

基于互信息的 RBF 神经网络结构优化设计

郭 伟

(辽宁工程技术大学电子与信息工程学院 葫芦岛 125105)

摘 要 以设计最小 RBF 网络结构为着眼点,提出了一种基于互信息的 RBF 神经网络结构优化算法。该算法用 k 近邻统计法估计隐节点输出矩阵与输出节点输出矩阵之间的互信息,获得每个隐节点与输出节点之间的相关性度量,删除相关性最小的隐节点,进而达到优化网络结构的目的。该算法具有自恢复机制,在简化网络结构的同时能有效保证网络的信息处理能力。在人工数据集和真实基准数据集上的仿真实验验证了该算法的有效性与稳定性。

关键词 RBF 神经网络,结构优化, k -近邻统计法,互信息

中图分类号 TP273 **文献标识码** A

Structural Optimization Algorithm for RBF Neural Network Based on Mutual Information

GUO Wei

(Institute of Electronic and Information Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract Aiming at designing the simplest RBF neural network architecture, a RBF neural network structure design algorithm based on mutual information was proposed in this paper. The relevance measure between each hidden and output units can be acquired by estimating the mutual information between the output matrix of the hidden unit and output unit, using k -nearest-neighbor statistics. And the simplest RBF neural network architecture can be achieved by removing the least related hidden units from the trained neural network one after another according to the relevance measure. This algorithm has the self-recovery mechanism, and the information processing capacity of the neural network can be ensured in the process of the simplification of the network's architecture. The simulation results on the artificial datasets and the real-world benchmark datasets show the effectiveness and stability of the algorithm.

Keywords RBF neural network, Structural optimization, k -nearest-neighbor statistics, Mutual information

1 引言

径向基函数神经网络(radial basis function, RBF)由于其拓扑结构简单和通用的逼近能力,以及收敛速度快、不易陷入局部极小、鲁棒性好等优点,在模式分类、信号处理、非线性系统建模与控制等方面得到了广泛的应用^[1-3]。RBF 神经网络应用的关键问题是网络结构设计和网络参数学习。所谓 RBF 网络结构设计,就是如何确定 RBF 网络中隐节点个数、核函数的位置与宽度。相对于参数学习而言,RBF 网络结构设计要困难得多,至今尚无确定的方法可循。

RBF 网络设计的常用方法有:聚类方法、修剪方法、增长方法和增长与修剪相结合的方法。聚类方法用输入样本之间的距离确定隐节点的数据中心,并根据各聚类中心之间的距离确定各隐节点核函数的扩展宽度。但由于聚类方法本身固有的缺陷以及聚类的盲目性和局限性,因此由聚类方法产生的 RBF 网络结构并不理想。文献[4]提出了一种最小资源神经网络(minimal resource allocating network, MRAN),MRAN 利用增长和删减策略对 RBF 神经网络拓扑结构进行调整,最终获得适用于研究对象的 RBF 网络结构^[5]。文献[6]提出一种基于粒子群优化(particle swarm optimization, PSO)的 RBF 神经网络结构优化算法,该方法利用 PSO 同时

对 RBF 网络的隐层神经元数和连接权值进行调整,从而提高整个神经网络的性能。但由于 PSO 是一种全局优化算法,因此该算法训练过程需要的时间较长。文献[7]提出了一种基于递归最小二乘算法(recursive least squares algorithm, ROLSA)和 PSO 的混杂前向 RBF 网络结构优化算法,该方法在学习速度和泛化能力方面均有一定的提高,但该方法参数设置较复杂,因此鲁棒性较差。文献[8]提出了一种基于前向正交选择(orthogonal forward selection, OFS)的 RBF 神经网络结构优化算法,该方法通过留一准则(leave-one-out, LOO)对 RBF 神经元进行选择,从而确定神经网络的结构,但 OFS-LOO 的参数修改算法是一种全局搜索算法,在很大程度上降低了其整体学习速度。因此,到目前为止,RBF 网络结构优化设计仍是一个开放的问题。

鉴于上述存在的问题,本文提出了一种基于互信息的 RBF 网络修剪算法(pruning based on mutual information, PBMI-RBF)。该算法利用互信息能够准确度量两个随机变量之间相关程度的特性,从而对网络结构进行精简,且该算法有自恢复机制,在简化网络结构的过程中既能准确地找出最有可能被删除的隐节点,又能保证网络对信息的处理能力不下降,因此其能够根据问题本身的复杂度设计 RBF 网络结构,解决了 RBF 神经网络结构过大或过小的问题。

到稿日期:2012-09-04 返修日期:2012-12-12 本文受国家自然科学基金(60971048),辽宁省科技厅基金(2009S051)资助。

郭 伟(1977-),女,博士,讲师,主要研究方向为智能信息处理、神经网络结构设计与优化。

2 RBF 神经网络

2.1 RBF 神经网络结构

RBF 网络是一种 3 层前馈网络,分别为输入层、隐含层和输出层。设 RBF 网络结构为 $n-m-p$ (n 个输入节点, m 个隐含层节点和 p 个输出节点),则第 k 个输出节点的输出为:

$$y_k = \sum_{i=1}^m w_{ki} \Phi_i(\|x - c_i\|) \quad (1)$$

式中, $x = (x_1, x_2, \dots, x_n)^T \in R^n$ 为网络输入向量, w_{ki} 是第 i 个隐层节点与第 k 个输出节点的连接权值, $\Phi(\cdot)$ 为第 i 个隐节点的输出:

$$\Phi_i(\|x - c_i\|) = e^{-\|x - c_i\| / \delta_i^2} \quad (2)$$

式中, c_i 为核函数数据中心, δ_i 为核函数扩展宽度。

2.2 RBF 神经网络梯度学习方法

通过最小化目标函数实现对各隐节点数据中心、扩展宽度和输出权值的调整。

设神经网络学习的目标函数为:

$$E = \frac{1}{2} \sum_{j=1}^N \beta e_j^2 \quad (3)$$

式中, β 为遗忘因子。误差 e_j 为:

$$e_j = y_j - F(x_j) = y_j - \sum_{i=1}^m w_{ji} \Phi_i(x_j) \quad (4)$$

神经网络函数 $F(x)$ 对数据中心 c_i 、扩展宽度 δ_i 和输出权值 w_i 的梯度分别为:

$$\nabla_{c_i} F(x) = \frac{2w_i}{\delta_i^2} \Phi_i(x) \|x - c_i\| \quad (5)$$

$$\nabla_{\delta_i} F(x) = -\frac{2w_i}{\delta_i^3} \Phi_i(x) \|x - c_i\|^2 \quad (6)$$

$$\nabla_{w_i} F(x) = \Phi_i(x) \quad (7)$$

考虑所有训练样本和遗忘因子的影响,则 c_i 、 δ_i 和 w_i 的调节量分别为:

$$\Delta_{c_i} = 2\eta \frac{w_i}{\delta_i^2} \sum_{j=1}^N \beta e_j \Phi_i(x_j) \|x_j - c_i\| \quad (8)$$

$$\Delta_{\delta_i} = -2\eta \frac{w_i}{\delta_i^3} \sum_{j=1}^N \beta e_j \Phi_i(x_j) \|x_j - c_i\|^2 \quad (9)$$

$$\Delta_{w_i} = \eta \sum_{j=1}^N \beta e_j \Phi_i(x_j) \quad (10)$$

式中, $\Phi_i(x_j)$ 为第 i 个隐节点对 x_j 的输出, η 为学习率。

3 基于互信息的 RBF 神经网络结构优化

3.1 互信息的定义

设随机变量 X 和 Y 的联合概率密度函数为 $\rho_{X,Y}(x,y)$, 则 X 和 Y 的边缘概率密度函数为:

$$\rho_X(x) = \int \rho_{X,Y}(x,y) dy \quad (11)$$

$$\rho_Y(y) = \int \rho_{X,Y}(x,y) dx \quad (12)$$

依据 Shannon 熵定义有:

$$H(Y) = - \int \rho_Y(y) \log \rho_Y(y) dy \quad (13)$$

$$H(X,Y) = - \int \rho_{X,Y}(x,y) \log \rho_{X,Y}(x,y) dx dy \quad (14)$$

熵 $H(Y)$ 描述了随机变量 Y 所包含的信息量;联合熵 $H(X,Y)$ 描述了随机变量 X,Y 共有的信息量。

按照信息论的有关理论,随机变量 X,Y 之间的互信息为:

$$I(X;Y) = H(X) + H(Y) - H(X,Y)$$

$$= \int \rho_{X,Y}(x,y) \log \frac{\rho_{X,Y}(x,y)}{\rho_X(x)\rho_Y(y)} dx dy \quad (15)$$

互信息是随机变量 X,Y 相关性的度量,因此当 X 和 Y 相互独立时, $I(X;Y) = 0$ 。

3.2 互信息的估计

由式(15)知,互信息的估计只需估计出联合概率分布 $\rho_{X,Y}(x,y)$ 即可,因此可用 k -近邻统计法来估计互信息^[9,10]。

设有 N 个输入-输出对为:

$$Z^{(i)} = [(x^{(i)})^T, (y^{(i)})^T]^T \quad (16)$$

式中, $i=1, \dots, N$, $x^{(i)} \in R^n$, $y^{(i)} \in R^p$ 。

若 $Z^{(i)}$ 的 k -近邻为:

$$Z^{(k(i))} = [(x^{(k(i))})^T, (y^{(k(i))})^T]^T \quad (17)$$

则 $Z^{(i)}$ 与 $Z^{(k(i))}$ 之间的 chebyshev 距离为:

$$\begin{aligned} \epsilon^i &= \|Z^{(i)} - Z^{(k(i))}\| \\ &= \max(\|x^{(i)} - x^{(k(i))}\|, \|y^{(i)} - y^{(k(i))}\|) \end{aligned} \quad (18)$$

而对于 $Z^{(i)}$ 中的分量 $x^{(i)}$ 和 $y^{(i)}$ 有:

$$\epsilon_X^i = \|x^{(i)} - x^{(k(i))}\| = \max_{s=1 \dots d} |x_s^{(i)} - x_s^{(k(i))}| \quad (19)$$

$$\epsilon_Y^i = \|y^{(i)} - y^{(k(i))}\| = \max_{t=1 \dots p} |y_t^{(i)} - y_t^{(k(i))}| \quad (20)$$

依据式(18)有:

$$\epsilon^{(i)} = \max(\epsilon_X^i, \epsilon_Y^i) \quad (21)$$

因此,对于 $Z^{(i)}$ ($i=1 \dots N$) 中的 $x^{(i)}$, 可以计算出 $Z^{(j)}$ ($j=1 \dots N, j \neq i$) 中 $x^{(j)}$ 的分量 $x_s^{(j)}$ 到 $x^{(i)}$ 的分量 $x_s^{(i)}$ 的距离小于 $\epsilon^{(i)}$ 的点的个数 $N_X^{(i)}$;同理,对于 $Z^{(i)}$ ($i=1 \dots N$) 中的 $y^{(i)}$, 也可以计算出 $Z^{(j)}$ ($j=1 \dots N, j \neq i$) 中 $y^{(j)}$ 的分量 $y_t^{(j)}$ 到 $y^{(i)}$ 的分量 $y_t^{(i)}$ 的距离小于 $\epsilon^{(i)}$ 的点的个数 $N_Y^{(i)}$ 。此时 $I(X;Y)$ 的估计值为^[11]:

$$\begin{aligned} \hat{I}(X;Y) &= -\frac{1}{N} \sum_{i=1}^N [\psi(N_X^{(i)} + 1) + \psi(N_Y^{(i)} + 1)] + \psi(k) + \\ &\quad (n+p-1)\psi(N) + \frac{n+p-1}{k} \end{aligned} \quad (22)$$

式中, $\psi(\cdot)$ 为 digamma 函数, $\psi(t+1) = \psi(t) + 1/t$, $\psi(1) \approx -0.5772156$ 。 k 的取值一般为 2~6 之间。

3.3 基于互信息的 RBF 神经网络修剪算法

既然互信息能够准确度量两个随机变量之间的相关程度,由式(1)知,RBF 网络输出节点的输出本身就是隐节点输出的线性组合,因此可以用互信息来度量 RBF 网络每个隐节点对所有训练样本的输出与输出节点对所有训练样本的输出之间的相关程度,删除相关程度最小的隐节点,以达到简化网络结构的目的。

不失一般性,我们讨论单输出 RBF 网络,设 RBF 网络的结构为 $n-m-1$,训练样本数为 N 。采用批学习方式,则 RBF 输出节点对 N 个训练样本的输出为 $y = (y^{(1)}, y^{(2)}, \dots, y^{(N)})^T$; RBF 第 j 个隐节点对第 i 个训练样本的输出为 $h_j^{(i)} = \Phi_j(\|x - c_j\|)$,则 RBF 第 j 个隐节点对 N 个训练样本的输出为:

$$h_j = (h_j^{(1)}, h_j^{(2)}, \dots, h_j^{(N)})^T \quad (23)$$

将 y 和 h_j 组成输入-输出对 $Z = [y^T, h_j^T]^T$,则可计算出每个隐节点的输出 h_j 和输出层节点的输出 y 之间的互信息 $I(y; h_j)$ 。由于 RBF 网络输出节点的输出不仅与隐节点输出有关,而且与该隐节点与输出节点的权连接有关,因此,可定义每个隐节点输出与输出节点输出的相关性度量如下:

$$r_j = \hat{I}(y; h_j) \times |w_j| \quad (24)$$

于是,可获得基于互信息的 RBF 网络修剪算法如下:

步骤 1 用 k -Means 聚类法产生一个初始结构较大的神经网络。

步骤 2 对网络进行适当训练,并用式(8)一式(10)调整网络中相应的参数。训练结束后,用式(22)和式(24)计算此时每个隐节点输出和输出节点输出之间的相关性,并删除相关性最小的隐层节点。

步骤 3 对网络进行适当训练,适当调整删除隐节点后的神经网络中的相关参数。

步骤 4 若达到训练目标,则转步骤 5;若网络性能变差(衡量指标视具体问题而定),则将步骤 2 中删除的隐节点重新放入隐层,并恢复当时的数据中心、扩展宽度和权连接,转步骤 2。

步骤 5 结束。

该算法在步骤 4 中有恢复上次删除的隐节点的功能,原因有:(1)由于本算法采用统计方法估计互信息,因此估值准确性与训练样本质量有关;(2)对于修剪算法,很难保证其不会有误删除隐节点的事件发生,所以修剪算法应该具有自恢复机制。

4 仿真实验

PBMI-RBF 算法能够根据学习对象自身的复杂度简化网络结构,同时能够保障网络信息处理能力不下降,得到与研究对象相适应的网络结构。为验证 PBMI-RBF 算法的有效性与稳定性,分别选取人工数据集上的非线性函数逼近和双螺旋分类问题,以及真实基准数据集上的 Wisconsin breast cancer 分类问题进行实验,并与最小资源优化网络 MRAN^[4]和 GGAP-RBF^[12](general growing and pruning)算法进行比较。

4.1 非线性函数逼近

选取典型的非线性函数进行逼近,此函数已被证明非常适合用来检测神经网络的性能^[13]。

$$y = 0.5 \left(\sin\left(-\frac{x+6}{2}\right) + 2e^{\left(-\frac{(x-0.5)^2}{4}\right)} + \sin\left(-\frac{(x-7)^2}{6}\right) \right) \quad (25)$$

对式(25),产生 1500 个样本 (x_i, y_i) , $x_i \in [-10, 10]$,其中 1000 个训练样本、500 个测试样本。实验时,选取 $k=4$,学习率 $\eta=0.001$,遗忘因子 $\beta=0.8$ 。判断网络性能的标准为均方差。

图 1 为初始结构为 1-20-1 的网络对函数 y 的逼近效果,训练结束后网络的最终结构为 1-12-1。从对典型非线性函数逼近的效果图可看出, PBMI-RBF 算法在精简 RBF 网络结构的同时,能够保证网络对函数的逼近性能。图 2 为逼近过程中误差下降曲线和隐节点数的变化动态。如图 2 所示,网络第一次删除隐节点后,在接下来的网络参数调整阶段,网络训练误差并没有达到删除隐节点前网络所能达到的训练误差,表明这次删除隐节点导致网络性能变差,因此将删除的隐节点重新放回网络,并恢复当时整个网络的相关参数。从误差下降曲线可以清晰看出,这个过程的前后,网络的训练误差没有任何变化,即算法中的自恢复机制能够保障当出现误操作时网络的性能不下降。从其后的误差曲线下下降还可以看出,

每次选择一个隐节点删除时,并没有引起整个误差曲线大的波动,表明用式(24)可以准确找出最有可能被删除的隐节点。




图 1 PBMI-RBF 对 y 的逼近效果




图 2 训练误差曲线与隐节点数动态

表 1 给出了 PBMI-RBF、MRAN 和 GGAP-RBF 3 种算法处理相同问题、达到相同期望误差时的比较结果(各自训练 20 次后的平均结果)。由表 1 知,达到相同的期望误差时, PBMI-RBF 网络结构最为紧凑,虽然运行时间比 GGAP-RBF 稍长,但 PBMI-RBF 网络的检测误差小于 GGAP-RBF 网络,一定程度上说明 PBMI-RBF 网络的泛化能力较强。

表 1 3 种算法的性能比较

函数	算法	期望误差	检测误差	最终隐节点数	训练时间(分)
y	PBMI-RBF	0.01	0.0119	19.3	4.36
	GGAR-RBF	0.01	0.0198	22.5	4.12
	MRAN	0.01	0.0262	30.8	6.92

实质上, MRAN 和 GGAP-RBF 都是一种自底向上且具有微调机制的 RBF 网络结构设计方法。而 PBMI-RBF 则是一种自顶向下的 RBF 网络结构设计方法,同时算法中的自恢复机制能够在删减网络结构的过程中最大限度地保障网络的信息处理能力,所以 PBMI-RBF 应该是它们的一种逆向设计方法。

4.2 双螺旋分类问题

双螺旋分类问题是评估神经网络分类复杂边界样本能力的一个基准问题^[14],也是最困难的模式分类问题之一。网络对双螺旋问题的分类能力往往可作为评价网络泛化能力的一个重要指标。




图 3 双螺旋的训练样本

双螺旋线由两条相互缠绕的螺旋线构成,每条螺旋线上的点对应于一类,其训练样本如图 3 所示。该分类问题的训

训练样本是平面上的 194 个点,这 194 个点分别属于两个点集,各 97 个样本,相应类的输出分别属于+1 和-1。双螺旋线分类问题的任务是判断输入样本属于两条螺旋线中的哪一条。由于两条螺旋线相互缠绕,即它们所对应的类之间是重叠的,因此加大了 RBF 网络进行模式分类的难度。

图 3 所示的训练样本产生方式如下:
$$\begin{aligned} \theta &= i \times \pi / 16 \\ r &= 6.5 \times (104 - i) / 104 \\ x &= r \times \sin(\theta) \\ y &= r \times \cos(\theta) \end{aligned} \tag{26}$$

式中, $i=0,1,\cdots,96$,则 (x,y) 和 $(-x,-y)$ 就可以构成两类样本,共 194 个样本点分别属于两个点集。测试样本为 $x=-7:0.1:7$ 和 $y=-7:0.1:7$,即 x 和 y 各 141 个,测试样本对为 19881 个。仿真时,选取 $k=4$,学习率 $\eta=0.002$,遗忘因子 $\beta=0.8$ 。

网络的初始结构为 2-80-1,衡量网络的性能指标为均方差。训练结束后网络的最终结构为 2-49-1。图 4 所示为隐节点数为 49 时,对 19881 个测试样本的分类效果,此时网络的训练精度为 100%,测试精度为 97.92%。




图 4 49 个隐节点的分类效果

表 2 列出 3 种算法针对双螺旋分类问题达到相同训练精度时的结果比较(平均运行 20 次)。通过对双螺旋分类问题的仿真实验与分析及与其他算法的比较可以看出, PBMI-RBF 设计出的 RBF 网络具有较强的泛化能力。

表 2 3 种算法的实验结果比较					
问题	算法	训练精度	测试精度	最终隐节点数	训练时间(分)
双螺旋分类	PBMI-RBF	100%	97.25%	48.7	11.79
	GGAR-RBF	100%	96.36%	53.2	10.35
	MRAN	100%	92.41%	61.5	15.26

4.3 Wisconsin breast cancer 数据分类

Wisconsin breast cancer 数据集是从临床实际获得的乳腺癌病人的 699 组镜检数据,每组数据通过乳腺癌患者肿瘤块的大小等 9 个特征值来判断此肿瘤为良性肿瘤还是恶性肿瘤。本文从 699 组数据中剔除 16 组个别特征值不明确的数据得到 683 组数据,选择前 342 组数据为学习样本,后 341 组数据为测试样本。网络输出[1 0]表示良性肿瘤,[0 1]表示恶性肿瘤。

实验时,选取 $k=4$,学习率 $\eta=0.003$,遗忘因子 $\beta=0.8$,网络的初始结构为 9-30-2,衡量网络的性能指标为均方差。图 5 所示为训练过程中训练误差曲线与网络隐节点变化动态,训练结束后网络的最终结构为 9-7-2。表 3 所列为 3 种算法对 Wisconsin breast cancer 分类问题达到相同训练精度时的结果对比(平均运行 20 次)。从表中可以看出本文算法设计出的 RBF 网络结构最简,对测试样本的识别精度最高,表明该算法在实际数据集上是有效的。




图 5 训练误差曲线与隐节点数动态

表 3 3 种算法的实验结果比较

问题	算法	训练精度	测试精度	最终隐节点数	训练时间(分)
Wisconsin	PBMI-RBF	100%	96.77%	7.3	2.16
	GGAR-RBF	100%	95.36%	8.8	1.42
	MRAN	100%	93.41%	13.6	4.45

结束语 本文以设计最小 RBF 网络结构为着眼点,提出了一种基于互信息的 RBF 神经网络结构优化算法。该算法采用 k -近邻统计法来估计每个隐节点的输出矩阵与输出节点的输出矩阵之间的互信息,确定要删除的隐节点,从而达到简化网络结构的目的。该算法属于自顶向下且具有自恢复机制的网络结构设计方法,在简化网络结构的过程中能够最大限度地保障网络的信息处理能力,因此能够根据问题本身的复杂度自适应设计 RBF 网络结构。通过对典型非线性函数的逼近实验,表明该算法确实能够设计出结构最为紧凑的 RBF 网络;通过对双螺旋分类的实验,表明该算法设计出的 RBF 网络具有较强的泛化能力;通过对 Wisconsin breast cancer 数据分类问题的实验,表明该算法在真实基准数据集上是有效的。

参 考 文 献

[1] 姜慧研,宗茂,刘相莹. 基于 ACO-SVM 的软件缺陷预测模型的研究[J]. 计算机学报,2011,34(6):1148-1154

[2] Chen S, Wang X X, Brown D J. Sparse incremental regression modeling using correlation criterion with boosting search[J]. IEEE Signal Processing Letters,2005,12(3):198-201

[3] 孟锦,马驰,何家浪,等. 基于 HHGA-RBF 神经网络的网络安全态势预测模型[J]. 计算机科学,2011,38(7):70-75

[4] Lu Ying-wei, Sundararajan N, Saratchandran P. A sequential learning scheme for function approximation using minimal radial basis function (RBF) neural networks[J]. Neural Computation, 1997,9:461-478

[5] Panchapakesan C, Palaniswami M, Ralph D, et al. Effects of moving the centers in an RBF network[J]. IEEE Transaction on Neural Networks,2002,13(6):1299-1307

[6] Feng H M. Self-generation RBFNs using evolutionary PSO learning[J]. Neurocomputing,2006,70(13):241-251

[7] Huang De-shuang, Du Ji-xiang. A constructive hybrid structure optimization methodology for radial basis probabilistic neural networks[J]. IEEE Transaction on Neural Networks, 2008, 19 (12):2099-2115

[8] Chen Sheng, Hong Xia, Luk B L, et al. Construction of tunable radial basis function networks using orthogonal forward selection[J]. IEEE Transaction on Systems, Man, and Cybernetics—Part B: Cybernetics,2009,39(2):457-466

(下转第 271 页)

果图。表1给出了本文方法与传统方法运行时间的对比。



图1 背景提取更新

表1 传统高斯背景建模与本文方法运行时间对比

算法名称	平均运行时间 ms/帧
传统高斯背景建模	33
李等人方法	26
本文方法	21

初始化各个变量,每个像素选取一个高斯分布, w_{init} 为 0.05,标准差 σ_{init} 为 20,权值更新率 β 为 0.1。

从图1中可以看出,本文的方法使背景提取与前景提取效果比李等人提出的方法更好,在运算时间上(见表1)也有一定的提高。

4.2 实验2 目标跟踪与统计计数

本文跟踪算法在跟踪时仅需要进行特征点计算,跟踪效果能够满足实时要求。

如图2、图3中上下两个矩形框分别为创建区 $S1(S2)$ 。只有人体进入创建区后才创建跟踪框,在离开跟踪区域后删除跟踪目标结点并计数。人身上的矩形框为跟踪框,其中心代表人体中心。图2对紧靠在一起的人进行了准确的分割与跟踪。图3对人体的合并与分离进行了准确跟踪,解决了复杂情况下的准确匹配跟踪。



图2 两人并肩跟踪效果



图3 复杂人群跟踪效果

通过视频播放,使用本文算法对某家商店从下午1点到7点之间的客流量进行数据统计所得到的数据记录如表2所列。

表2 客流量统计精度

测试场景	实际进入人数	系统统计的进入人数	进入人数准确率(%)	实际出去人数	系统统计的出去人数	出去人数准确率(%)
场景1	974	965	99	912	1789	93
场景2	1311	1274	97	1215	1266	96

本文算法的优点在于解决了因客流拥挤进入视频监控区而造成的跟踪匹配错误,提高了跟踪和计数的精确度,同时满足了实时性的要求,但仍然存在误判,主要原因是人群中混有类似人大小(人的宽度、厚度)的移动物体,但一般的不同于标准人尺度大小的移动物体能够准确识别出来。

结束语 提出了一种改进的混合高斯模型在客流量统计研究中的应用。在高斯模型中主要是减少了计算量,区分开了均值与方差的更新速率。跟踪部分主要通过改进的特征跟踪,引入了预测方向向量,实现了在视频监控区内的单人来回走、多人并肩走、多人相向走、前后串走等多种复杂情况下的准确计数。通过实验表明,该设计方法的识别准确率在96%以上,具有较好的实用价值。

参考文献

- [1] 李娟,邵春福,杨励雅. 基于混合高斯模型的行人检测方法[J]. 吉林大学学报:工学版,2011,41(1):41-45
- [2] 蒋明,潘娇丽. 一种改进的混合高斯背景估计方法[J]. 微型机与应用,2011,30(11):31-34
- [3] 袁霄,王丽萍. 基于 MeanShift 算法的运动人体跟踪[J]. 计算机工程与科学,2008,30(4):46-49
- [4] 刘皓挺,姜国华,王丽. 一种基于 Snake 模型的多目标跟踪算法[J]. 计算机工程与应用,2006,23(12):76-79
- [5] 陈明,陈一民,黄诗华. 增强现实中视频对象跟踪算法[J]. 计算机工程,2010,36(12):229-231
- [6] Hager G D, Dewan M, Stewart C V. Multiple Kernel Tracking with SSD[J]. IEEE Conference on Computer Vision and Pattern Recognition, 2004, 23(4): 790-797
- [7] Dai Y P, Yu G H, Hirasawa K. New Development on Tracking Algorithm with Derivation Measurement[J]. IEEE International Conference on System, Man and Cybernetics, 2001, 25(4): 3181-3186
- [8] 魏娟丽,翟社平,王万诚. 视频序列中人体运动目标的检测与跟踪研究[J]. 计算机应用与软件, 2006, 23(4): 139-141
- [9] 赵宏伟,冯嘉. 一种实用的运动目标检测和跟踪算法[J]. 吉林大学学报:工学版, 2009, 39(2): 386-390
- [10] 张德才. 视频流中多人跟踪算法研究[D]. 长春:吉林大学, 2011

(上接第255页)

- [9] Stogbauer H, Kraskov A, Astakhov S A, et al. Least dependent component analysis based on mutual information [J]. Physical Review E, 2004, 70(6): 066123
- [10] Xing Hong-jie, Hu Bao-gang. Two-Phase Construction of Multi-layer Perceptions Using Information Theory[J]. IEEE Transactions on Neural Networks, 2009, 20(4): 542-550
- [11] Rossi F, Lendasse A, Francois D, et al. Mutual information for the selection of relevant variables in spectrometric nonlinear modeling[J]. Chemometrics and Intelligent Laboratory Sys-

tems, 2006, 80: 215-226

- [12] Huang Guang-bin, et al. A generalized growing and pruning RBF (GGAP-RBF) neural network for function approximation[J]. IEEE Transaction on Neural Networks, 2005, 16(1): 57-67
- [13] Xu Jin-hua, Ho D W C. A new training and pruning algorithm based on node dependence and Jacobian rank deficiency[J]. Neurocomputing, 2006, 70(1-3): 544-558
- [14] Ridella A, Rovetta S, Zunino R. Circular back propagation for classification[J]. IEEE Transaction on Neural Networks, 1997, 8(1): 84-97