdot n)$$

均方误差MSE是指估计值与真实值之差平方的期望值.MSE越小,说明预测模型描述实验数据精度更高.它不针对某一特定样本,是衡量平均误差

的一种较为方便的方法.

2.4 A网样本的获取

A网样本的获取是A网构造过程的关键,具体方法如下:

(1) 对B网进行训练,若本次训练后的均方误差与上次训练后的均方误差的差值 $\Delta MSE < 0$,则用临时数组记录B网本次训练调整后的权矩阵;

(2) 将某个区间内的步长和(1)中记录的权矩阵带入B网进行训练,并计算均方误差,搜索使B网均方误差最小的最优学习步长 λ ;

(3) 记录B网本次均方误差和上次均方误差的差值和最优学习步长作为A网的训练样本.

2.5 A网控制B网的过程

- (1) 获取A网的样本 $(\Delta MSE, \lambda)$;
- (2) 将A网的样本带入A网进行训练;
- (3) 对B网进行训练;
- (4) 计算B网本次均方误差 MSE_i ,若 MSE_i 达到精度要求,则转至(7)结束.
- (5) 计算B网本次均方误差 MSE_i 与上一次均方误差 MSE_{i-1} 的差值 ΔMSE 并反馈给A网;
- (6) 若 $\Delta MSE < 0$,调用A网,将 ΔMSE 作为A网的输入计算输出步长 λ ,将 λ 传给B网作为B网下一次训练所采用的步长,转至(3);
- (7) 结束.

本文车牌定位的流程图如图2所示.




图2 车牌定位流程图

3 车牌的第一次定位

3.1 车牌特征的提取

本文使用RGB颜色空间,采用区域直方图法提取车牌特征^[3-4].每个像素的颜色都是由红(R)、绿(G)、蓝(B)三个分量组成的,通过R、G、B三种基本颜色不同程度的叠加可以生成各种各样的颜色.通过实验观察可发现车牌区域和非车牌区域图像的R、G、B直方图信息有着显著的差异,主要表现在均值、标准差、峰值高度和峰值坐标,因此可以提取车牌区域的直方图特征进行车牌定位.

计算一幅图片R、G、B分量的直方图.对于R

分量,其直方图的横坐标为 R 值,取值范围为 0~255,纵坐标为图片中相应的 R 值出现的次数,这样就可以绘制 R 分量的直方图.采用同样的方式,可得到 G 分量和 B 分量的直方图.根据 R、G、B 直方图,计算每个分量的均值、标准差、峰值高度和峰值坐标,计算公式如下所示.

(1) 计算 R、G、B 分量的均值 μ_R 、 μ_G 、 μ_B :

$$\mu = \sum_{i=0}^{255} i \cdot H_i / (m \cdot n),$$

式中, m 和 n 分别为区域的宽度和高度, i 为 R、G、B 分量的值,取值范围为 0~255, H_i 为相应的 i 值出现的次数,即为直方图中横坐标 i 所对应的 i 坐标的值;

(2) 根据 R、G、B 的均值,分别计算 R、G、B 分量的标准差 s_R 、 s_G 、 s_B :

$$s = \sqrt{\sum_{i=0}^{255} H_i (i - \mu)^2 / (m \cdot n - 1)};$$

(3) 计算 R、G、B 直方图的峰值高度 $H_{\max}$:

$$H_{\max} = \max\{H_0, H_1, H_2, \dots, H_{255}\};$$

(4) 峰值坐标 φ 为 $H_{\max}$ 对应的横坐标.

本文汽车图片尺寸为 704×576 ,位深度为 24 位.车牌特征提取的具体步骤如下:

(1) 检测区域的确定.检测区域选取图片中间 600×500 的长方形区域;

(2) 将检测区域划分为边长为 n 个像素的方格;

(3) 逐行遍历方格,计算每个方格 R、G、B 三个分量的直方图信息,包括均值、标准差、峰值高度、峰值坐标,每个方格均可获取包含 12 个数据的结果集;

(4) 将(3)中的结果标准化至 0 到 1 之间的值,供神经网络学习.

车牌的长宽比大约为 14:5,本文车牌区域大约为 280×100 像素,故本文中 n 取 20,这样车牌区域方格数为 14×5 .

3.2 AB 神经网络的训练及使用

B 网学习样本的选取.从多张图片中,选择一些是车牌区域的方格和不是车牌区域的方格,将其 R、G、B 直方图信息的 12 个数据标准化作为 B 网的输入向量,令输出向量分别为 0.9 和 0.1,见表 1.

表 1 B 网样本的输出向量

输入样本类别	输出向量
车牌区域样本	0.9
非车牌区域样本	0.1

本文共选取了 300 个训练样本,其中车牌区域的样本个数为 100,非车牌区域的样本个数为 200.

A 网学习样本的选取.根据 A 网学习样本的获取方法,获得 A 网的学习样本.本文中 A 网的部分学习样本见表 2.

表 2 A 网的部分学习样本

输入 ΔE	期望输出 λ
-0.012 678 3	0.291 647
-0.012 956 7	0.311 345
-0.013 237 8	0.387 489
-0.014 352 3	0.412 265
-0.014 681 2	0.439 647
-0.014 939 7	0.461 289
-0.015 287 9	0.499 648
-0.015 334 8	0.556 607
-0.016 123 8	0.598 314
-0.016 748 3	0.635 976
-0.017 558 9	0.661 375
-0.017 862 3	0.679 462
-0.018 296 7	0.691 208
-0.018 728 1	0.699 738

本文中 B 网的初始学习步长 $\lambda=0.5$,误差精度 $e=0.005$.AB 网络和标准 BP 网络的均方误差训练曲线对比情况如图 3 所示.




图 3 AB 网络和标准 BP 网络均方误差曲线对比图

利用 AB 网络判别.对于一张采集到的图片,计算检测区域内每个方格的 R、G、B 直方图的均值、标准差、峰值高度、峰值坐标,得到包含 12 个数据的结果集,将其标准化作为 B 网的输入,带入 AB 网络计算输出.若输出接近 0.9,则表示是车牌区域,用笔画出该方格的四条边;若输出接近 0.1,则表示不是车牌区域,不做任何操作. AB 网络判别结果如图 4 所示.

车牌区域的方格基本都被标出,但其他不是车牌的区域还存在一些神经网络认为是车牌区域的方格,故要采取相应的措施加以过滤.



图4 AB神经网络判别结果

3.3 矩形滑动窗口过滤

本文采集汽车图片的摄像头是固定的且正对车头,汽车驶入检测线即触发摄像头取一张照片,这样车牌区域的大小基本一致.由于车牌的高宽比是固定的,我们采用一个固定大小的矩形滑动窗口进行车牌的第一次定位.

第一次定位后的车牌图像(含车牌的四边和铆钉)宽度占14个边长为20像素的方格,高度占5个方格,因此选择一个包含 14×5 个方格的矩形滑动窗口逐行遍历检测区域,统计矩形滑动窗口内神经网络判别为车牌区域方格的总数,取包含车牌区域方格总数最大的矩形区域,作为车牌第一次定位的结果.第一次定位的结果如图5所示.



图5 车牌第一次定位结果

4 车牌的精确定位

4.1 区域均值法

第一次定位的结果不仅包含车牌的文字信息,还包含车牌的边框和铆钉,不能直接进行字符分割,必须精定位到只包含车牌文字的矩形范围.

本文先对第一次定位的车牌采用区域均值法区分前景与背景,将车牌字符标记出来.使用边长为 m 像素的小格遍历第一次定位的车牌区域,计算小格内所有像素点的RGB均值 $\bar{\mu}$.区域均值法需要设定一个阈值 T 并定义一个二维数组 S 用于记录区域均值的结果.根据如下公式计算:

$$\bar{\mu} = \sum_{i=0}^{m^2} (R_i + G_i + B_i) / (3m^2)$$

$$S[i][j] = \begin{cases} 1, & \bar{\mu} > T \\ 0, & \bar{\mu} \leq T \end{cases}$$

将均值 $\bar{\mu}$ 大于 T 的小格用画笔标记出来.文中取 $m = 2, T = 210$,区域均值法的效果如图6所示.




图6 第一次定位的车牌均值处理结果

4.2 均值跳变法

根据区域均值法标记的结果,采用均值跳变法确定车牌字符区域的上、下、左、右四个方向的边界,从而完成车牌的精确定位.

均值跳变法根据上述二维数组 S 每行和每列值的跳变次数 $count$ 来判断该行或列是否为车牌字符.设采用区域均值法后某行或列的一维数组为 $arr[n]$.

$$f(a, b) = \begin{cases} 0, & a = b \\ 1, & \text{其他} \end{cases},$$

$$count = \sum_{i=0}^{n-1} f(arr[i], arr[i+1]).$$

从车牌第一次定位的左右边界按列向中间遍历,采用均值跳变法判断该列是否为车牌字符,同样从上下边界按行向中间遍历,判断该列是否为车牌字符.均值跳变法需要对行和列的跳变次数分别设定不同的阈值 T_1 和 T_2 ,若某行或列跳变次数大于阈值,说明该行或列是车牌字符,则退出循环.本文中阈值 $T_1 = 14, T_2 = 7$.精确定位的结果如图7所示,参见图中的矩形框区域.




图7 车牌精确定位结果

5 实验结果

本文对项目中480张汽车图片进行了车牌定位实验,结果有474张图片能够快速准确地定位,准确率为98.75%.不能准确定位的6张图片是因为车牌处破损较重或被泥水污染^[5].

6 结束语

本文基于AB神经网络模型,用A网动态地调
(下转第9页)

数据量过大,以及数据传输完毕再解压导致的用户等待问题,提出了一个分级压缩及渐近传输系统.通过这种方式,实现了数据的渐进传输、实时解压和渐进显示,克服了传统方法中影像“阶跃”显示的问题,使遥感影像能够在虚拟地球平台快速、平滑的发布.这种质量的流式数据传输模式,降低了对网络带宽的需求,为提高虚拟地球平台上遥感影像的网络发布效率提供了更好的解决方法.

参考文献:

- [1] 李小雄,伍清河.高正则二维小波的构造及在遥感图像编码中的应用[J].微电子学与计算机,2009,26(3):38-40.
- [2] Yang Chaowei, David wong, Yang Ruixin, et al. Performance-improving techniques in web-based GIS[J]. International Journal of Geographical Information Science, 2005, 19(3): 319-342.
- [3] 刘鹏,毕建涛,曹彦荣,等.遥感影像数据库引擎设计与实现[J].地球信息科学,2005,7(2):105-110.
- [4] 张军,成礼智,杨海滨,等.基于纹理的自适应提升小

波变换图像压缩[J].计算机学报,2010,33(1):184-192.

- [5] 霍亮,杨耀东,刘小勇,等.瓦片金字塔模型技术的研究与实践[J].测绘科学,2012,11(37):144-146.
- [6] 李艳红,庞小平,李海亭.网络环境下的遥感影像金字塔纹理压缩算法与实验[J].地球信息科学学报,2012(14):109-115.

作者简介:

石翠萍 女,(1980-),博士研究生.研究方向为遥感影像的压缩.

张钧萍 女,(1970-),博士生导师,教授.研究方向为遥感影像分析与应用、遥感影像分析.

曲海成 男,(1981-),博士研究生.研究方向为遥感影像的调度与传输.

陈浩 男,(1978-),博士,副教授.研究方向为遥感影像的压缩.

王艳春 女,(1974-),副教授.研究方向为遥感影像分析.

(上接第4页)

整B网的训练步长,使B网的收敛速度更快,并将此模型应用于车牌定位过程^[6-7].

本文车牌的第一次定位和精确定位过程均采用独创的方法,与传统图像处理方法相比,速度快,精度高.

参考文献:

- [1] 俞克强,宫宁生,徐昊骞.商场客流量中改进BP神经网络的应用[J].微电子学与计算机,2013,30(2):65-68.
- [2] 黄艳国,赵书玲,许伦辉.基于纹理特征和颜色匹配的车牌定位方法[J].微电子学与计算机,2011,28(9):123-126.
- [3] 陈兆学,施鹏飞.基于灰度图像的车牌快速定位和分割方法[J].计算机工程,2006,32(5):173-174.

[4] 章毓晋.图像工程(下):图像理解与计算机视觉[M].北京:清华大学出版社,2000.

[5] 杨淑莹.VC++图像处理程序设计[M].北京:清华大学出版社,2005.

[6] Neubauer C. Evaluation of convolutional neural networks for visual recognition [J]. Neural Networks, 1998, 9(4): 685-696.

[7] Fukushima K. Neocognitron: a hierarchical neural network capable of visual pattern recognition [J]. Neural Networks, 1988, 1(2): 119-130.

作者简介:

章晔炜 男,(1989-),硕士研究生.研究方向为人工神经网络、图像处理.

宫宁生 男,(1958-),教授,硕士生导师.研究方向为模式识别、神经网络.