

# 基于 CNN 同心邻域极值的多车道智能交通系统图像多车牌区域的边缘检测<sup>①</sup>

谢 康<sup>②\*</sup> 杨义先<sup>\* \*\*</sup> 张 玲<sup>\*\*</sup> 杜晓峰<sup>\*\*</sup> 辛 阳<sup>\*\*</sup>

(\* 山东大学信息科学与工程学院 济南 250100)

(\*\* 北京邮电大学信息安全中心 北京 100876)

**摘要** 针对现有智能交通系统(ITS)多车牌定位识别算法漏检率高、处理速度慢等问题,在研究细胞神经网络(CNN)理论的基础上,提出了一种基于 CNN 同心邻域极值(CNE)的 ITS 图像多车牌区域边缘检测算法,简称 CNECNN 算法。该算法只需计算 CNN 中同心邻域内极大值与极小值函数差的二阶微分零交叉点,即可获得图像的边缘。此外,该算法利用 CNN 稳态能量函数惩罚约束机制优化粒子群适应度函数,在解空间中搜索参数全局最优解以获得 CNN 邻域极值模板参数。该算法为并行算法,具有运算量小,易于大规模集成电路实现,能够克服早熟收敛等优点。实验结果表明,与传统边缘检测算子和 CNN 通用机(CNNUM)固定模板参数算法相比,该算法漏检度降低了 12.9%。

**关键词** 多车牌, 边缘检测, 细胞神经网络(CNN), 同心邻域极值(CNE), 粒子群优化(PSO)

## 0 引言

车牌识别(license plate recognition, LPR)技术是智能交通系统(intelligent transportation system, ITS)的最重要的技术之一。车牌识别技术的关键在于车牌定位、字符分割和字符识别三部分。车牌定位准确与否直接决定了后续的字符分割和识别效果。根据车牌特征的不同通常可以采用不同的车牌定位方法,常见的定位方法有基于边缘检测的方法、基于彩色分割的方法、基于小波变换的方法、基于遗传算法的方法、基于数学形态学的方法和基于灰度图像纹理特征的方法等。现有的智能交通系统(ITS)的车牌定位算法多是针对单一车道设计的,在多车道的情况下必须为每一个车道都配备相应的设施和系统,这样会导致较多的人力和设备资源的耗费。针对这种情况,多车道公路路口和城市要道的实时监视与监控系统的研究成为智能交通领域的研究热点。多车道 ITS,采集到的每一帧 ITS 图像内都可能含有多个不同类型的车牌区域,准确完整地

定位出每帧图像中所包含的所有车牌区域具有重要意义。车牌字符区域与车牌背景色之间对比度高,与其他非车牌区域相比往往含有更丰富的纵向边缘信息,因此精确快速地提取出 ITS 图像的边缘区域是研究多车道 ITS 的车牌定位的关键步骤。本文在研究细胞神经网络(cellular neural network, CNN)理论的基础上,提出了一种基于 CNN 同心邻域极值的多区域边缘检测算法。

## 1 相关工作

已经有很多学者研究并提出了提取 ITS 图像边缘的方法<sup>[1-3]</sup>:文献[1]首先将前端采集系统获得的含车牌区域的彩色图像转化为灰度图像,然后采用可变阈值的自适应垂直 Sobel 边缘检测器计算输入图像像素点邻域一阶或二阶方向导数,由方向导数变化规律来考查领域内的灰度变化,从而获得边缘区域;文献[2]利用 Sobel 算子结合高斯内核与原图像进行卷积,计算出垂直方向的边缘密度来获得边

<sup>①</sup> 973 计划(2007CB310704),国家自然科学基金(61121061, 61161140320)和中央高校基本科研业务费专项资金(2012RC0216, 2012RC0215)资助。

<sup>②</sup> 女,1987 年生,博士生;研究方向:图像处理与分析,神经网络及其应用;联系人,E-mail: xiekang1987@sina.com  
(收稿日期:2013-09-05)

缘区域。上述算法通过采用经典的边缘检测算子方法来获得车牌区域的边缘,这类算法的特点是比较简单,处理效果比较明显,但是抗干扰能力差、准确度低。

为了充分利用车牌区域的彩色特征,文献[3]提出了基于四元数特定颜色对的边缘检测算法:用同色调全饱和度四元数表示输入彩色 ITS 图像,然后借助四对特定颜色对模板检测边缘,但是这一方案也存在着固有缺陷:在复杂的天气环境下,对含有多种不同类型车牌区域的采样 ITS 图像处理速度慢,硬件可实现性差,难以满足实时处理的要求。

针对上述问题,本文利用细胞神经网络(CNN)算法处理图像与图像大小无关,可高速并行计算,易于超大规模集成电路(very large scale integration, VLSI)硬件实现的特性<sup>[4]</sup>,提出了一种基于 CNN 同心邻域极值(concentric neighborhood extreme value of CNN, CNECNN)的 ITS 图像边缘检测算法(简称 CNECNN 算法)该算法只需计算出同心邻域内极值函数(最大值与最小值)差的零交叉点就可获得 ITS 图像的边缘。

利用 CNN 进行图像处理的最重要的步骤是设计出适合算法的模板。很多专家与学者研究并提出了一些设计模板参数的方法<sup>[5-10]</sup>。文献[5]通过对 CNN 动态迭代过程进行分析,将目标操作转化为几个局部约束条件不等式,不等式中与含有模板参数的输入、输出、状态进行一一映射,不等式对应位置项即为模版参数值。该方法的缺陷是只能通过分析获得模板参数的取值范围,无法获得参数最优解。

文献[6]采用松弛算法将求解目标问题抽象成线性不等式。该方法采用当其收敛到解空间的第一个解时就停止搜索的方法很快地找到可行解,但也因此无法确保找到的是最优解;为获得最优解需要在解空间内再次进行搜索,也因此无法保证快速性。

文献[7-10]通过将模板参数设计过程转化为求解目标函数极值,在目标解空间内利用遗传算法(genetic algorithm, GA)<sup>[7]</sup>、蚁群优化算法<sup>[8]</sup>、Hopfield 神经网络<sup>[9]</sup>、粒子群优化(particle swarm optimization, PSO)算法<sup>[10]</sup>等学习方法搜索全局最优解,从而获得相应的模板参数。这类方法可以搜寻到最优解,但是其参数设计、迭代过程较为复杂。此外,PSO 算法设计参数结构简单、易于实现,能较为快速地搜索到最优解,但是需要设计新的约束条件来使算法跳出局部早熟收敛解。

针对上述问题,为获得 CNN 同心邻域极值模

板,本文提出了基于能量函数惩罚约束粒子群优化(energy constrained particle swarm optimization, ECP-SO)的算法对模板参数进行优化。该方法基于细胞神经网络能量函数,结合条件约束粒子群算法,通过对最优目标参数的搜索使网络能量达到全局最小值,避免陷入局部优化,获得模板参数最优解。该方法有效地融合了 CNN 算法和 PSO 算法的优点,对含有多个车牌区域的输入图像进行并行处理,运算量小,易于大规模 VLSI 集成实现,解决了难以实时准确提取出各种类型的车牌区域边缘这一问题。

## 2 相关知识

### 2.1 细胞神经网络

CNN 于 1988 年由美国加州伯克莱大学 Leon O. Chua 教授和 Lin Yang 博士提出,是一种具有实时高速并行处理信号能力的非线性大规模局部互连模拟电路<sup>[4]</sup>。CNN 的基本结构单元为细胞,任一细胞只与最近邻若干细胞相连,不直接相连的细胞通过动态连续的传播效应相互影响;任一细胞由少量结构相同的线性与非线性的电路元件组成:只使用一个独立电压源、一个独立电流源、一个线性电容,两个线性电阻,至多 2m 个线性压控电流源和一个非线性压控电流源,其易于使用 VLSI 实现的特性使神经网络走向实用化,因此,在很多领域得到广泛的应用<sup>[11-14]</sup>,例如运动目标分类与识别<sup>[11]</sup>、图像处理中的边缘检测<sup>[12]</sup>、遥感图像中路径检测<sup>[13]</sup>、生物医学中癌细胞的特征提取<sup>[14]</sup>等领域。

规模为  $M \times N$  的 CNN 由  $M \times N$  个排列成  $M$  行  $N$  列空间阵列的细胞组成,以网络中第  $i$  行第  $j$  列的细胞  $c(i, j)$  为中心,半径为  $r$  的邻域  $N_r(i, j)$  定义为  $N_r(i, j) = \{c(k, l) | \max\{|k - i|, |l - j|\} \leq r\}$

$$1 \leq k \leq M, 1 \leq l \leq N \quad (1)$$

任一细胞都有恒定的输入  $v_{u_{ij}}$  和输出  $v_{y_{kl}}$ ,状态变量  $v_{x_{ij}}$  动态变化过程可用一阶非线性微分方程表示,根据 KCL、KVL 定律得出状态方程为

$$C \frac{dv_{x_{ij}}(t)}{dt} = -\frac{1}{R} v_{x_{ij}}(t) + \sum_{c(k,l) \in N_r(i,j)} A(i, j; k, l) v_{y_{kl}}(t) + \sum_{c(k,l) \in N_r(i,j)} B(i, j; k, l) v_{u_{kl}}(t) + I \quad (2)$$

输出方程为

$$v_{y_{kl}}(t) = f(v_{x_{ij}}) = \frac{1}{2}(|v_{x_{ij}}(t) + 1| - |v_{x_{ij}}(t) - 1|) \quad (3)$$

约束条件为

$$|v_{xij}(0)| \leq 1, |v_{uji}(0)| \leq 1 \quad (4)$$

其中,  $1 \leq i \leq M, 1 \leq j \leq N$ ,  $A(i, j; k, l), B(i, j; k, l)$  分别表示输入  $v_{uji}$ 、输出  $v_{ykl}$  与细胞之间的连接权, 分别构成由  $(2r+1)^2$  个参数元素组成的反馈模板矩阵  $\mathbf{A}$  与控制模板矩阵  $\mathbf{B}$ 。根据不同问题设计出的偏移量  $\mathbf{I}$  以及模板  $\mathbf{A}, \mathbf{B}$  内的参数值决定了 CNN 的瞬态特性。

若系统稳定, 满足 Lyapunov 定理的能量函数为

$$\begin{aligned} E(t) = & -\frac{1}{2} \sum_{(i,j)} \sum_{(k,l)} A(i, j; k, l) v_{yij}(t) v_{ykl}(t) \\ & + \frac{1}{2R_x} \sum_{(i,j)} v_{yij}(t)^2 - \sum_{(i,j)} \sum_{(k,l)} B(i, j; k, l) \\ & v_{yij}(t) v_{uikl} - \sum_{(i,j)} I v_{yij}(t) \end{aligned} \quad (5)$$

其中  $1 \leq i, k \leq M; 1 \leq j, l \leq N$ 。随时间的增加能量函数单调下降, 若反馈模板矩阵  $\mathbf{A}$  满足对称条件  $A(i, j; k, l) = A(k, l; i, j)$  及最小反馈系数约束定理  $A(i, j; k, l) > 1/R_x$ , 则每个细胞经过暂态衰减为 0 后, 必将收敛到能量最小稳定点<sup>[7]</sup>。并且  $\lim_{t \rightarrow \infty} v_{yij}(t) = \pm 1, 1 \leq i \leq M, 1 \leq j \leq N$ , 保证系统有二值输出, 表示出图像的边缘与非边缘区域。

## 2.2 粒子群算法

粒子群优化(PSO)算法是一种面向全局的连续值优化算法,于1995年由美国华盛顿James Kennedy博士和Russell Eberhart博士提出<sup>[15]</sup>。该算法通过模拟鸟群的觅食行为,将种群内的可能解称为粒子,通过在解空间内“飞翔”以寻求最优解。所有的粒子由被优化的适应度函数决定当前的适应度值,每一个粒子由其速度决定寻找解的方向和距离,根据自己搜索到的历史最优位置和种群最优位置进行比较、更新,追随当前最优粒子搜索解空间最优解。

设在  $d$  维解空间内,由  $n$  个粒子组成一个种群,其中第  $i$  个粒子的位置向量为  $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$ , 其速度向量为  $V_i = (v_{i1}, v_{i2}, \dots, v_{id})$ , 自身经历过的最优解向量为  $P_i = (p_{i1}, p_{i2}, \dots, p_{id})$ , 也称为适应度最高的个体极值  $p_{best}$ 。整个种群所有粒子经历过的最优解向量为  $P_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ , 也称为全局最优解  $g_{best}$ 。在每一次迭代中,粒子根据  $p_{best}$ 、 $g_{best}$  这两个动态极值来更新自己的速度和位置,其速度和位置更新方程为

$$\begin{aligned} V_i(t+1) = & \omega \times V_i(t) + c_1 \times r_1 \times (p_{best} - V_i(t)) \\ & + c_2 \times r_2 \times (g_{best} - V_i(t)) \end{aligned} \quad (6)$$

$$X_i(t+1) = X_i(t) + V_i(t+1) \quad (7)$$

其中,  $i = 1, 2, \dots, d$ ,  $\omega$  为惯性因子, 为当前速度影

响下一时刻速度的权重值。常数  $c_1, c_2$  为学习率, 在迭代过程中分别控制全局与个体最优粒子的学习速率, 通常被限定为  $0 < c_1, c_2 < 2$ ,  $r_1, r_2$  在  $[0, 1]$  区间内随机取值, 为避免  $V_i(t), X_i(t)$  逃逸出解空间, 通常人为选定其取值范围, 当迭代次数达到设定的最大迭代值或粒子群当前搜索到的最优位置符合设定的最小适应度值时, 迭代中止。

由于利用 PSO 训练神经网络参数没有选择、交叉、变异等运算, 算法结构简单、收敛速度快、训练精度高, 但是在训练后期若某一粒子发现当前最优位置恰为局部最优点, 则其他粒子就会迅速向该点靠拢, 粒子种群无法在解空间中重新搜索, 因此算法易陷入局部极小值点, 产生早熟收敛。

## 3 基于 CNN 同心邻域极值的边缘检测方法

### 3.1 CNECNN 算法的数学模型

理论上讲, 边缘是亮度函数发生阶跃跳变的位置, 其特点在于该点灰度发生较大变化, 即具有较大的导数值。在一维的情况下, 目标区域的边缘轮廓存在于均匀亮度区域间亮度过渡曲线一半的地方; 但是在二维的情况下, 由于像素的网格矩阵排列方式使得寻找过渡曲线的方向变得更加复杂。若要准确地定位出目标区域的轮廓, 需要估计过渡区域的宽度并在区域中追踪它的位置。在缺乏噪声的情况下, 两个均匀亮度区域间过渡地带的中间点即为边缘点<sup>[16]</sup>。

设  $\{f(x, y) | (x, y) \in 0 \leq x \leq (N_v - 1) \cap (0 \leq y \leq (N_h - 1))\}$  为一灰度图像, 其中  $N_v, N_h$  分别表示垂直、水平方向上图像的尺度。任意选取像素点  $C(x_0, y_0) \in f(x, y)$  为中心, 以  $R, r$  为邻域半径构造两个同心邻域矩形窗, 其中, 令  $R_{max}, R_{min}, r_{max}, r_{min}$  分别为  $R \times R, r \times r$  矩形窗内像素的最大值和最小值。其中, 条件  $R_{min} \leq r_{min} \leq r_{max} \leq R_{max}$  总被满足, 同心邻域区域示意图如图 1 所示。

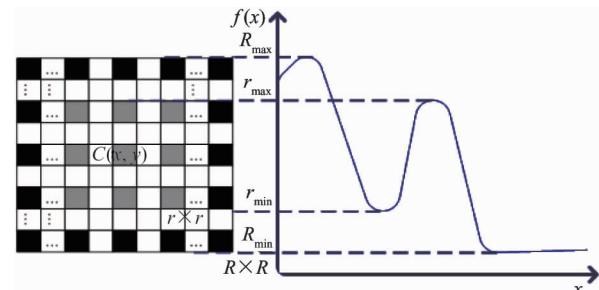


图 1 同心邻域区域示意图

对于每个同心邻域矩形窗定义:

$$\begin{aligned} d_1(c) &= R_{\max} - r_{\max} \\ &= f(x_0 + x_R, y_0 + y_R) - f(x_0, y_0) \end{aligned} \quad (8)$$

$$\begin{aligned} d_2(c) &= r_{\min} - R_{\min} \\ &= f(x_0, y_0) - f(x_0 - x_R, y_0 - y_R) \end{aligned} \quad (9)$$

在无噪声的情况下,若中心点 C 位于亮度转折的中心点,则  $d_1(c) = d_2(c)$ 。这个过程的合理性在于较大的  $R$  邻域窗口标识过渡地带,较小的  $r$  邻域窗口被完全放置在较大窗口的中心,跟踪半高亮点。若外部窗口大于亮度过渡地带,则其涵盖了轮廓区域;若亮度过渡区域更大,则条件  $d_1(c) = d_2(c)$  恰被满足<sup>[16]</sup>。整个过程直到其中一个外部窗口的极值离开不连续区域。

但是在现实情况下,由于边缘邻域亮度的不规则性,不可避免地要叠加上噪声。此外,对于阶跃型边缘,亮度函数一次微分的极值点或二次微分的零交叉点都为边缘点,因此可采用一次微分和二次微分就可判断出边缘的位置和灰度变化的方向。定义  $D(c)$  为亮度函数差,引出定理 1。

**定理 1:** 同心邻域内亮度函数动态变化的二阶微分零交叉点为边缘点。

证明:由亮度函数差定义可知:

$$D(c) = d_1(c) - d_2(c) \geq 0 \quad (10)$$

将式(8)、式(9)带入式(10)可得

$$\begin{aligned} f(x_0 + x_R, y_0 + y_R) + f(x_0 - x_R, y_0 - y_R) \\ - 2f(x_0, y_0) \geq 0 \end{aligned} \quad (11)$$

即

$$\begin{aligned} f(x_0 + x_R, y_0 + y_R) + f(x_0 - x_R, y_0 - y_R) \geq \\ 2f\left(\frac{x_0 + x_R + x_0 - x_R}{2}, \frac{y_0 + y_R + y_0 - y_R}{2}\right) \end{aligned} \quad (12)$$

式(12)满足二阶微分的定义,因此  $D(c)$  为 C 点的二阶导数,根据其动态变化可以确定边缘边缘的位置和灰度变化的方向。因此,相较于沿梯度方向的方向导数  $\partial^2/\partial n^2$ ,基于同心邻域矩形窗运算 D 的零点相当于寻找  $f(x, y)$  的亮度函数二阶微分零交叉点。若  $D_c(x_0, y_0) = 0$  或  $D_c(x_0, y_0)$  与邻域  $D_c$  值互异,则 C 点为边缘点。可以看出,相比较于传统的边缘检测算法,基于同心邻域极值的 CNN 边缘检测算法只依赖于邻域内的极值(最大值、最小值),就可以准确的计算出图像的边缘,运算量小,易于大规模集成电路实现。

### 3.2 CNECNN 算法的模板参数设计

用 CNN 来获得图像的边缘关键在于设计出合

适的代表细胞之间连接权的反馈矩阵  $A$  与控制矩阵  $B$  内的参数,然后将参数矩阵  $A, B$ , 初始输入  $U$  和偏移量  $I$  代入网络状态方程迭代,引导网络向最小能量状态移动直至稳定的输出代表边缘区域的二值稳定解。基于 PSO 算法设计参数结构简单、易于实现,能较为快速的搜索到最优解,但是需要设计新的约束条件使算法跳出局部早熟收敛解。

#### 3.2.1 确定 CNECNN 算法优化模板参数

由 CNN 邻域对称性条件  $A(i, j; k, l) = A(k, l; i, j)$  可得细胞间的相互影响权值是相同的,通常 CNN 的模板设计为

$$A = \begin{bmatrix} a_1 & a_2 & a_3 \\ a_4 & a_5 & a_6 \\ a_7 & a_8 & a_9 \end{bmatrix} \quad B = \begin{bmatrix} b_1 & b_2 & b_3 \\ b_4 & b_5 & b_6 \\ b_7 & b_8 & b_9 \end{bmatrix} \quad I = i \quad (13)$$

假设  $C(3,3)$  为中央细胞,则位于其左上角的邻域细胞  $C(2,2)$  输出反馈对中心细胞的交互式影响为参数  $A(3,3;2,2) = a_1$ ; 若  $C(2,2)$  为中央细胞,则其右下角的邻域细胞  $C(3,3)$  输出反馈对中心细胞的影响反映在参数  $A(2,2;3,3) = a_9$  上,两者的相互影响权值相同  $A(3,3;2,2) = A(2,2;3,3)$ , 则可以推出  $a_1 = a_9, a_2 = a_8, a_3 = a_7, a_4 = a_6$ , 同理输入控制模板  $B$  内参数也满足此对等关系。令  $X^T = [A^T, B^T, I]$  为一个 19 维的向量,通过分析局部极值模板结构<sup>[17]</sup>(如式 14 所示)及模板参数对等关系,得出只需优化  $X^T$  中的  $a, b, i$  3 个参数值。

$$A = a, \quad B = \begin{bmatrix} b & b & b \\ b & 0 & b \\ b & b & b \end{bmatrix}, \quad b = \begin{cases} \text{sign}(\Delta v_{uij}) \rightarrow \text{minima} \\ -\text{sign}(\Delta v_{uij}) \rightarrow \text{maxima} \end{cases}, \quad I = i \quad (14)$$

#### 3.2.2 基于 ECPSO 优化 CNECNN 模板参数

由 CNN 能量函数有界性定理

$$\begin{aligned} |E(t)| &\leq \frac{1}{2} \sum_{(i,j)} \sum_{(k,l)} |A(i, j; k, l)| \\ &+ \sum_{(i,j)} \sum_{(k,l)} |B(i, j; k, l)| \\ &+ MN\left(\frac{1}{2R_x} + |I|\right) \end{aligned} \quad (15)$$

可知 CNN 网络收敛稳定平衡点是能量函数的极小值点,即输出理想最终解时能量函数  $E(t)$  必将收敛于极小稳定值,因此采用能量函数作为约束条件可以使种群快速收敛于极值可行解,并且避免训练模板参数陷入早熟收敛。

对于含有约束条件的优化方法,可先采用罚函数的方法将其转为无条件约束函数,再将其优化,则基于 ECPSO 算法的适应度函数为

$$F(x) = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |\bar{y}_{ij}(x) - y_{ij}(x)| + r \left[ \sum_{i=1}^3 \max\{0, -E_i(x)\}^2 \right]} \quad (16)$$

其中,  $y_{ij}(x)$  为 CNN 的期望输出值,  $\bar{y}_{ij}(x)$  为 CNN 的实际输出值,  $c$  为惩罚因子, 一般采用较大的数值, 本文采用  $r = 10^8$  对不可行解加以约束。当  $x$  为可行解时,  $\max\{0, -E_i(x)\} = 0$ ; 当  $x$  为不可行解时,  $\max\{0, -E_i(x)\} = -E(x)$ 。

综上所述,对粒子群优化算法进行改进,提出了一种新的基于能量约束粒子群优化算法—ECPSO, 对细胞神经网络区域极值模板进行优化,其算法流程如下:

步骤 1:按照细胞神经网络的结构初始化粒子群中粒子的位置和初始速度。

步骤 2:将初始  $a, b, i$  值代入式(14),经式(2)、式(3)求出  $y_{ij}(x), E_{ij}(x)$ ,由式(16)计算当前值适应度函数  $F(x)$ 。

步骤 3:对于每个粒子,将其  $F(x)$  与经历过的最佳位置  $ep_{best}$  适应度函数值做比较,如果其  $F(x)$  优于  $F(ep_{best})$ ,这将该粒子设置为新的  $ep_{best}$ 。

步骤 4:对于每个粒子,将其  $F(x)$  与全局经历过的最佳位置  $eg_{best}$  适应度函数值做比较,如果其  $F(x)$  优于  $F(eg_{best})$ ,这将其设置为新的  $eg_{best}$ 。

步骤 5:根据式(6)、式(7)对粒子的速度和位置进行更新。

步骤 6:判断算法收敛准则是否满足,如果满足则执行步骤 7;否则返回步骤 2。

步骤 7:输出  $eg_{best}$ , 算法运行结束。

由于 CNN 网络稳定收敛、输出理想最终解时,  $E(t)$  必将收敛于极小稳定值,因此与以往基于 PSO 训练 CNN 模板参数方法<sup>[17]</sup>相比,基于 ECPSO 的算法在粒子群优化算法的基本框架中以系统总体动态能量函数作为约束条件来对模板参数优化,这样可以使种群快速收敛于可行解的极值,避免陷入局部优化,优化得来的极值模板参数可更好地满足 CNN 的动态稳定性。

## 4 仿真结果及分析

为保证 ECPSO 算法的收敛性和稳定性,本文算

法采用加速因子  $c_1, c_2$  (设为 1.49),惯性因子  $\omega$  (设为 0.729),  $r_1, r_2$  (设为 [0, 1] 区间内的随机数)。为快速获得模板参数,如图 2 所示,截取含有多个车道多个车牌区域中的单一车道 ITS 图像作为输入,对于随机选取的中心细胞  $C_{i,j}$  初始状态  $v_{xij}(0)$  和  $v_{yij}(0)$  设为 -1,其他参数  $C = 10^{-9} F, R_x = 10^3 \Omega$ 。经过 23 次迭代,算法获得同心邻域内极值模板最终解:

$$\begin{aligned} A &= 1.740573 \\ B &= k \begin{bmatrix} -0.211057 & -0.211057 & -0.211057 \\ -0.211057 & 0 & -0.211057 \\ -0.211057 & -0.211057 & -0.211057 \end{bmatrix} \\ I &= -6.573041 \end{aligned} \quad (17)$$

其中:  $k = \begin{cases} -1 \rightarrow minima \\ 1 \rightarrow maxima \end{cases}$ 。



(a) 原始单车道输入图



(b) 期望输出目标图

图 2 CNN 模板训练图

在 2G 内存的 PC 机上,采用复杂现实环境下采集到的含有多种类型多个车牌区域的 ITS 图像在仿真软件 Matlab7.6.0 中进行仿真实验:

(1) ECPSO 算法与 GA 算法、PSO 算法优解效率比较

采用本文 ECPSO 算法与 GA 算法、PSO 算法对 CNN 邻域极值模板参数进行优化,为定量分析本文

算法的优越性,以迭代次数和群体适应度方差作为各算法的优解效率定量评价标准。定量评价公式为

$$\sigma^2 = \sum_{i=1}^n \left( \frac{f_i - f_{avg}}{f} \right)^2 \quad (18)$$

其中,  $f$  为归一化因子, 取任意值;  $f_i$  为第  $i$  个粒子的适应度;  $f_{avg}$  为当前粒子群的平均适应度。定量评价优解效率仿真结果如图 3 所示。

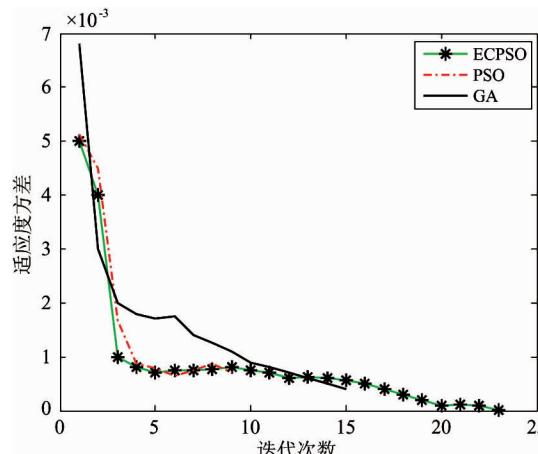


图 3 优解效率仿真结果图

可以看出, 基于 PSO 的参数优化算法收敛速度较快, 但当迭代到  $i = 9$  时, 算法寻到局部最优解就

停止搜索, 陷入早熟收敛; 基于 ECPSO 的算法相比较于 GA 算法收敛速度快, 能够跳出早熟收敛局部最优解, 寻找到全局最优解。

(2) CNECNN 算法与 Sobel 算子、CNNUML 模板边缘检测性能比较

随机选取 60 张如表 1 所示的各种环境下(白昼、黑夜、晴天、阴雨)采集到的 ITS 图像, 将本文 CNECNN 算法与在提取车牌区域边缘时常采用的经典边缘检测算子、CNN 通用机(CNN Universal Machine, CNNUML)中的边缘检测模板<sup>[18]</sup>(如式(19)所示)进行实验比较, 实验结果统计如表 1 所示。

$$A = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad B = \begin{bmatrix} -0.25 & -0.25 & -0.25 \\ -0.25 & 2 & -0.25 \\ -0.25 & -0.25 & -0.25 \end{bmatrix} \quad I = -1.5 \quad (19)$$

分析如下: 定义有效检测率  $\eta$  为

$$\eta = \sum_{i=1}^n \left( \frac{f_{di}}{f_{si}} \right) \times 100\% \quad (20)$$

其中,  $n$  为仿真 ITS 图像数量,  $f_{di}$  为第  $i$  帧仿真 ITS 图像中检测出的有效车牌数量,  $f_{si}$  为第  $i$  帧仿真 ITS 图像中含有车牌区域数量。

表 1 三种方法测试 4 组不同环境下采集的 ITS 图像, 比较检测率和平均处理速度

方法	Sobel 边缘检测算子				CNNUML 通用固定模板				本文 CNECNN 算法					
	仿真 ITS 图像		采集环境		白昼		夜晚		白昼		夜晚		白昼	
采集环境	晴天	阴雨	晴天	阴雨	晴天	阴雨	晴天	阴雨	晴天	阴雨	晴天	阴雨	晴天	阴雨
$n$	20	15	15	10	20	15	15	10	20	15	15	10	20	15
$\sum_{i=1}^n f_{si}$	45	21	19	16	45	21	19	16	45	21	19	16	45	21
$\sum_{i=1}^n f_{di}$	39	19	15	12	43	19	17	14	45	20	19	14	100	95.2
$\eta / (\%)$	86.7	90.5	78.9	75	95.6	90.5	89.5	87.5	100	95.2	100	87.5	—	—
$E(\eta) / (\%)$	84.2				92.1				97.1					

本文方法平均有效检测率  $E(\eta)$  为 97.1%, 比 Sobel 算子高 12.9%, 比 CNNUML 通用固定模板高 5%, 达到较好的鲁棒性。不能精确定位的原因主要为随机选取的 ITS 图像内含有严重褪色污染的车牌区域, 对比度太小; 车速超过一定范围时被抓拍到的车牌区域严重模糊失真; 黑夜和阴雨天气下抓拍到的黑底白字和白底黑字或红字车牌与环境背景对比度很小, 导致检测失败、不完整。随机选取一幅晴天白昼情况下的 ITS 图像仿真实验结果如图 4 所示。

图 4(a) 为原图, 小型车体含有的蓝底白字车 — 1034 —

牌, 大型公交车体含有的黄底黑字车牌。实验结果表明, 对于蓝底白字车牌区域, Sobel 算子提取的边缘(如图 4(b) 所示)比较模糊、不够清晰完整。基于 CNNUML 的算法提取出的边缘(如图 4(c) 所示)比较细腻, 不管是车体的强边缘, 还是车牌区域的弱边缘, 都较为清晰准确地提取了出来, 但是对于图右边公交车体上黄底黑字的车牌区域, 采用经典的边缘检测算子和基于 CNNUML 算法都无法提取出车牌区域的边缘。相比较于其他两种算法, 本文 CNECNN 算法可以清晰、准确地提取出蓝底白字和黄底

黑字的车牌区域的边缘(如图 4(d)所示)。本文算法若采用 VLSI 硬件实现,运算速度与实时性优势将

会更加突出。

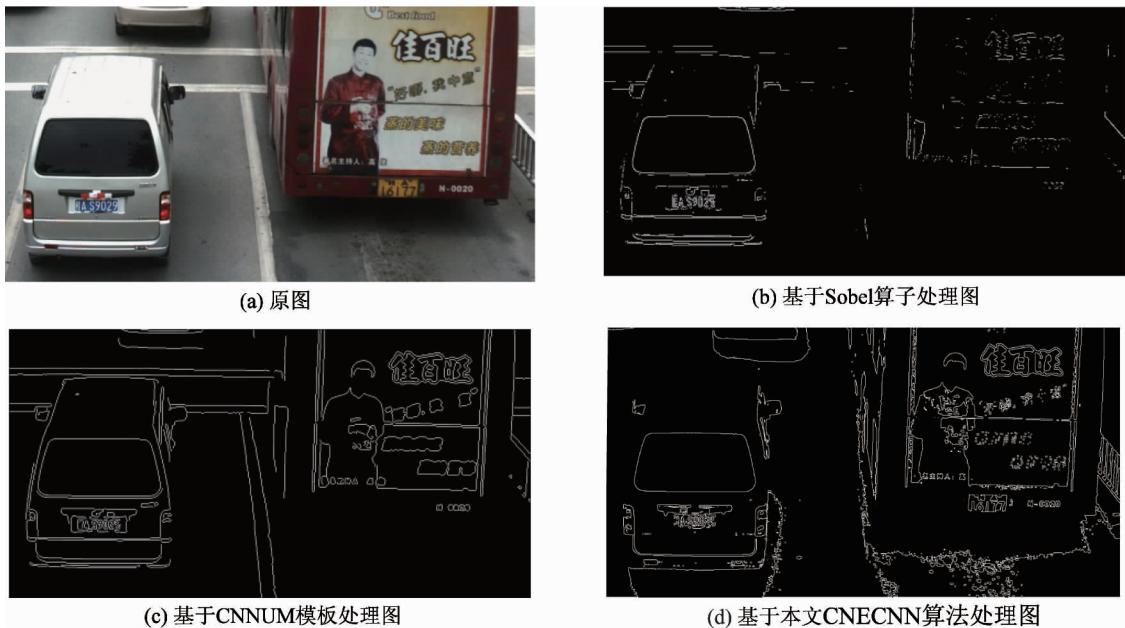


图 4 各算法边缘检测结果对比图

## 5 结论

针对现有多车牌智能交通系统(ITS)普遍存在漏检率高、运行速度慢等问题,本文提出了一种基于细胞神经网络同心邻域极值(CNECNN)的边缘检测算法,并通过能量函数约束法构造新的 PSO 适应度函数来获得适用于本算法的 CNN 模板参数,该算法避免了 PSO 算法易于早熟收敛这一问题并寻找到参数全局最优解。与 GA 算法相比,算法收敛速度快,参数设置简单,实现复杂度低。

通过对各种天气环境下采集到的含有多种类型、多个车牌区域的现实场景图像进行了仿真实验。实验结果表明,相比于传统的边缘检测算子和 CN- NUM 中通用的边缘检测模板,基于 CNECNN 的边缘检测新方法对于各种类型的车牌区域都有较高的检测率,即使在其他方法失效时,基于 CNECNN 仍能准确提取出边缘区域。此外,此新方法继承了 CNN 算法的优点:易于采用大规模结构简单的 VLSI 硬件实现,可进行并行计算,从而大大提高运行速度,对于研究目前市面少有的针对多车道运行监控系统具有重要的参考价值。

## 参考文献

[ 1 ] Rattanathammawat P, Chalidabhongse T H. A car plate

detector using edge information. In: International Symposium on Communications and Information Technologies, Bangkok, Thailand, 2006. 1039-1043

- [ 2 ] Abolghasemi V, Ahmadyfard A. An edge-based color-aided method for license plate detection. *Image and Vision Computing*, 2009, 27(8): 1134-1142
- [ 3 ] 王建, 刘立, 王天慧. 基于四元数特定颜色对边缘检测的车牌定位. *计算机应用*, 2011, 31(3): 729-732
- [ 4 ] Chua L O, Yang L. Cellular neural networks: Theory. *IEEE Transactions on Circuits and Systems*, 1988, 35(10): 1257-1272
- [ 5 ] 王怀颖, 杨立瑞, 章毓晋. 基于 CNN 的康普顿背散射图像中违禁品分割方法. *电子学报*, 2011, 38(11): 549-554
- [ 6 ] Czuni L, Sziranyi T. Motion segmentation and tracking optimization with edge relaxation in the cellular nonlinear network architecture. In: Proceedings of the 6th IEEE International Workshop on Cellular Neural Networks and their Applications, Catania, Italy, 2000. 51-56
- [ 7 ] Fasih A, Chedjou J C, Kyamakya K. Cellular neural network trainer and template optimization for advanced robot locomotion based on genetic algorithm. In: 15th International Conference on Mechatronics and Machine Vision in Practice, Auckland, New Zealand, 2008. 317-322
- [ 8 ] Unal M, Onat M, Bal A. Cellular neural network training by ant colony optimization algorithm. In: IEEE 18th Sig-

- nal Processing and Communications Applications Conference, Diyarbakir, Turkey, 2010. 471-474
- [ 9 ] Ueda Y, Kawahara M, Inoue T, et al. Space-varying cellular neural networks designed by hopfield neural network. In: The 2010 International Joint Conference on Neural Networks, Barcelona, Spanish, 2010. 1-6
- [ 10 ] Fornarelli G, Giaquinto A. Adaptive particle swarm optimization for CNN associative memories design. *Neurocomputing*, 2009, 72(16-18) : 3851-3862
- [ 11 ] Chua L O, Yang L. Cellular neural networks: Application. *IEEE Transactions on Circuits and Systems*, 1988, 35(10) : 1273-1290
- [ 12 ] Parmaksizoglu S, Gunay E, Alci M. Determining cloning templates of CNN via moga: edge detection. In: Proceedings of IEEE 19th Conference on Signal Processing and Communications Applications, Antalya, Turkey, 2011. 758-761
- [ 13 ] Sarhan E, Khalifa E, Nabil A M. Road extraction framework by using cellular neural network from remote sensing images. In: International Conference on Image Informa-
- tion Processing, Himachal Pradesh, India, 2011. 1-5
- [ 14 ] Abdullah A, Mohamaddiah H. Development of cellular neural network algorithm for detecting lung cancer symptoms. In: IEEE EMBS Conference on Biomedical Engineering and Sciences, Kuala Lumpur, Malaysia, 2010. 138-143
- [ 15 ] Kennedy J, Eberhart R. Particle swarm optimization. In: Proceedings of IEEE International Conference on Neural Networks, Perth, Australia, 1995. 1942-1948
- [ 16 ] Sciascio E Di, Guaragnella C. Simple nonlinear dual-window operator for edge detection. *Optical Engineering*, 2002, 41(9) : 2181-2185
- [ 17 ] Rekeczky C, Roska T, Ushida A. CNN based self-adjusting nonlinear filters. In: IEEE International Workshop on Cellular Neural Networks and their Applications, Seville, Spanish, 1996. 5-6
- [ 18 ] Roska T, Chua L O. The CNN Universal Machine: An Analogic Array Computer. *IEEE Transaction Circuits and Systems: analog and digital signal processing*, 1993, 40(3) : 163-173

## Edge detection in multi-license plate area of ITS images based on concentric neighborhood extreme value of CNN

Xie Kang\*, Yang Yixian\*\*\*, Zhang Ling\*\*, Du Xiaofeng\*\*, Xin Yang\*\*

(\* College of Information Science and Engineering, Shandong University, Jinan 250100)

(\*\* Information Security Center, Beijing University of Posts and Telecommunications, Beijing 100876)

### Abstract

The cellular neural network (CNN) theory was applied to the study of edge detection in the multi-license area of an intelligent transportation system (ITS)' images to improve the ITS' performance in license plate recognition, and a new edge detection algorithm based on the concentric neighborhood extreme (CNE) value of CNN, called CNECNN algorithm for short, was put forward. To get the edge area, this algorithm calculates the zero-crossing point of a difference function that depends only on the concentric neighborhood extreme value. In order to obtain the CNN template parameters, an energy function constraint method is used to construct a new fitness function of particle swarm optimization (PSO), jumping out the premature convergence, and ultimately find the optimal solution. This new approach can be easily used for VLSI implementation because of its parallelism. Compared with the traditional edge detection operators and general edge detection template in CNN Universal Machine (CNNU), the simulation results of the images collected in the real environment show that the algorithm based on CNECNN can reduce the miss rate by 12.9%.

**Key words:** multi-license plate, edge detection, cellular neural network (CNN), concentric neighborhood extreme (CNE) value, particle swarm optimization (PSO)