



(12)发明专利

(10)授权公告号 CN 105338335 B

(45)授权公告日 2017.03.29

(21)申请号 201510673217.3

(22)申请日 2015.10.15

(65)同一申请的已公布的文献号

申请公布号 CN 105338335 A

(43)申请公布日 2016.02.17

(73)专利权人 宁波大学

地址 315211 浙江省宁波市江北区风华路
818号

(72)发明人 邵枫 张竹青 李福翠

(74)专利代理机构 宁波奥圣专利代理事务所
(普通合伙) 33226

代理人 周珏

(51)Int.Cl.

H04N 13/00(2006.01)

(56)对比文件

CN 103369348 A, 2013.10.23,

CN 104243956 A, 2014.12.24,

CN 104574366 A, 2015.04.29,

KR 10-2014-0148080 A, 2014.12.31,

CN 104822058 A, 2015.08.05,

邵枫等.基于显著性分析的立体图像视觉舒
适度预测.《光学精密工程》.2014, 第22卷(第6
期),Gaoxiang Zhang ET AL.Saliency
Detection : A Self-adaption Sparse
Representation Approach.《2011 Sixth
International Conference on Image and
Graphics》.2011,

审查员 张永海

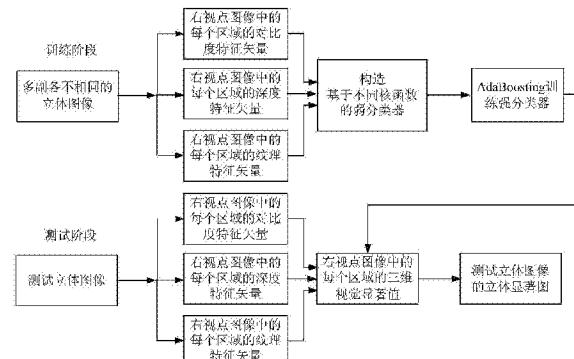
权利要求书6页 说明书16页 附图4页

(54)发明名称

一种立体图像显著图提取方法

(57)摘要

本发明公开了一种立体图像显著图提取方法,其包括训练阶段和测试阶段两个过程,在训练阶段,提取多幅立体图像各自的右视点图像中的每个区域的对比度、深度和纹理特征矢量,并分别构造基于不同核函数的弱分类器,再通过AdaBoosting模型构造使得经过训练得到的弱分类器的回归函数值与标签值之间的误差最小的强分类器;在测试阶段,计算测试立体图像的右视点图像中的每个区域的对比度、深度和纹理特征矢量,并利用已训练得到的强分类器来预测测试立体图像的右视点图像中的每个区域的三维视觉显著值,从而得到测试立体图像的立体显著图;优点是所训练得到的强分类器较好地反映了不同特征和不同核对显著的影响,从而有效地提高了三维视觉显著值的预测准确性。



1. 一种立体图像显著图提取方法, 其特征在于包括训练阶段和测试阶段两个过程, 所述的训练阶段过程的具体步骤如下:

①-1、将选取的N幅各不相同的立体图像以及每幅立体图像的右视差图像和右视点图像的真实眼动图构成一个集合, 记为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$, 其中, $N \geq 1$, L_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的左视点图像, R_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的右视点图像, d_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的右视差图像, F_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的右视点图像的真实眼动图;

①-2、采用超像素分割技术将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像分割成M个互不重叠的区域, 将 R_i 中的第*h*个区域记为 $SP_{i,h}$, 其中, $M \geq 1, 1 \leq h \leq M$;

①-3、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域的对比度特征矢量, 将 $SP_{i,h}$ 的对比度特征矢量记为 $\mathbf{X}_{i,h}^c, \mathbf{X}_{i,h}^c = [f_{i,h}^1, f_{i,h}^2, f_{i,h}^3, f_{i,h}^4, f_{i,h}^5, f_{i,h}^6]$, 其中, $\mathbf{X}_{i,h}^c$ 的维数为6, 符号“[]”为矢量表示符号, $f_{i,h}^1$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的L分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的L分量的颜色值的距离, $f_{i,h}^2$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的a分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的a分量的颜色值的距离, $f_{i,h}^3$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的b分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的b分量的颜色值的距离, $f_{i,h}^4$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的R分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的R分量的颜色值的距离, $f_{i,h}^5$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的G分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的G分量的颜色值的距离, $f_{i,h}^6$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的B分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的B分量的颜色值的距离, R_i 中的背景区域是指 R_i 中位于最左边、最右边、最上边、最下边的区域, $SP_{i,h}$ 的相邻区域是指 R_i 中与 $SP_{i,h}$ 左相邻、右相邻、上相邻、下相邻的区域;

①-4、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域的深度特征矢量, 将 $SP_{i,h}$ 的深度特征矢量记为 $\mathbf{X}_{i,h}^d, \mathbf{X}_{i,h}^d = [\bar{d}_{i,h}, g_{i,h}^1, g_{i,h}^2]$, 其中, $\mathbf{X}_{i,h}^d$ 的维数为3, 符号“[]”为矢量表示符号, $\bar{d}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点的视差幅值的均值, $g_{i,h}^1$ 表示 $SP_{i,h}$ 中的所有像素点的视差幅值与 R_i 中的背景区域中的所有像素点的视差幅值的距离, $g_{i,h}^2$ 表示 $SP_{i,h}$ 中的所有像素点的视差幅值与 $SP_{i,h}$ 的相邻区域中的所有像素点的视差幅值的距离;

①-5、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域中的所有像素点的LBP特征统计直方图, 将以矢量形式表示的LBP特征统计直方图作为对应区域的纹理特征矢量, 将 $SP_{i,h}$ 的纹理特征矢量记为 $\mathbf{X}_{i,h}^t$, 其中, $\mathbf{X}_{i,h}^t$ 的维数为59;

①-6、按 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的M个互不重叠的区域, 将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像的真实眼动图对应分割成M个互不重叠的区域; 然后计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像的真

实眼动图中的每个区域的平均眼动值；接着按平均眼动值的大小对 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有N幅立体图像的右视点图像的真实眼动图中的 $M \times N$ 个区域进行排序；之后从排序后的 $M \times N$ 个区域中取平均眼动值最高的20%区域，并将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有立体图像的右视点图像中与所取的每个区域对应的区域作为正样本区域，同时从排序后的 $M \times N$ 个区域中取平均眼动值最低的40%区域，并将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有立体图像的右视点图像中与所取的每个区域对应的区域作为负样本区域；再将所有正样本区域的特征矢量集的集合作为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 的正样本集合，记为 $\{\mathbf{S}_j^+ | 1 \leq j \leq T_1\}$ ，并将所有负样本区域的特征矢量集的集合作为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 的负样本集合，记为 $\{\mathbf{S}_k^- | 1 \leq k \leq T_2\}$ ；最后将 $\{\mathbf{S}_j^+ | 1 \leq j \leq T_1\}$ 和 $\{\mathbf{S}_k^- | 1 \leq k \leq T_2\}$ 构成初始的样本训练集，记为 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ ， $\{\mathbf{S}_r^-\} = \{\mathbf{S}_j^+, \mathbf{S}_k^-\}$ ；其中， \mathbf{S}_j^+ 表示第 j 个正样本区域的特征矢量集， $\mathbf{S}_j^+ = \{\mathbf{X}_j^c, \mathbf{X}_j^d, \mathbf{X}_j^t, L_j\}$ ， \mathbf{X}_j^c 表示第 j 个正样本区域的对比度特征矢量， \mathbf{X}_j^d 表示第 j 个正样本区域的深度特征矢量， \mathbf{X}_j^t 表示第 j 个正样本区域的纹理特征矢量， L_j 表示第 j 个正样本区域的标签值， $L_j = +1$ ， T_1 表示正样本区域的总个数， $T_1 = 0.2 \times M \times N$ ， \mathbf{S}_k^- 表示第 k 个负样本区域的特征矢量集， $\mathbf{S}_k^- = \{\mathbf{X}_k^{c'}, \mathbf{X}_k^{d'}, \mathbf{X}_k^{t'}, L_k'\}$ ， $\mathbf{X}_k^{c'}$ 表示第 k 个负样本区域的对比度特征矢量， $\mathbf{X}_k^{d'}$ 表示第 k 个负样本区域的深度特征矢量， $\mathbf{X}_k^{t'}$ 表示第 k 个负样本区域的纹理特征矢量， L_k' 表示第 k 个负样本区域的标签值， $L_k' = -1$ ， T_2 表示负样本区域的总个数， $T_2 = 0.4 \times M \times N$ ， \mathbf{S}_r^+ 表示 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的第 r 个样本， \mathbf{S}_r^+ 为正样本或为负样本，若 \mathbf{S}_r^+ 中的标签值为 $+1$ ，则 \mathbf{S}_r^+ 为正样本，若 \mathbf{S}_r^+ 中的标签值为 -1 ，则 \mathbf{S}_r^+ 为负样本， $T = 0.6 \times M \times N$ ， $T = T_1 + T_2$ ；

①-7、采用AdaBoosting模型作为机器学习的方法，对 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的所有正样本和所有负样本进行训练，使得经过训练得到的弱分类器的回归函数值与标签值之间的误差最小，得到 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的每个样本的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数，将 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的任意一个样本的第 m 个弱分类器的回归函数的最优的权重矢量和最优的偏置项及权重系数对应记为 \mathbf{w}_m^{opt} 和 b_m^{opt} 及 β_m^{opt} ；然后根据 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的任意一个样本的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数，构造一个强分类器，将根据 \mathbf{S}_r^+ 的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数构造的强分类器记为 $\Phi(r)$ ， $\phi(r) = \sum_{m=1}^L \beta_m^{opt} ((\mathbf{w}_m^{opt})^T \mathbf{k}_m(r) + b_m^{opt})$ ；其中， $1 \leq m \leq L$ ， L 表示 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的任意一个样本的弱分类器的总个数， $L = N_f \times N_k$ ， N_f 表示 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的任意一个样本中的特征矢量的总个数， $N_f = 3$ ， N_k 表示 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$ 中的任意一个样本的任意一个弱分类器的回归函数的核的总个数， $N_k \geq 2$ ， $(\mathbf{w}_m^{opt})^T$ 为 \mathbf{w}_m^{opt} 的转置矢量， $\mathbf{k}_m(r)$ 表示 \mathbf{S}_r^+ 的第 m 个弱分类器的回归函数的核函数；

所述的步骤①-7中将 \mathbf{w}_m^{opt} 和 b_m^{opt} 及 β_m^{opt} 组成一个组合，记为 $(\mathbf{w}_m^{opt}, b_m^{opt}, \beta_m^{opt})$ ， $(\mathbf{w}_m^{opt}, b_m^{opt}, \beta_m^{opt}) = \arg \min_{(\mathbf{w}_m, b_m, \beta_m) \in \Psi} \sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$ ，其中， $\arg \min_{(\mathbf{w}_m, b_m, \beta_m) \in \Psi} \sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$ 表

示取使得 $\sum_{r=1}^T \left(\sum_{m=1}^L \beta_m \left((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m \right) - L_r \right)^2$ 的值最小的 w_m 、 b_m 和 β_m 的值， w_m 、 b_m 和 β_m 对应表示权重矢量、偏置项和权重系数， (w_m, b_m, β_m) 为 w_m 、 b_m 和 β_m 组成的组合， Ψ 表示对 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的所有样本进行训练的所有的权重矢量和偏置项及权重系数的组合的集合， $(w_m)^T$ 为 w_m 的转置矢量， L_r 表示 \mathbf{S}_r^\pm 中的标签值；

所述的测试阶段过程的具体步骤如下：

②-1、对于任意一幅测试立体图像 S_{test} ，将 S_{test} 的左视点图像、右视点图像、右视差图像对应记为 L_{test} 、 R_{test} 、 d_{test} ；然后采用超像素分割技术将 R_{test} 分割成 M' 个互不重叠的区域，将 R_{test} 中的第 h 个区域记为 SP_h' ，其中， $M' \geq 1, 1 \leq h \leq M'$ ；

②-2、按照步骤①-3至步骤①-5的过程，以相同的操作方式获取 R_{test} 中的每个区域的对比度特征矢量、深度特征矢量和纹理特征矢量；然后将 R_{test} 中的每个区域的对比度特征矢量、深度特征矢量和纹理特征矢量构成的集合作为输入样本；再计算 R_{test} 中的每个区域对应的输入样本的每个弱分类器的回归函数的核函数，将 SP_h' 对应的输入样本的第 m 个弱分类器的回归函数的核函数记为 $k_m(h)$ ；

②-3、根据训练阶段构造的强分类器 $\phi(r)$ ，获取 R_{test} 中的每个区域的三维视觉显著值，将 SP_h' 的三维视觉显著值记为 $S_{3D,h}$ ， $S_{3D,h} = \phi(h) = \sum_{m=1}^L \beta_m^{opt} \left((\mathbf{w}_m^{opt})^T \mathbf{k}_m(h) + b_m^{opt} \right)$ ；再将 R_{test} 中的每个区域的三维视觉显著值作为对应区域中的所有像素点的显著值，对于 SP_h' ，将 SP_h' 的三维视觉显著值作为 SP_h' 中的所有像素点的显著值，从而得到 S_{test} 的立体显著图，记为 $\{S_{3D}(x', y')\}$ ，其中， (x', y') 表示 S_{test} 中的像素点的坐标位置， $1 \leq x' \leq W'$ ， $1 \leq y' \leq H'$ ， W' 和 H' 对应表示 S_{test} 的宽度和高度， $S_{3D}(x', y')$ 表示 $\{S_{3D}(x', y')\}$ 中坐标位置为 (x', y') 的像素点的像素值， $S_{3D}(x', y')$ 亦表示 R_{test} 中坐标位置为 (x', y') 的像素点的显著值。

2. 根据权利要求1所述的一种立体图像显著图提取方法，其特征在于所述的步骤①-3中的 $\mathbf{X}_{i,h}^c$ 的获取过程为：

①-3a、计算 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的L分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的L分量的颜色值的距离 $f_{i,h}^1$ ， $f_{i,h}^1 = \frac{\sum_{q \in \mathbb{Q}} |\bar{L}_{i,h} - \bar{L}_{i,q}|}{Q}$ ，其

中， \mathbb{Q} 表示 R_i 中的所有背景区域的序号的集合， $\bar{L}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的L分量的颜色值的均值， $\bar{L}_{i,q}$ 表示 R_i 中的第 q 个区域 $SP_{i,q}$ 中的所有像素点在CIELAB颜色空间的L分量的颜色值的均值， Q 表示 R_i 中的背景区域的总个数，符号“|”为取绝对值符号；

①-3b、计算 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的a分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的a分量的颜色值的距离 $f_{i,h}^2$ ， $f_{i,h}^2 = \frac{\sum_{q \in \mathbb{Q}} |\bar{a}_{i,h} - \bar{a}_{i,q}|}{Q}$ ，其

中， $\bar{a}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的a分量的颜色值的均值， $\bar{a}_{i,q}$ 表示 R_i 中的第 q 个区域 $SP_{i,q}$ 中的所有像素点在CIELAB颜色空间的a分量的颜色值的均值；

①-3c、计算 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的b分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的b分量的颜色值的距离 $f_{i,h}^3$ ， $f_{i,h}^3 = \frac{\sum_{q \in \mathbb{Q}} |\bar{b}_{i,h} - \bar{b}_{i,q}|}{Q}$ ，其中， $\bar{b}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的b分量的颜色值的均值， $\bar{b}_{i,q}$ 表示 R_i 中的第q个区域 $SP_{i,q}$ 中的所有像素点在CIELAB颜色空间的b分量的颜色值的均值；

①-3d、计算 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的R分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的R分量的颜色值的距离 $f_{i,h}^4$ ， $f_{i,h}^4 = \frac{\sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |\bar{R}_{i,h} - \bar{R}_{i,p}|^2 \right)}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}$ ，其中， \mathbb{N}_h 表示 $SP_{i,h}$ 的所有相邻区域的序号的集合， $\exp()$ 表示以自然基数e为底的指数函数， \mathbf{x}_{SP_h} 表示 $SP_{i,h}$ 中的中心像素点的坐标位置， \mathbf{x}_{SP_p} 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的中心像素点的坐标位置， σ_p 表示高斯函数的标准差， $\bar{R}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的R分量的颜色值的均值， $\bar{R}_{i,p}$ 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的所有像素点在RGB颜色空间的R分量的颜色值的均值，P表示 $SP_{i,h}$ 的相邻区域的总个数，符号“|| |”为求欧式距离符号；

①-3e、计算 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的G分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的G分量的颜色值的距离 $f_{i,h}^5$ ， $f_{i,h}^5 = \frac{\sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |\bar{G}_{i,h} - \bar{G}_{i,p}|^2 \right)}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}$ ，其中， $\bar{G}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的G分量的颜色值的均值， $\bar{G}_{i,p}$ 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的所有像素点在RGB颜色空间的G分量的颜色值的均值；

①-3f、计算 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的B分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的B分量的颜色值的距离 $f_{i,h}^6$ ， $f_{i,h}^6 = \frac{\sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |\bar{B}_{i,h} - \bar{B}_{i,p}|^2 \right)}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}$ ，其中， $\bar{B}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的B分量的颜色值的均值， $\bar{B}_{i,p}$ 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的所有像素点在RGB颜色空间的B分量的颜色值的均值；

①-3g、将 $f_{i,h}^1$ 、 $f_{i,h}^2$ 、 $f_{i,h}^3$ 、 $f_{i,h}^4$ 、 $f_{i,h}^5$ 和 $f_{i,h}^6$ 按顺序进行排列，构成 $SP_{i,h}$ 的对比度特征矢量 $\mathbf{X}_{i,h}^c$ 。

3. 根据权利要求1或2所述的一种立体图像显著图提取方法，其特征在于所述的步骤①-4中的 $\mathbf{X}_{i,h}^d$ 的获取过程为：

①-4a、计算 $SP_{i,h}$ 中的所有像素点的视差幅值的均值 $\bar{d}_{i,h}$ ；
 ①-4b、计算 $SP_{i,h}$ 中的所有像素点的视差幅值与 R_i 中的背景区域中的所有像素点的视差幅值的距离 $g_{i,h}^1$ ， $g_{i,h}^1 = \frac{\sum_{q \in \mathbb{Q}} |\bar{d}_{i,h} - \bar{d}_{i,q}|}{Q}$ ，其中， \mathbb{Q} 表示 R_i 中的所有背景区域的序号的集合， $\bar{d}_{i,q}$ 表示 R_i 中的第q个区域 $SP_{i,q}$ 中的所有像素点的视差幅值的均值，Q表示 R_i 中的背景区域的总

个数,符号“||”为取绝对值符号;

①-4c、计算 $SP_{i,h}$ 中的所有像素点的视差幅值与 $SP_{i,h}$ 的相邻区域中的所有像素点的视

$$\text{差幅值的距离 } g_{i,h}^2 = \frac{\sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |\bar{d}_{i,h} - \bar{d}_{i,p}|^2 \right)}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}, \text{ 其中, } \mathbb{N}_h \text{ 表示}$$

$SP_{i,h}$ 的所有相邻区域的序号的集合, $\exp()$ 表示以自然基数e为底的指数函数, \mathbf{x}_{SP_h} 表示 $SP_{i,h}$ 中的中心像素点的坐标位置, \mathbf{x}_{SP_p} 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的中心像素点的坐标位置, σ_p 表示高斯函数的标准差, $\bar{d}_{i,p}$ 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的所有像素点的视差幅值的均值, P表示 $SP_{i,h}$ 的相邻区域的总个数, 符号“|| |”为求欧式距离符号;

①-4d、将 $\bar{d}_{i,h}$ 、 $g_{i,h}^1$ 和 $g_{i,h}^2$ 按顺序进行排列, 构成 $SP_{i,h}$ 的深度特征矢量 $\mathbf{X}_{i,h}^d$ 。

4. 根据权利要求3所述的一种立体图像显著图提取方法, 其特征在于所述的步骤①-7 中将 \mathbf{S}_r^\pm 的第m个弱分类器的回归函数记为 $f_m(r)$, $f_m(r) = (\mathbf{w}_m)^T k_m(r) + b_m$, 其中, \mathbf{w}_m 为权重矢量, $(\mathbf{w}_m)^T$ 为 \mathbf{w}_m 的转置矢量, b_m 为偏置项, $k_m(r)$ 表示 $f_m(r)$ 的核函数。

5. 根据权利要求4所述的一种立体图像显著图提取方法, 其特征在于所述的步骤①-7 中当取 $N_k = 3$ 时 $1 \leq m \leq 9$, 则 \mathbf{S}_r^\pm 的第1个弱分类器的回归函数的核函数为 $k_1(r)$,

$$k_1(r) = \sum_{r'=1}^T \exp\left(-\gamma \times \|\mathbf{X}_r^c - \mathbf{X}_{r'}^c\|^2\right); \mathbf{S}_r^\pm$$
 的第2个弱分类器的回归函数的核函数为 $k_2(r)$,

$$k_2(r) = \sum_{r'=1}^T \exp\left(-\gamma \times \|\mathbf{X}_r^d - \mathbf{X}_{r'}^d\|^2\right); \mathbf{S}_r^\pm$$
 的第3个弱分类器的回归函数的核函数为 $k_3(r)$,

$$k_3(r) = \sum_{r'=1}^T \exp\left(-\gamma \times \|\mathbf{X}_r^t - \mathbf{X}_{r'}^t\|^2\right); \mathbf{S}_r^\pm$$
 的第4个弱分类器的回归函数的核函数为 $k_4(r)$,

$$k_4(r) = \sum_{r'=1}^T (\mathbf{X}_r^c)^T \mathbf{X}_{r'}^c; \mathbf{S}_r^\pm$$
 的第5个弱分类器的回归函数的核函数为 $k_5(r)$, $k_5(r) = \sum_{r'=1}^T (\mathbf{X}_r^d)^T \mathbf{X}_{r'}^d; \mathbf{S}_r^\pm$

的第6个弱分类器的回归函数的核函数为 $k_6(r)$, $k_6(r) = \sum_{r'=1}^T (\mathbf{X}_r^t)^T \mathbf{X}_{r'}^t; \mathbf{S}_r^\pm$ 的第7个弱分类器的

回归函数的核函数为 $k_7(r)$, $k_7(r) = \sum_{r'=1}^T (\gamma \times (\mathbf{X}_r^c)^T \mathbf{X}_{r'}^c + e)^d; \mathbf{S}_r^\pm$ 的第8个弱分类器的回归函数的

核函数为 $k_8(r)$, $k_8(r) = \sum_{r'=1}^T (\gamma \times (\mathbf{X}_r^d)^T \mathbf{X}_{r'}^d + e)^d; \mathbf{S}_r^\pm$ 的第9个弱分类器的回归函数的核函数为 k_9

(r), $k_9(r) = \sum_{r'=1}^T (\gamma \times (\mathbf{X}_r^t)^T \mathbf{X}_{r'}^t + e)^d$; 其中, $1 \leq r' \leq T$, $\exp()$ 表示以自然基数e为底的指数函数,

\mathbf{X}_r^c 、 \mathbf{X}_r^d 和 \mathbf{X}_r^t 对应表示 \mathbf{S}_r^\pm 中的对比度特征矢量、深度特征矢量和纹理特征矢量, \mathbf{X}_r^c 、 \mathbf{X}_r^d 和

\mathbf{X}_r^t 对应表示 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的第 r' 个样本 \mathbf{S}_r^\pm 中的对比度特征矢量、深度特征矢量和纹理特

征矢量, $(\mathbf{X}_r^c)^T$ 为 \mathbf{X}_r^c 的转置矩阵, $(\mathbf{X}_r^d)^T$ 为 \mathbf{X}_r^d 的转置矩阵, $(\mathbf{X}_r^t)^T$ 为 \mathbf{X}_r^t 的转置矩阵, γ 、e和d均

为核参数, 符号“|| |”为求欧式距离符号。

6. 根据权利要求5所述的一种立体图像显著图提取方法, 其特征在于所述的核参数 $\gamma = 1/10$, $e = 3$, $d = 1$ 。

7. 根据权利要求1所述的一种立体图像显著图提取方法, 其特征在于所述的步骤②-2

中当取N_k=3时1≤m≤9,则SP_h'对应的输入样本的第1个弱分类器的回归函数的核函数为k₁(h), $\mathbf{k}_1(h)=\sum_{h'=1}^{M'} \exp\left(-\gamma \times \|\mathbf{X}_h^c - \mathbf{X}_{h'}^c\|^2\right)$;SP_h'对应的输入样本的第2个弱分类器的回归函数的核函数为k₂(h), $\mathbf{k}_2(h)=\sum_{h'=1}^{M'} \exp\left(-\gamma \times \|\mathbf{X}_h^d - \mathbf{X}_{h'}^d\|^2\right)$;SP_h'对应的输入样本的第3个弱分类器的回归函数的核函数为k₃(h), $\mathbf{k}_3(h)=\sum_{h'=1}^{M'} \exp\left(-\gamma \times \|\mathbf{X}_h^t - \mathbf{X}_{h'}^t\|^2\right)$;SP_h'对应的输入样本的第4个弱分类器的回归函数的核函数为k₄(h), $\mathbf{k}_4(h)=\sum_{h'=1}^{M'} (\mathbf{X}_h^c)^T \mathbf{X}_{h'}^c$;SP_h'对应的输入样本的第5个弱分类器的回归函数的核函数为k₅(h), $\mathbf{k}_5(h)=\sum_{h'=1}^{M'} (\mathbf{X}_h^d)^T \mathbf{X}_{h'}^d$;SP_h'对应的输入样本的第6个弱分类器的回归函数的核函数为k₆(h), $\mathbf{k}_6(h)=\sum_{h'=1}^{M'} (\mathbf{X}_h^t)^T \mathbf{X}_{h'}^t$;SP_h'对应的输入样本的第7个弱分类器的回归函数的核函数为k₇(h), $\mathbf{k}_7(h)=\sum_{h'=1}^{M'} \left(\gamma \times (\mathbf{X}_h^c)^T \mathbf{X}_{h'}^c + e\right)^d$;SP_h'对应的输入样本的第8个弱分类器的回归函数的核函数为k₈(h), $\mathbf{k}_8(h)=\sum_{h'=1}^{M'} \left(\gamma \times (\mathbf{X}_h^d)^T \mathbf{X}_{h'}^d + e\right)^d$;SP_h'对应的输入样本的第9个弱分类器的回归函数的核函数为k₉(h), $\mathbf{k}_9(h)=\sum_{h'=1}^{M'} \left(\gamma \times (\mathbf{X}_h^t)^T \mathbf{X}_{h'}^t + e\right)^d$;其中,1≤h'≤M',exp()表示以自然基数e为底的指数函数, \mathbf{X}_h^c 、 \mathbf{X}_h^d 和 \mathbf{X}_h^t 对应表示SP_h'对应的输入样本中的对比度特征矢量、深度特征矢量和纹理特征矢量, \mathbf{X}_h^c 、 \mathbf{X}_h^d 和 \mathbf{X}_h^t 对应表示R_{test}中的第h'个区域SP_h"对应的输入样本中的对比度特征矢量、深度特征矢量和纹理特征矢量,(\mathbf{X}_h^c)^T为 \mathbf{X}_h^c 的转置矩阵,(\mathbf{X}_h^d)^T为 \mathbf{X}_h^d 的转置矩阵,(\mathbf{X}_h^t)^T为 \mathbf{X}_h^t 的转置矩阵,γ、e和d均为核参数,符号“|||”为求欧式距离符号。

8. 根据权利要求7所述的一种立体图像显著图提取方法,其特征在于所述的核参数γ=1/10,e=3,d=1。

一种立体图像显著图提取方法

技术领域

[0001] 本发明涉及一种图像信号的处理方法,尤其是涉及一种立体图像显著图提取方法。

背景技术

[0002] 在人类视觉接收与信息处理中,由于大脑资源有限以及外界环境信息重要性区别,因此在处理过程中人脑对外界环境信息并不是一视同仁的,而是表现出选择特征。人们在观看图像或者视频片段时注意力并非均匀分布到图像的每个区域,而是对某些显著区域关注度更高。如何将视频中视觉注意度高的显著区域检测并提取出来是计算机视觉以及基于内容的视频检索领域的一个重要的研究内容。而随着立体视频显示技术和高质量立体视频内容获取技术的快速发展,针对立体图像/视频的显著区域检测及建模也是一个非常重要的研究内容。

[0003] 然而,立体图像并不是平面图像的简单空间拓展,因此人眼感知立体图像产生立体视觉的过程也不是简单的左视点图像和右视点图像叠加的过程,因此,立体视觉特征(例如:三维视觉注意力)并不是平面视觉特性的简单拓展。然而,现有的立体图像显著图提取方法还停留在平面图像显著提取方法的简单拓展。因此,如何从立体图像中有效地提取出立体视觉特征、如何使得提取出的立体视觉特征符合人眼三维观看行为、如何采用机器学习方法训练出分类模型,都是在对立体图像进行视觉显著图提取过程中需要研究解决的问题。

发明内容

[0004] 本发明所要解决的技术问题是提供一种立体图像显著图提取方法,其符合显著语义特征,且具有较强的提取稳定性和较高的提取准确性。

[0005] 本发明解决上述技术问题所采用的技术方案为:一种立体图像显著图提取方法,其特征在于包括训练阶段和测试阶段两个过程,所述的训练阶段过程的具体步骤如下:

[0006] ①-1、将选取的N幅各不相同的立体图像以及每幅立体图像的右视差图像和右视点图像的真实眼动图构成一个集合,记为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$, 其中, $N \geq 1$, L_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第 i 幅立体图像的左视点图像, R_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第 i 幅立体图像的右视点图像, d_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第 i 幅立体图像的右视差图像, F_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第 i 幅立体图像的右视点图像的真实眼动图;

[0007] ①-2、采用超像素分割技术将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像分割成M个互不重叠的区域,将 R_i 中的第 h 个区域记为 $SP_{i,h}$, 其中, $M \geq 1$, $1 \leq h \leq M$;

[0008] ①-3、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域的对比度特征矢量,将 $SP_{i,h}$ 的对比度特征矢量记为 $\mathbf{X}_{i,h}^c$, $\mathbf{X}_{i,h}^c = [f_{i,h}^1, f_{i,h}^2, f_{i,h}^3, f_{i,h}^4, f_{i,h}^5, f_{i,h}^6]$, 其中, $\mathbf{X}_{i,h}^c$ 的维数为6, 符号“[]”为矢量表示符号, $f_{i,h}^1$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜

色空间的L分量的颜色值与R_i中的背景区域中的所有像素点在CIELAB颜色空间的L分量的颜色值的距离, $f_{i,h}^2$ 表示SP_{i,h}中的所有像素点在CIELAB颜色空间的a分量的颜色值与R_i中的背景区域中的所有像素点在CIELAB颜色空间的a分量的颜色值的距离, $f_{i,h}^3$ 表示SP_{i,h}中的所有像素点在CIELAB颜色空间的b分量的颜色值与R_i中的背景区域中的所有像素点在CIELAB颜色空间的b分量的颜色值的距离, $f_{i,h}^4$ 表示SP_{i,h}中的所有像素点在RGB颜色空间的R分量的颜色值与SP_{i,h}的相邻区域中的所有像素点在RGB颜色空间的R分量的颜色值的距离, $f_{i,h}^5$ 表示SP_{i,h}中的所有像素点在RGB颜色空间的G分量的颜色值与SP_{i,h}的相邻区域中的所有像素点在RGB颜色空间的G分量的颜色值的距离, $f_{i,h}^6$ 表示SP_{i,h}中的所有像素点在RGB颜色空间的B分量的颜色值与SP_{i,h}的相邻区域中的所有像素点在RGB颜色空间的B分量的颜色值的距离, R_i中的背景区域是指R_i中位于最左边、最右边、最上边、最下边的区域, SP_{i,h}的相邻区域是指R_i中与SP_{i,h}左相邻、右相邻、上相邻、下相邻的区域;

[0009] ①-4、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域的深度特征矢量, 将SP_{i,h}的深度特征矢量记为 $\mathbf{X}_{i,h}^d$, $\mathbf{X}_{i,h}^d = [\bar{d}_{i,h}, g_{i,h}^1, g_{i,h}^2]$, 其中, $\mathbf{X}_{i,h}^d$ 的维数为3, 符号“[]”为矢量表示符号, $\bar{d}_{i,h}$ 表示SP_{i,h}中的所有像素点的视差幅值的均值, $g_{i,h}^1$ 表示SP_{i,h}中的所有像素点的视差幅值与R_i中的背景区域中的所有像素点的视差幅值的距离, $g_{i,h}^2$ 表示SP_{i,h}中的所有像素点的视差幅值与SP_{i,h}的相邻区域中的所有像素点的视差幅值的距离;

[0010] ①-5、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域中的所有像素点的LBP特征统计直方图, 将以矢量形式表示的LBP特征统计直方图作为对应区域的纹理特征矢量, 将SP_{i,h}的纹理特征矢量记为 $\mathbf{X}_{i,h}^t$, 其中, $\mathbf{X}_{i,h}^t$ 的维数为59;

[0011] ①-6、按 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的M个互不重叠的区域, 将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像的真实眼动图对应分割成M个互不重叠的区域; 然后计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像的真实眼动图中的每个区域的平均眼动值; 接着按平均眼动值的大小对 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有N幅立体图像的右视点图像的真实眼动图中的M×N个区域进行排序; 之后从排序后的M×N个区域中取平均眼动值最高的20%区域, 并将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有立体图像的右视点图像中与所取的每个区域对应的区域作为正样本区域, 同时从排序后的M×N个区域中取平均眼动值最低的40%区域, 并将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有立体图像的右视点图像中与所取的每个区域对应的区域作为负样本区域; 再将所有正样本区域的特征矢量集的集合作为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 的正样本集合, 记为 $\{\mathbf{S}_j^+ | 1 \leq j \leq T_1\}$, 并将所有负样本区域的特征矢量集的集合作为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 的负样本集合, 记为 $\{\mathbf{S}_k^- | 1 \leq k \leq T_2\}$; 最后将 $\{\mathbf{S}_j^+ | 1 \leq j \leq T_1\}$ 和 $\{\mathbf{S}_k^- | 1 \leq k \leq T_2\}$ 构成初始的样本训练集, 记为 $\{\mathbf{S}_r^+ | 1 \leq r \leq T\}$, $\{\mathbf{S}_r^+\} = \{\mathbf{S}_j^+, \mathbf{S}_k^-\}$; 其中, \mathbf{S}_j^+ 表示第j个正样本区域的特征矢量集, $\mathbf{S}_j^+ = \{\mathbf{X}_j^c, \mathbf{X}_j^d, \mathbf{X}_j^t, L_j\}$, \mathbf{X}_j^c 表示第j个正样本区域的对比度特征矢量, \mathbf{X}_j^d 表示第j个正样本区域的深度特征矢量, \mathbf{X}_j^t 表示第j个正样本区

域的纹理特征矢量, L_j 表示第 j 个正样本区域的标签值, $L_j = +1$, T_1 表示正样本区域的总个数, $T_1 = 0.2 \times M \times N$, \mathbf{S}_k^- 表示第 k 个负样本区域的特征矢量集, $\mathbf{S}_k^- = \{\mathbf{X}_k^c, \mathbf{X}_k^d, \mathbf{X}_k^t, L_k^-\}$, \mathbf{X}_k^c 表示第 k 个负样本区域的对比度特征矢量, \mathbf{X}_k^d 表示第 k 个负样本区域的深度特征矢量, \mathbf{X}_k^t 表示第 k 个负样本区域的纹理特征矢量, L_k^- 表示第 k 个负样本区域的标签值, $L_k^- = -1$, T_2 表示负样本区域的总个数, $T_2 = 0.4 \times M \times N$, \mathbf{S}_r^\pm 表示 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的第 r 个样本, \mathbf{S}_r^\pm 为正样本或为负样本, 若 \mathbf{S}_r^\pm 中的标签值为 $+1$, 则 \mathbf{S}_r^\pm 为正样本, 若 \mathbf{S}_r^\pm 中的标签值为 -1 , 则 \mathbf{S}_r^\pm 为负样本, $T = 0.6 \times M \times N$, $T = T_1 + T_2$;

[0012] ①-7、采用AdaBoosting模型作为机器学习的方法, 对 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的所有正样本和所有负样本进行训练, 使得经过训练得到的弱分类器的回归函数值与标签值之间的误差最小, 得到 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的每个样本的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数, 将 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的任意一个样本的第 m 个弱分类器的回归函数的最优的权重矢量和最优的偏置项及权重系数对应记为 \mathbf{w}_m^{opt} 和 b_m^{opt} 及 β_m^{opt} ; 然后根据 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的任意一个样本的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数, 构造一个强分类器, 将根据 \mathbf{S}_r^\pm 的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数构造的强分类器记为 $\Phi(r)$, $\phi(r) = \sum_{m=1}^L \beta_m^{opt} ((\mathbf{w}_m^{opt})^T \mathbf{k}_m(r) + b_m^{opt})$; 其中, $1 \leq m \leq L$, L 表示 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的任意一个样本的弱分类器的总个数, $L = N_f \times N_k$, N_f 表示 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的任意一个样本中的特征矢量的总个数, $N_f = 3$, N_k 表示 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的任意一个样本的任意一个弱分类器的回归函数的核的总个数, $N_k \geq 2$, $(\mathbf{w}_m^{opt})^T$ 为 \mathbf{w}_m^{opt} 的转置矢量, $\mathbf{k}_m(r)$ 表示 \mathbf{S}_r^\pm 的第 m 个弱分类器的回归函数的核函数;

[0013] 所述的测试阶段过程的具体步骤如下:

[0014] ②-1、对于任意一幅测试立体图像 S_{test} , 将 S_{test} 的左视点图像、右视点图像、右视差图像对应记为 L_{test} 、 R_{test} 、 d_{test} ; 然后采用超像素分割技术将 R_{test} 分割成 M' 个互不重叠的区域, 将 R_{test} 中的第 h 个区域记为 SP_h' , 其中, $M' \geq 1$, $1 \leq h \leq M'$;

[0015] ②-2、按照步骤①-3至步骤①-5的过程, 以相同的操作方式获取 R_{test} 中的每个区域的对比度特征矢量、深度特征矢量和纹理特征矢量; 然后将 R_{test} 中的每个区域的对比度特征矢量、深度特征矢量和纹理特征矢量构成的集合作为输入样本; 再计算 R_{test} 中的每个区域对应的输入样本的每个弱分类器的回归函数的核函数, 将 SP_h' 对应的输入样本的第 m 个弱分类器的回归函数的核函数记为 $k_m(h)$;

[0016] ②-3、根据训练阶段构造的强分类器 $\Phi(r)$, 获取 R_{test} 中的每个区域的三维视觉显著值, 将 SP_h' 的三维视觉显著值记为 $S_{3D,h}$, $S_{3D,h} = \Phi(h)$, $\phi(h) = \sum_{m=1}^L \beta_m^{opt} ((\mathbf{w}_m^{opt})^T \mathbf{k}_m(h) + b_m^{opt})$; 再将 R_{test} 中的每个区域的三维视觉显著值作为对应区域中的所有像素点的显著值, 对于 SP_h' , 将 SP_h' 的三维视觉显著值作为 SP_h' 中的所有像素点的显著值, 从而得到 S_{test} 的立体显著图, 记为 $\{S_{3D}(x', y')\}$, 其中, (x', y') 表示 S_{test} 中的像素点的坐标位置, $1 \leq x' \leq W'$, $1 \leq y' \leq H'$,

W'和H'对应表示S_{test}的宽度和高度,S_{3D}(x',y')表示{S_{3D}(x',y')}中坐标位置为(x',y')的像素点的像素值,S_{3D}(x',y')亦表示R_{test}中坐标位置为(x',y')的像素点的显著值。

[0017] 所述的步骤①-3中的X_{i,h}^c的获取过程为:

[0018] ①-3a、计算SP_{i,h}中的所有像素点在CIELAB颜色空间的L分量的颜色值与R_i中的背景区域中的所有像素点在CIELAB颜色空间的L分量的颜色值的距离f_{i,h}¹, f_{i,h}¹= $\frac{\sum_{q \in Q} |\bar{L}_{i,h} - \bar{L}_{i,q}|}{Q}$,

其中,Q表示R_i中的所有背景区域的序号的集合, $\bar{L}_{i,h}$ 表示SP_{i,h}中的所有像素点在CIELAB颜色空间的L分量的颜色值的均值, $\bar{L}_{i,q}$ 表示R_i中的第q个区域SP_{i,q}中的所有像素点在CIELAB颜色空间的L分量的颜色值的均值,Q表示R_i中的背景区域的总个数, 符号“|”为取绝对值符号;

[0019] ①-3b、计算SP_{i,h}中的所有像素点在CIELAB颜色空间的a分量的颜色值与R_i中的背景区域中的所有像素点在CIELAB颜色空间的a分量的颜色值的距离f_{i,h}², f_{i,h}²= $\frac{\sum_{q \in Q} |\bar{a}_{i,h} - \bar{a}_{i,q}|}{Q}$,

其中, $\bar{a}_{i,h}$ 表示SP_{i,h}中的所有像素点在CIELAB颜色空间的a分量的颜色值的均值, $\bar{a}_{i,q}$ 表示R_i中的第q个区域SP_{i,q}中的所有像素点在CIELAB颜色空间的a分量的颜色值的均值;

[0020] ①-3c、计算SP_{i,h}中的所有像素点在CIELAB颜色空间的b分量的颜色值与R_i中的背景区域中的所有像素点在CIELAB颜色空间的b分量的颜色值的距离f_{i,h}³, f_{i,h}³= $\frac{\sum_{q \in Q} |\bar{b}_{i,h} - \bar{b}_{i,q}|}{Q}$, 其

中, $\bar{b}_{i,h}$ 表示SP_{i,h}中的所有像素点在CIELAB颜色空间的b分量的颜色值的均值, $\bar{b}_{i,q}$ 表示R_i中的第q个区域SP_{i,q}中的所有像素点在CIELAB颜色空间的b分量的颜色值的均值;

[0021] ①-3d、计算SP_{i,h}中的所有像素点在RGB颜色空间的R分量的颜色值与SP_{i,h}的相邻区域中的所有像素点在RGB颜色空间的R分量的颜色值的距离f_{i,h}⁴, f_{i,h}⁴= $\frac{\sum_{p \in N_h} \exp(-\|\mathbf{x}_{SP_p} - \mathbf{x}_{SP_h}\|^2 / 2\sigma_p^2) \times \sum_{p \in N_h} |\bar{R}_{i,p} - \bar{R}_{i,h}|^2}{P \times \sum_{p \in N_h} \exp(-\|\mathbf{x}_{SP_p} - \mathbf{x}_{SP_h}\|^2 / 2\sigma_p^2)}$,

其中, N_h 表示SP_{i,h}的所有相邻区域的序号的集合, exp()表示以自然基数e为底的指数函数, \mathbf{x}_{SP_p} 表示SP_{i,h}中的中心像素点的坐标位置, \mathbf{x}_{SP_p} 表示R_i中的第p个区域SP_{i,p}中的中心像素点的坐标位置, σ_p 表示高斯函数的标准差, $\bar{R}_{i,p}$ 表示SP_{i,h}中的所有像素点在RGB颜色空间的R分量的颜色值的均值, $\bar{R}_{i,p}$ 表示R_i中的第p个区域SP_{i,p}中的所有像素点在RGB颜色空间的R分量的颜色值的均值,P表示SP_{i,h}的相邻区域的总个数, 符号“|| |”为求欧式距离符号;

[0022] ①-3e、计算SP_{i,h}中的所有像素点在RGB颜色空间的G分量的颜色值与SP_{i,h}的相邻区域中的所有像素点在RGB颜色空间的G分量的颜色值的距离f_{i,h}⁵, f_{i,h}⁵= $\frac{\sum_{p \in N_h} \exp(-\|\mathbf{x}_{SP_p} - \mathbf{x}_{SP_h}\|^2 / 2\sigma_p^2) \times \sum_{p \in N_h} |\bar{G}_{i,p} - \bar{G}_{i,h}|^2}{P \times \sum_{p \in N_h} \exp(-\|\mathbf{x}_{SP_p} - \mathbf{x}_{SP_h}\|^2 / 2\sigma_p^2)}$,

其中, $\bar{G}_{i,h}$ 表示SP_{i,h}中的所有像素点在RGB颜色空间的G分量的颜色值的均值, $\bar{G}_{i,p}$ 表示R_i中的第p个区域SP_{i,p}中的所有像素点在RGB颜色空间的G分量的颜色值的均值;

[0023] ①-3f、计算SP_{i,h}中的所有像素点在RGB颜色空间的B分量的颜色值与SP_{i,h}的相邻

区域中的所有像素点在RGB颜色空间的B分量的颜色值的距离 $f_{i,h}^6$, $f_{i,h}^6 = \frac{\sum_{p \in \mathbb{N}_h} \exp\left(-\|\mathbf{x}_{SP_p} - \mathbf{x}_{SP_h}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |B_{i,p} - B_{i,h}|^2}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_p} - \mathbf{x}_{SP_h}\|^2 / 2\sigma_p^2\right)\right)}$

其中, $\bar{B}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的B分量的颜色值的均值, $\bar{B}_{i,p}$ 表示 R_i 中的第 p 个区域 $SP_{i,p}$ 中的所有像素点在RGB颜色空间的B分量的颜色值的均值;

[0024] ①-3g、将 $f_{i,h}^1$ 、 $f_{i,h}^2$ 、 $f_{i,h}^3$ 、 $f_{i,h}^4$ 、 $f_{i,h}^5$ 和 $f_{i,h}^6$ 按顺序进行排列, 构成 $SP_{i,h}$ 的对比度特征矢量 $\mathbf{X}_{i,h}^d$ 。

[0025] 所述的步骤①-4中的 $\mathbf{X}_{i,h}^d$ 的获取过程为:

[0026] ①-4a、计算 $SP_{i,h}$ 中的所有像素点的视差幅值的均值 $\bar{d}_{i,h}$;

[0027] ①-4b、计算 $SP_{i,h}$ 中的所有像素点的视差幅值与 R_i 中的背景区域中的所有像素点的视差幅值的距离 $g_{i,h}^1$, $g_{i,h}^1 = \frac{\sum_{q \in \mathbb{Q}} |\bar{d}_{i,h} - \bar{d}_{i,q}|}{Q}$, 其中, \mathbb{Q} 表示 R_i 中的所有背景区域的序号的集合,

合, $\bar{d}_{i,q}$ 表示 R_i 中的第 q 个区域 $SP_{i,q}$ 中的所有像素点的视差幅值的均值, Q 表示 R_i 中的背景区域的总个数, 符号“| |”为取绝对值符号;

[0028] ①-4c、计算 $SP_{i,h}$ 中的所有像素点的视差幅值与 $SP_{i,h}$ 的相邻区域中的所有像素点

的视差幅值的距离 $g_{i,h}^2$, $g_{i,h}^2 = \frac{\sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |\bar{d}_{i,h} - \bar{d}_{i,p}|^2 \right)}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}$, 其中, \mathbb{N}_h

表示 $SP_{i,h}$ 的所有相邻区域的序号的集合, $\exp()$ 表示以自然基数 e 为底的指数函数, \mathbf{x}_{SP_h} 表示 $SP_{i,h}$ 中的中心像素点的坐标位置, \mathbf{x}_{SP_p} 表示 R_i 中的第 p 个区域 $SP_{i,p}$ 中的中心像素点的坐标位置, σ_p 表示高斯函数的标准差, $\bar{d}_{i,p}$ 表示 R_i 中的第 p 个区域 $SP_{i,p}$ 中的所有像素点的视差幅值的均值, P 表示 $SP_{i,h}$ 的相邻区域的总个数, 符号“| | |”为求欧式距离符号;

[0029] ①-4d、将 $\bar{d}_{i,h}$ 、 $g_{i,h}^1$ 和 $g_{i,h}^2$ 按顺序进行排列, 构成 $SP_{i,h}$ 的深度特征矢量 $\mathbf{X}_{i,h}^d$ 。

[0030] 所述的步骤①-7中将 \mathbf{S}_r^\pm 的第 m 个弱分类器的回归函数记为 $f_m(r)$, $f_m(r) = (\mathbf{w}_m)^T k_m(r) + b_m$, 其中, \mathbf{w}_m 为权重矢量, $(\mathbf{w}_m)^T$ 为 \mathbf{w}_m 的转置矢量, b_m 为偏置项, $k_m(r)$ 表示 $f_m(r)$ 的核函数。

[0031] 所述的步骤①-7中当取 $N_k = 3$ 时 $1 \leq m \leq 9$, 则 \mathbf{S}_r^\pm 的第 1 个弱分类器的回归函数的核函数为 $k_1(r)$, $\mathbf{k}_1(r) = \sum_{r'=1}^T \exp\left(-\gamma \times \|\mathbf{X}_r^c - \mathbf{X}_{r'}^c\|^2\right)$; \mathbf{S}_r^\pm 的第 2 个弱分类器的回归函数的核函数为 $k_2(r)$, $\mathbf{k}_2(r) = \sum_{r'=1}^T \exp\left(-\gamma \times \|\mathbf{X}_r^d - \mathbf{X}_{r'}^d\|^2\right)$; \mathbf{S}_r^\pm 的第 3 个弱分类器的回归函数的核函数为 $k_3(r)$, $\mathbf{k}_3(r) = \sum_{r'=1}^T \exp\left(-\gamma \times \|\mathbf{X}_r^t - \mathbf{X}_{r'}^t\|^2\right)$; \mathbf{S}_r^\pm 的第 4 个弱分类器的回归函数的核函数为 $k_4(r)$, $\mathbf{k}_4(r) = \sum_{r'=1}^T (\mathbf{X}_r^d)^T \mathbf{X}_{r'}^d$; \mathbf{S}_r^\pm 的第 5 个弱分类器的回归函数的核函数为 $k_5(r)$, $\mathbf{k}_5(r) = \sum_{r'=1}^T (\mathbf{X}_r^d)^T \mathbf{X}_{r'}^d$; \mathbf{S}_r^\pm

的第6个弱分类器的回归函数的核函数为 $k_6(r)$, $\mathbf{k}_6(r)=\sum_{r'=1}^T(\mathbf{X}_{r'})^T \mathbf{X}_{r'}^t$; \mathbf{S}_r^t 的第7个弱分类器的回归函数的核函数为 $k_7(r)$, $\mathbf{k}_7(r)=\sum_{r'=1}^T(\gamma \times (\mathbf{X}_{r'}^c)^T \mathbf{X}_{r'}^c + e)^d$; \mathbf{S}_r^t 的第8个弱分类器的回归函数的核函数为 $k_8(r)$, $\mathbf{k}_8(r)=\sum_{r'=1}^T(\gamma \times (\mathbf{X}_{r'}^d)^T \mathbf{X}_{r'}^d + e)^d$; \mathbf{S}_r^t 的第9个弱分类器的回归函数的核函数为 $k_9(r)$, $\mathbf{k}_9(r)=\sum_{r'=1}^T(\gamma \times (\mathbf{X}_{r'}^t)^T \mathbf{X}_{r'}^t + e)^d$; 其中, $1 \leq r' \leq T$, $\exp()$ 表示以自然基数e为底的指数函数, \mathbf{X}_r^c 、 \mathbf{X}_r^d 和 \mathbf{X}_r^t 对应表示 \mathbf{S}_r^t 中的对比度特征矢量、深度特征矢量和纹理特征矢量, \mathbf{X}_r^c 、 \mathbf{X}_r^d 和 \mathbf{X}_r^t 对应表示 $\{\mathbf{S}_r^t | 1 \leq r \leq T\}$ 中的第 r' 个样本 \mathbf{S}_r^t 中的对比度特征矢量、深度特征矢量和纹理特征矢量, $(\mathbf{X}_r^c)^T$ 为 \mathbf{X}_r^c 的转置矩阵, $(\mathbf{X}_r^d)^T$ 为 \mathbf{X}_r^d 的转置矩阵, $(\mathbf{X}_r^t)^T$ 为 \mathbf{X}_r^t 的转置矩阵, γ 、e和d均为核参数, 符号“|| |”为求欧式距离符号。

[0032] 所述的核参数 $\gamma=1/10$, $e=3$, $d=1$ 。

[0033] 所述的步骤①-7中将 \mathbf{w}_m^{opt} 和 b_m^{opt} 及 β_m^{opt} 组成一个组合, 记为 $(\mathbf{w}_m^{opt}, b_m^{opt}, \beta_m^{opt})$, $(\mathbf{w}_m^{opt}, b_m^{opt}, \beta_m^{opt}) = \arg \min_{(\mathbf{w}_m, b_m, \beta_m) \in \Psi} \sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$, 其中, $\arg \min_{(\mathbf{w}_m, b_m, \beta_m) \in \Psi} \sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$ 表示取使得 $\sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$ 的值最小的 \mathbf{w}_m 、 b_m 和 β_m 的值, \mathbf{w}_m 、 b_m 和 β_m 对应表示权重矢量、偏置项和权重系数, $(\mathbf{w}_m, b_m, \beta_m)$ 为 \mathbf{w}_m 、 b_m 和 β_m 组成的组合, Ψ 表示对 $\{\mathbf{S}_r^t | 1 \leq r \leq T\}$ 中的所有样本进行训练的所有权重矢量和偏置项及权重系数的组合的集合, $(\mathbf{w}_m)^T$ 为 \mathbf{w}_m 的转置矢量, L_r 表示 \mathbf{S}_r^t 中的标签值。

[0034] 所述的步骤②-2中当取 $N_k=3$ 时 $1 \leq m \leq 9$, 则 SP_h 对应的输入样本的第一个弱分类器的回归函数的核函数为 $k_1(h)$, $\mathbf{k}_1(h)=\sum_{h'=1}^{M'} \exp(-\gamma \times \|\mathbf{X}_h^c - \mathbf{X}_{h'}^c\|^2)$; SP_h 对应的输入样本的第2个弱分类器的回归函数的核函数为 $k_2(h)$, $\mathbf{k}_2(h)=\sum_{h'=1}^{M'} \exp(-\gamma \times \|\mathbf{X}_h^d - \mathbf{X}_{h'}^d\|^2)$; SP_h 对应的输入样本的第3个弱分类器的回归函数的核函数为 $k_3(h)$, $\mathbf{k}_3(h)=\sum_{h'=1}^{M'} \exp(-\gamma \times \|\mathbf{X}_h^t - \mathbf{X}_{h'}^t\|^2)$; SP_h 对应的输入样本的第4个弱分类器的回归函数的核函数为 $k_4(h)$, $\mathbf{k}_4(h)=\sum_{h'=1}^{M'} (\mathbf{X}_h^c)^T \mathbf{X}_{h'}^c$; SP_h 对应的输入样本的第5个弱分类器的回归函数的核函数为 $k_5(h)$, $\mathbf{k}_5(h)=\sum_{h'=1}^{M'} (\mathbf{X}_h^d)^T \mathbf{X}_{h'}^d$; SP_h 对应的输入样本的第6个弱分类器的回归函数的核函数为 $k_6(h)$, $\mathbf{k}_6(h)=\sum_{h'=1}^{M'} (\mathbf{X}_h^t)^T \mathbf{X}_{h'}^t$; SP_h 对应的输入样本的第7个弱分类器的回归函数的核函数为 $k_7(h)$, $\mathbf{k}_7(h)=\sum_{h'=1}^{M'} (\gamma \times (\mathbf{X}_h^c)^T \mathbf{X}_{h'}^c + e)^d$; SP_h 对应的输入样本的第8个弱分类器的回归函数的核函数为 $k_8(h)$, $\mathbf{k}_8(h)=\sum_{h'=1}^{M'} (\gamma \times (\mathbf{X}_h^d)^T \mathbf{X}_{h'}^d + e)^d$; SP_h 对应的输入样本的第9个弱分类器的回归函数的核函数为 $k_9(h)$, $\mathbf{k}_9(h)=\sum_{h'=1}^{M'} (\gamma \times (\mathbf{X}_h^t)^T \mathbf{X}_{h'}^t + e)^d$; 其中, $1 \leq h' \leq M'$, $\exp()$ 表示以自然基数e为底的指数函数, \mathbf{X}_h^c 、 \mathbf{X}_h^d 和 \mathbf{X}_h^t 对应表示 SP_h 对应

的输入样本中的对比度特征矢量、深度特征矢量和纹理特征矢量, \mathbf{X}_h^c 、 \mathbf{X}_h^d 和 \mathbf{X}_h^t 对应表示 R_{test} 中的第 h 个区域 SP_h 对应的输入样本中的对比度特征矢量、深度特征矢量和纹理特征矢量, $(\mathbf{X}_h^c)^T$ 为 \mathbf{X}_h^c 的转置矩阵, $(\mathbf{X}_h^d)^T$ 为 \mathbf{X}_h^d 的转置矩阵, $(\mathbf{X}_h^t)^T$ 为 \mathbf{X}_h^t 的转置矩阵, γ 、 e 和 d 均为核参数, 符号“|| |”为求欧式距离符号。

[0035] 所述的核参数 $\gamma = 1/10$, $e = 3$, $d = 1$ 。

[0036] 与现有技术相比, 本发明的优点在于:

[0037] 1) 本发明方法同时考虑了立体图像的右视点图像中的每个区域的对比度特征矢量、深度特征矢量和纹理特征矢量, 并分别构造基于不同核函数的弱分类器, 再通过 AdaBoosting 模型作为机器学习的方法, 构造使得经过训练得到的弱分类器的回归函数值与标签值之间的误差最小的强分类器, 所训练得到的强分类器能够很好地反映不同特征、不同核对显著的影响, 符合显著语义特征。

[0038] 2) 本发明方法通过 AdaBoosting 模型作为机器学习的方法, 构造使得经过训练得到的弱分类器的回归函数值与标签值之间的误差最小的强分类器, 然后利用已训练得到的强分类器来预测测试立体图像的右视点图像中的每个区域的三维视觉显著值, 从而得到测试立体图像的立体显著图, 这个过程有效地提高了三维视觉显著值的预测准确性和稳定性, 从而提高了测试立体图像的立体显著图的提取稳定性和提取准确性。

附图说明

- [0039] 图1为本发明方法的总体实现框图;
- [0040] 图2a为“Image1”的右视点图像;
- [0041] 图2b为“Image1”的右视点图像的真实眼动图;
- [0042] 图2c为“Image1”的立体显著图;
- [0043] 图3a为“Image2”的右视点图像;
- [0044] 图3b为“Image2”的右视点图像的真实眼动图;
- [0045] 图3c为“Image2”的立体显著图;
- [0046] 图4a为“Image3”的右视点图像;
- [0047] 图4b为“Image3”的右视点图像的真实眼动图;
- [0048] 图4c为“Image3”的立体显著图;
- [0049] 图5a为“Image4”的右视点图像;
- [0050] 图5b为“Image4”的右视点图像的真实眼动图;
- [0051] 图5c为“Image4”的立体显著图;
- [0052] 图6a为“Image5”的右视点图像;
- [0053] 图6b为“Image5”的右视点图像的真实眼动图;
- [0054] 图6c为“Image5”的立体显著图;
- [0055] 图7a为“Image6”的右视点图像;
- [0056] 图7b为“Image6”的右视点图像的真实眼动图;
- [0057] 图7c为“Image6”的立体显著图。

具体实施方式

[0058] 以下结合附图实施例对本发明作进一步详细描述。

[0059] 本发明提出的一种立体图像显著图提取方法,其总体实现框图如图1所示,其包括训练阶段和测试阶段两个过程,训练阶段过程的具体步骤如下:

[0060] ①-1、将选取的N幅各不相同的立体图像以及每幅立体图像的右视差图像和右视点图像的真实眼动图构成一个集合,记为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$,其中,N ≥ 1 , L_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的左视点图像, R_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的右视点图像, d_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的右视差图像, F_i 表示 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的第*i*幅立体图像的真实眼动图。

[0061] 在本实施例中,采用新加坡国立大学提供的三维人眼跟踪数据库(NUS 3D-Saliency database)构造训练立体图像集,该三维人眼跟踪数据库包含600幅立体图像以及对应的右视差图像,并给出了每幅立体图像的右视点图像的真实眼动图。

[0062] ①-2、采用现有的超像素分割技术将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像分割成M个互不重叠的区域,将 R_i 中的第*h*个区域记为 $SP_{i,h}$,可将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像重新表示为M个区域的集合,可将 R_i 重新表示的M个区域的集合记为 $\{SP_{i,h}\}$,其中,M ≥ 1 ,在本实施例中取M=400,1≤*h*≤M。

[0063] ①-3、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域的对比度特征矢量,将 $SP_{i,h}$ 的对比度特征矢量记为 $\mathbf{X}_{i,h}^c$, $\mathbf{X}_{i,h}^c = [f_{i,h}^1, f_{i,h}^2, f_{i,h}^3, f_{i,h}^4, f_{i,h}^5, f_{i,h}^6]$,其中, $\mathbf{X}_{i,h}^c$ 的维数为6,符号“[]”为矢量表示符号, $f_{i,h}^1$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的L分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的L分量的颜色值的距离, $f_{i,h}^2$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的a分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的a分量的颜色值的距离, $f_{i,h}^3$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的b分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的b分量的颜色值的距离, $f_{i,h}^4$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的R分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的R分量的颜色值的距离, $f_{i,h}^5$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的G分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的G分量的颜色值的距离, $f_{i,h}^6$ 表示 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的B分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的B分量的颜色值的距离, R_i 中的背景区域是指 R_i 中位于最左边、最右边、最上边、最下边的区域,即将落在 R_i 中的最左边、最右边、最上边和最下边的区域作为背景区域, $SP_{i,h}$ 的相邻区域是指 R_i 中与 $SP_{i,h}$ 左相邻、右相邻、上相邻、下相邻的区域。

[0064] 在此具体实施例中,步骤①-3中的 $\mathbf{X}_{i,h}^c$ 的获取过程为:

[0065] ①-3a、计算 $SP_{i,h}$ 中的所有像素点在CIELAB颜色空间的L分量的颜色值与 R_i 中的背景区域中的所有像素点在CIELAB颜色空间的L分量的颜色值的距离 $f_{i,h}^1$,

$$f_{i,h}^1 = \frac{\sum_{q \in Q} |\bar{L}_{i,h} - \bar{L}_{i,q}|}{Q},$$

其中,Q表示 R_i 中的所有背景区域的序号的集合, $\bar{L}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在CIELAB颜

色空间的L分量的颜色值的均值, $\bar{L}_{i,q}$ 表示 R_i 中的第 q 个区域 $SP_{i,q}$ ($SP_{i,q}$ 为背景区域) 中的所有像素点在 CIELAB 颜色空间的 L 分量的颜色值的均值, Q 表示 R_i 中的背景区域的总个数, 符号“||”为取绝对值符号。

[0066] ①-3b、计算 $SP_{i,h}$ 中的所有像素点在 CIELAB 颜色空间的 a 分量的颜色值与 R_i 中的背

$$\text{景区域中的所有像素点在 CIELAB 颜色空间的 a 分量的颜色值的距离 } f_{i,h}^2, f_{i,h}^2 = \frac{\sum_{q \in Q} |\bar{a}_{i,h} - \bar{a}_{i,q}|}{Q},$$

其中, $\bar{a}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在 CIELAB 颜色空间的 a 分量的颜色值的均值, $\bar{a}_{i,q}$ 表示 R_i 中的第 q 个区域 $SP_{i,q}$ ($SP_{i,q}$ 为背景区域) 中的所有像素点在 CIELAB 颜色空间的 a 分量的颜色值的均值。

[0067] ①-3c、计算 $SP_{i,h}$ 中的所有像素点在 CIELAB 颜色空间的 b 分量的颜色值与 R_i 中的背

$$\text{景区域中的所有像素点在 CIELAB 颜色空间的 b 分量的颜色值的距离 } f_{i,h}^3, f_{i,h}^3 = \frac{\sum_{q \in Q} |\bar{b}_{i,h} - \bar{b}_{i,q}|}{Q},$$

其中, $\bar{b}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在 CIELAB 颜色空间的 b 分量的颜色值的均值, $\bar{b}_{i,q}$ 表示 R_i 中的第 q 个区域 $SP_{i,q}$ ($SP_{i,q}$ 为背景区域) 中的所有像素点在 CIELAB 颜色空间的 b 分量的颜色值的均值。

[0068] ①-3d、计算 $SP_{i,h}$ 中的所有像素点在 RGB 颜色空间的 R 分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在 RGB 颜色空间的 R 分量的颜色值的距离 $f_{i,h}^4$,

$$f_{i,h}^4 = \frac{\sum_{p \in N_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in N_h} |\bar{R}_{i,h} - \bar{R}_{i,p}|^2 \right)}{P \times \sum_{p \in N_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}, \text{ 其中, } N_h \text{ 表示 } SP_{i,h} \text{ 的所有相邻区}$$

域的序号的集合, $\exp()$ 表示以自然基数 e 为底的指数函数, \mathbf{x}_{SP_h} 表示 $SP_{i,h}$ 中的中心像素点的坐标位置, \mathbf{x}_{SP_p} 表示 R_i 中的第 p 个区域 $SP_{i,p}$ ($SP_{i,p}$ 为 $SP_{i,h}$ 的相邻区域) 中的中心像素点的坐标位置, σ_p 表示高斯函数的标准差, 在本实施例中取 $\sigma_p = 0.4$, $\bar{R}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点在 RGB 颜色空间的 R 分量的颜色值的均值, $\bar{R}_{i,p}$ 表示 R_i 中的第 p 个区域 $SP_{i,p}$ 中的所有像素点在 RGB 颜色空间的 R 分量的颜色值的均值, P 表示 $SP_{i,h}$ 的相邻区域的总个数, 在本实施例中取 $P = 20$, 符号“|| |”为求欧式距离符号。

[0069] ①-3e、计算 $SP_{i,h}$ 中的所有像素点在 RGB 颜色空间的 G 分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在 RGB 颜色空间的 G 分量的颜色值的距离 $f_{i,h}^5$,

$$f_{i,h}^5 = \frac{\sum_{p \in N_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in N_h} |\bar{G}_{i,h} - \bar{G}_{i,p}|^2 \right)}{P \times \sum_{p \in N_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}, \text{ 其中, } \bar{G}_{i,h} \text{ 表示 } SP_{i,h} \text{ 中的所有像}$$

素点在 RGB 颜色空间的 G 分量的颜色值的均值, $\bar{G}_{i,p}$ 表示 R_i 中的第 p 个区域 $SP_{i,p}$ 中的所有像素

点在RGB颜色空间的G分量的颜色值的均值。

[0070] ①-3f、计算 $SP_{i,h}$ 中的所有像素点在RGB颜色空间的B分量的颜色值与 $SP_{i,h}$ 的相邻区域中的所有像素点在RGB颜色空间的B分量的颜色值的距离 $f_{i,h}^6$ ，

$$f_{i,h}^6 = \frac{\sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |\bar{B}_{i,h} - \bar{B}_{i,p}|^2 \right)}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}, \text{其中}, \bar{B}_{i,h} \text{表示} SP_{i,h} \text{中的所有像素}$$

点在RGB颜色空间的B分量的颜色值的均值， $\bar{B}_{i,p}$ 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的所有像素点在RGB颜色空间的B分量的颜色值的均值。

[0071] ①-3g、将 $f_{i,h}^1$ 、 $f_{i,h}^2$ 、 $f_{i,h}^3$ 、 $f_{i,h}^4$ 、 $f_{i,h}^5$ 和 $f_{i,h}^6$ 按顺序进行排列，构成 $SP_{i,h}$ 的对比度特征矢量 $\mathbf{X}_{i,h}^c$ 。

[0072] ①-4、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域的深度特征矢量，将 $SP_{i,h}$ 的深度特征矢量记为 $\mathbf{X}_{i,h}^d$ ， $\mathbf{X}_{i,h}^d = [\bar{d}_{i,h}, g_{i,h}^1, g_{i,h}^2]$ ，其中， $\mathbf{X}_{i,h}^d$ 的维数为3，符号“[]”为矢量表示符号， $\bar{d}_{i,h}$ 表示 $SP_{i,h}$ 中的所有像素点的视差幅值的均值， $g_{i,h}^1$ 表示 $SP_{i,h}$ 中的所有像素点的视差幅值与 R_i 中的背景区域中的所有像素点的视差幅值的距离， $g_{i,h}^2$ 表示 $SP_{i,h}$ 中的所有像素点的视差幅值与 $SP_{i,h}$ 的相邻区域中的所有像素点的视差幅值的距离。

[0073] 在此具体实施例中，步骤①-4中的 $\mathbf{X}_{i,h}^d$ 的获取过程为：

[0074] ①-4a、计算 $SP_{i,h}$ 中的所有像素点的视差幅值的均值 $\bar{d}_{i,h}$ 。

[0075] ①-4b、计算 $SP_{i,h}$ 中的所有像素点的视差幅值与 R_i 中的背景区域中的所有像素点

的视差幅值的距离 $g_{i,h}^1$ ， $g_{i,h}^1 = \frac{\sum_{q \in \mathbb{Q}} |\bar{d}_{i,h} - \bar{d}_{i,q}|}{Q}$ ，其中， \mathbb{Q} 表示 R_i 中的所有背景区域的序号的集合， $\bar{d}_{i,q}$ 表示 R_i 中的第q个区域 $SP_{i,q}$ （ $SP_{i,q}$ 为背景区域）中的所有像素点的视差幅值的均值，Q表示 R_i 中的背景区域的总个数，符号“||”为取绝对值符号。

[0076] ①-4c、计算 $SP_{i,h}$ 中的所有像素点的视差幅值与 $SP_{i,h}$ 的相邻区域中的所有像素点

的视差幅值的距离 $g_{i,h}^2$ ， $g_{i,h}^2 = \frac{\sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h} |\bar{d}_{i,h} - \bar{d}_{i,p}|^2 \right)}{P \times \sum_{p \in \mathbb{N}_h} \left(\exp\left(-\|\mathbf{x}_{SP_h} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}$ ，其中， \mathbb{N}_h

表示 $SP_{i,h}$ 的所有相邻区域的序号的集合， $\exp()$ 表示以自然基数e为底的指数函数， \mathbf{x}_{SP_h} 表示 $SP_{i,h}$ 中的中心像素点的坐标位置， \mathbf{x}_{SP_p} 表示 R_i 中的第p个区域 $SP_{i,p}$ （ $SP_{i,p}$ 为 $SP_{i,h}$ 的相邻区域）中的中心像素点的坐标位置， σ_p 表示高斯函数的标准差，在本实施例中取 $\sigma_p = 0.4$ ， $\bar{d}_{i,p}$ 表示 R_i 中的第p个区域 $SP_{i,p}$ 中的所有像素点的视差幅值的均值，P表示 $SP_{i,h}$ 的相邻区域的总

个数,符号“|| |”为求欧式距离符号。

[0077] ①-4d、将 $\bar{d}_{i,h}$ 、 $g_{i,h}^1$ 和 $g_{i,h}^2$ 按顺序进行排列,构成 $S_{i,h}$ 的深度特征矢量 $\mathbf{X}_{i,h}^d$ 。

[0078] ①-5、计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的每个区域中的所有像素点的LBP特征统计直方图,将以矢量形式表示的LBP特征统计直方图作为对应区域的纹理特征矢量,将 $S_{i,h}$ 的纹理特征矢量记为 $\mathbf{X}_{i,h}^t$,其中, $\mathbf{X}_{i,h}^t$ 的维数为59。

[0079] ①-6、按 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像中的M个互不重叠的区域,将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像的真实眼动图对应分割成M个互不重叠的区域,即 R_i 中的每个区域与 F_i 中的每个区域一一对应;然后计算 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的每幅立体图像的右视点图像的真实眼动图中的每个区域的平均眼动值;接着按平均眼动值的大小对 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有N幅立体图像的右视点图像的真实眼动图中的M×N个区域进行排序;之后从排序后的M×N个区域中取平均眼动值最高的20%区域,并将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有立体图像的右视点图像中与所取的每个区域对应的区域作为正样本区域,同时从排序后的M×N个区域中取平均眼动值最低的40%区域,并将 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 中的所有立体图像的右视点图像中与所取的每个区域对应的区域作为负样本区域;再将所有正样本区域的特征矢量集的集合作为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 的正样本集合,记为 $\{\mathbf{S}_j^+ | 1 \leq j \leq T_1\}$,并将所有负样本区域的特征矢量集的集合作为 $\{L_i, R_i, d_i, F_i | 1 \leq i \leq N\}$ 的负样本集合,记为 $\{\mathbf{S}_k^- | 1 \leq k \leq T_2\}$;最后将 $\{\mathbf{S}_j^+ | 1 \leq j \leq T_1\}$ 和 $\{\mathbf{S}_k^- | 1 \leq k \leq T_2\}$ 构成初始的样本训练集,记为 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$, $\{\mathbf{S}_r^\pm\} = \{\mathbf{S}_j^+, \mathbf{S}_k^-\}$;其中, \mathbf{S}_j^+ 表示第j个正样本区域的特征矢量集, $\mathbf{S}_j^+ = \{\mathbf{X}_j^c, \mathbf{X}_j^d, \mathbf{X}_j^t, L_j\}$, \mathbf{X}_j^c 表示第j个正样本区域的对比度特征矢量, \mathbf{X}_j^d 表示第j个正样本区域的深度特征矢量, \mathbf{X}_j^t 表示第j个正样本区域的纹理特征矢量, L_j 表示第j个正样本区域的标签值, $L_j = +1$, T_1 表示正样本区域的总个数, $T_1 = 0.2 \times M \times N$, \mathbf{S}_k^- 表示第k个负样本区域的特征矢量集, $\mathbf{S}_k^- = \{\mathbf{X}_k^{c'}, \mathbf{X}_k^{d'}, \mathbf{X}_k^{t'}, L_k'\}$, $\mathbf{X}_k^{c'}$ 表示第k个负样本区域的对比度特征矢量, $\mathbf{X}_k^{d'}$ 表示第k个负样本区域的深度特征矢量, $\mathbf{X}_k^{t'}$ 表示第k个负样本区域的纹理特征矢量, L_k' 表示第k个负样本区域的标签值, $L_k' = -1$, T_2 表示负样本区域的总个数, $T_2 = 0.4 \times M \times N$, \mathbf{S}_r^\pm 表示 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的第r个样本, \mathbf{S}_r^\pm 为正样本或为负样本,若 \mathbf{S}_r^\pm 中的标签值为+1,则 \mathbf{S}_r^\pm 为正样本,若 \mathbf{S}_r^\pm 中的标签值为-1,则 \mathbf{S}_r^\pm 为负样本, $T = 0.6 \times M \times N$, $T = T_1 + T_2$ 。

[0080] ①-7、采用现有的AdaBoosting模型作为机器学习的方法,对 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的所有正样本和所有负样本进行训练,使得经过训练得到的弱分类器的回归函数值与标签值之间的误差最小,得到 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的每个样本的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数, $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的所有样本相对应的弱分类器的回归函数的最优的权重矢量和最优的偏置项及权重系数相同,即 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的所有样本各自的第m个弱分类器的回归函数的最优的权重矢量相同、最优的偏置项相同及权重系数

相同,将 $\{\mathbf{S}_r^{\pm} | 1 \leq r \leq T\}$ 中的任意一个样本的第m个弱分类器的回归函数的最优的权重矢量和最优的偏置项及权重系数对应记为 \mathbf{w}_m^{opt} 和 b_m^{opt} 及 β_m^{opt} ;然后根据 $\{\mathbf{S}_r^{\pm} | 1 \leq r \leq T\}$ 中的任意一个样本的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数,构造一个强分类器,将根据 \mathbf{S}_r^{\pm} 的所有弱分类器各自的回归函数的最优的权重矢量和最优的偏置项及权重系数构造的强分类器记为 $\Phi(r)$, $\phi(r) = \sum_{m=1}^L \beta_m^{opt} ((\mathbf{w}_m^{opt})^T \mathbf{k}_m(r) + b_m^{opt})$;其中,1≤m≤L,L表示 $\{\mathbf{S}_r^{\pm} | 1 \leq r \leq T\}$ 中的任意一个样本的弱分类器的总个数,L=N_f×N_k,N_f表示 $\{\mathbf{S}_r^{\pm} | 1 \leq r \leq T\}$ 中的任意一个样本中的特征矢量的总个数,在本实施例中 $\{\mathbf{S}_r^{\pm} | 1 \leq r \leq T\}$ 中的任意一个样本中包含对比度特征矢量、深度特征矢量和纹理特征矢量,即N_f=3,N_k表示 $\{\mathbf{S}_r^{\pm} | 1 \leq r \leq T\}$ 中的任意一个样本的任意一个弱分类器的回归函数的核的总个数,N_k≥2,在本实施例中取N_k=3, $(\mathbf{w}_m^{opt})^T$ 为 \mathbf{w}_m^{opt} 的转置矢量,k_m(r)表示 \mathbf{S}_r^{\pm} 的第m个弱分类器的回归函数的核函数。

[0081] 在此具体实施例中,步骤①-7中将 \mathbf{S}_r^{\pm} 的第m个弱分类器的回归函数记为f_m(r), $f_m(r) = (\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m$,其中, \mathbf{w}_m 为权重矢量, $(\mathbf{w}_m)^T$ 为 \mathbf{w}_m 的转置矢量, b_m 为偏置项, $\mathbf{k}_m(r)$ 表示 $f_m(r)$ 的核函数。

[0082] 在此具体实施例中,步骤①-7中当取N_k=3时1≤m≤9,则 \mathbf{S}_r^{\pm} 的第1个弱分类器的回归函数的核函数为k₁(r), $\mathbf{k}_1(r) = \sum_{r'=1}^T \exp(-\gamma \times \|\mathbf{X}_{r'}^c - \mathbf{X}_{r'}^e\|^2)$; \mathbf{S}_r^{\pm} 的第2个弱分类器的回归函数的核函数为k₂(r), $\mathbf{k}_2(r) = \sum_{r'=1}^T \exp(-\gamma \times \|\mathbf{X}_{r'}^d - \mathbf{X}_{r'}^e\|^2)$; \mathbf{S}_r^{\pm} 的第3个弱分类器的回归函数的核函数为k₃(r), $\mathbf{k}_3(r) = \sum_{r'=1}^T \exp(-\gamma \times \|\mathbf{X}_{r'}^e - \mathbf{X}_{r'}^t\|^2)$; \mathbf{S}_r^{\pm} 的第4个弱分类器的回归函数的核函数为k₄(r), $\mathbf{k}_4(r) = \sum_{r'=1}^T (\mathbf{X}_{r'}^e)^T \mathbf{X}_{r'}^c$; \mathbf{S}_r^{\pm} 的第5个弱分类器的回归函数的核函数为k₅(r), $\mathbf{k}_5(r) = \sum_{r'=1}^T (\mathbf{X}_{r'}^d)^T \mathbf{X}_{r'}^d$; \mathbf{S}_r^{\pm} 的第6个弱分类器的回归函数的核函数为k₆(r), $\mathbf{k}_6(r) = \sum_{r'=1}^T (\mathbf{X}_{r'}^t)^T \mathbf{X}_{r'}^t$; \mathbf{S}_r^{\pm} 的第7个弱分类器的回归函数的核函数为k₇(r), $\mathbf{k}_7(r) = \sum_{r'=1}^T (\gamma \times (\mathbf{X}_{r'}^e)^T \mathbf{X}_{r'}^e + e)^d$; \mathbf{S}_r^{\pm} 的第8个弱分类器的回归函数的核函数为k₈(r), $\mathbf{k}_8(r) = \sum_{r'=1}^T (\gamma \times (\mathbf{X}_{r'}^d)^T \mathbf{X}_{r'}^d + e)^d$; \mathbf{S}_r^{\pm} 的第9个弱分类器的回归函数的核函数为k₉(r), $\mathbf{k}_9(r) = \sum_{r'=1}^T (\gamma \times (\mathbf{X}_{r'}^t)^T \mathbf{X}_{r'}^t + e)^d$;其中,1≤r'≤T,exp()表示以自然基数e为底的指数函数, $\mathbf{X}_{r'}^c$ 、 $\mathbf{X}_{r'}^d$ 和 $\mathbf{X}_{r'}^t$ 对应表示 \mathbf{S}_r^{\pm} 中的对比度特征矢量、深度特征矢量和纹理特征矢量, $\mathbf{X}_{r'}^c$ 、 $\mathbf{X}_{r'}^d$ 和 $\mathbf{X}_{r'}^t$ 对应表示 $\{\mathbf{S}_r^{\pm} | 1 \leq r \leq T\}$ 中的第r'个样本 $\mathbf{S}_{r'}^{\pm}$ 中的对比度特征矢量、深度特征矢量和纹理特征矢量, $(\mathbf{X}_r^c)^T$ 为 \mathbf{X}_r^c 的转置矩阵, $(\mathbf{X}_r^d)^T$ 为 \mathbf{X}_r^d 的转置矩阵, $(\mathbf{X}_r^t)^T$ 为 \mathbf{X}_r^t 的转置矩阵,γ,e和d均为核参数,在本实施例中取γ=1/10,e=3,d=1,符号“|||”为求欧式距离符号。

[0083] 在此具体实施例中,步骤①-7中将 \mathbf{w}_m^{opt} 和 b_m^{opt} 及 β_m^{opt} 组成一个组合,记为 $(\mathbf{w}_m^{opt}, b_m^{opt}, \beta_m^{opt})$, $(\mathbf{w}_m^{opt}, b_m^{opt}, \beta_m^{opt}) = \arg \min_{(\mathbf{w}_m, b_m, \beta_m) \in \Psi} \sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$,其中, $\arg \min_{(\mathbf{w}_m, b_m, \beta_m) \in \Psi} \sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$

表示取使得 $\sum_{r=1}^T \left(\sum_{m=1}^L \beta_m ((\mathbf{w}_m)^T \mathbf{k}_m(r) + b_m) - L_r \right)^2$ 的值最小的 w_m, b_m 和 β_m 的值， w_m, b_m 和 β_m 对应表示权重矢量、偏置项和权重系数， (w_m, b_m, β_m) 为 w_m, b_m 和 β_m 组成的组合， Ψ 表示对 $\{\mathbf{S}_r^\pm | 1 \leq r \leq T\}$ 中的所有样本进行训练的所有权重矢量和偏置项及权重系数的组合的集合， $(\mathbf{w}_m)^T$ 为 w_m 的转置矢量， L_r 表示 \mathbf{S}_r^\pm 中的标签值。

[0084] 测试阶段过程的具体步骤如下：

[0085] ②-1、对于任意一幅测试立体图像 S_{test} ，将 S_{test} 的左视点图像、右视点图像、右视差图像对应记为 $L_{test}, R_{test}, d_{test}$ ；然后采用现有的超像素分割技术将 R_{test} 分割成 M' 个互不重叠的区域，将 R_{test} 中的第 h 个区域记为 SP_h' ，其中， $M' \geq 1$ ，在本实施例中取 $M' = 400, 1 \leq h \leq M'$ 。

[0086] ②-2、按照步骤①-3至步骤①-5的过程，以相同的操作方式获取 R_{test} 中的每个区域的对比度特征矢量、深度特征矢量和纹理特征矢量；然后将 R_{test} 中的每个区域的对比度特征矢量、深度特征矢量和纹理特征矢量构成的集合作为输入样本；再计算 R_{test} 中的每个区域对应的输入样本的每个弱分类器的回归函数的核函数，将 SP_h' 对应的输入样本的第 m 个弱分类器的回归函数的核函数记为 $k_m(h)$ 。

[0087] 在此，如 SP_h' 的对比度特征矢量的获取过程为：

[0088] A1、计算 SP_h' 中的所有像素点在CIELAB颜色空间的L分量的颜色值与 R_{test} 中的背景

$$\text{区域中的所有像素点在CIELAB颜色空间的L分量的颜色值的距离 } f_h^1, f_h^1 = \frac{\sum_{q \in Q'} |\bar{L}_h - \bar{L}_q|}{Q'},$$

其中， Q' 表示 R_{test} 中的所有背景区域的序号的集合， \bar{L}_h 表示 SP_h' 中的所有像素点在CIELAB颜色空间的L分量的颜色值的均值， \bar{L}_q 表示 R_{test} 中的第 q 个区域 SP_q' 中的所有像素点在CIELAB颜色空间的L分量的颜色值的均值， Q' 表示 R_{test} 中的背景区域的总个数，符号“| |”为取绝对值符号。

[0089] B1、计算 SP_h' 中的所有像素点在CIELAB颜色空间的a分量的颜色值与 R_{test} 中的背景

$$\text{区域中的所有像素点在CIELAB颜色空间的a分量的颜色值的距离 } f_h^2, f_h^2 = \frac{\sum_{q \in Q'} |\bar{a}_h - \bar{a}_q|}{Q'},$$

其中， \bar{a}_h 表示 SP_h' 中的所有像素点在CIELAB颜色空间的a分量的颜色值的均值， \bar{a}_q 表示 R_{test} 中的第 q 个区域 SP_q' 中的所有像素点在CIELAB颜色空间的a分量的颜色值的均值。

[0090] C1、计算 SP_h' 中的所有像素点在CIELAB颜色空间的b分量的颜色值与 R_{test} 中的背景

$$\text{区域中的所有像素点在CIELAB颜色空间的b分量的颜色值的距离 } f_h^3, f_h^3 = \frac{\sum_{q \in Q'} |\bar{b}_h - \bar{b}_q|}{Q'},$$

其中， \bar{b}_h 表示 SP_h' 中的所有像素点在CIELAB颜色空间的b分量的颜色值的均值， \bar{b}_q 表示 R_{test} 中的第 q 个区域 SP_q' 中的所有像素点在CIELAB颜色空间的b分量的颜色值的均值。

[0091] D1、计算 SP_h' 中的所有像素点在RGB颜色空间的R分量的颜色值与 SP_h' 的相

邻区域中的所有像素点在RGB颜色空间的R分量的颜色值的距离 f_h^{4+} ，

$$f_h^{4+} = \frac{\sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p'}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h'} |\bar{R}_{h'} - \bar{R}_p'|^2 \right)}{P' \times \sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p'}\|^2 / 2\sigma_p^2\right) \right)},$$

其中， \mathbb{N}_h' 表示 SP_h' 的所有相邻区域的序号的集合， $\exp()$ 表示以自然基数e为底的指数函数， $\mathbf{x}_{SP_h'}$ 表示 SP_h' 中的中心像素点的坐标位置， $\mathbf{x}_{SP_p'}$ 表示 R_{test} 中的第p个区域 SP_p' 中的中心像素点的坐标位置， σ_p 表示高斯函数的标准差，在本实施例中取 $\sigma_p = 0.4$ ， $\bar{R}_{h'}$ 表示 SP_h' 中的所有像素点在RGB颜色空间的R分量的颜色值的均值， \bar{R}_p' 表示 R_{test} 中的第p个区域 SP_p' 中的所有像素点在RGB颜色空间的R分量的颜色值的均值， P' 表示 SP_h' 的相邻区域的总个数，在本实施例中取 $P' = 20$ ，符号“|||”为求欧式距离符号。

[0092] E1、计算 SP_h' 中的所有像素点在RGB颜色空间的G分量的颜色值与 SP_h' 的相邻区域中的所有像素点在RGB颜色空间的G分量的颜色值的距离 f_h^{5+} ，

$$f_h^{5+} = \frac{\sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p'}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h'} |\bar{G}_{h'} - \bar{G}_p'|^2 \right)}{P' \times \sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p'}\|^2 / 2\sigma_p^2\right) \right)}$$

其中， $\bar{G}_{h'}$ 表示 SP_h' 中的所有像素点在RGB颜色空间的G分量的颜色值的均值， \bar{G}_p' 表示 R_{test} 中的第p个区域 SP_p' 中的所有像素点在RGB颜色空间的G分量的颜色值的均值。

[0093] F1、计算 SP_h' 中的所有像素点在RGB颜色空间的B分量的颜色值与 SP_h' 的相邻区域中的所有像素点在RGB颜色空间的B分量的颜色值的距离 f_h^{6+} ，

$$f_h^{6+} = \frac{\sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p'}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h'} |\bar{B}_{h'} - \bar{B}_p'|^2 \right)}{P' \times \sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p'}\|^2 / 2\sigma_p^2\right) \right)}$$

其中， $\bar{B}_{h'}$ 表示 SP_h' 中的所有像素点在RGB颜色空间的B分量的颜色值的均值， \bar{B}_p' 表示 R_{test} 中的第p个区域 SP_p' 中的所有像素点在RGB颜色空间的B分量的颜色值的均值。

[0094] G1、将 f_h^{1+} 、 f_h^{2+} 、 f_h^{3+} 、 f_h^{4+} 、 f_h^{5+} 和 f_h^{6+} 按顺序进行排列，构成 SP_h' 的对比度特征矢量。

[0095] 在此，如 SP_h' 的深度特征矢量的获取过程为：

[0096] A2、计算 SP_h' 中的所有像素点的视差幅值的均值 $\bar{d}_{h'}$ 。

[0097] B2、计算 SP_h' 中的所有像素点的视差幅值与 R_{test} 中的背景区域中的所有像素点的视差幅值的距离 g_h^{1+} ， $g_h^{1+} = \frac{\sum_{q \in \mathbb{Q}'} |\bar{d}_{h'} - \bar{d}_q'|}{Q'}$ ，其中， \mathbb{Q}' 表示 R_{test} 中的所有背景区域的序号的集

合, \bar{d}_q' 表示 R_{test} 中的第 q 个区域 SP_q' 中的所有像素点的视差幅值的均值, Q' 表示 R_{test} 中的背景区域的总个数, 符号“ $||$ ”为取绝对值符号。

[0098] C1、计算 SP_h' 中的所有像素点的视差幅值与 SP_h' 的相邻区域中的所有像素点的视

$$\text{差幅值的距离 } g_h^2, g_h^2 = \frac{\sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \times \sum_{p \in \mathbb{N}_h'} |\bar{d}_h' - \bar{d}_p'|^2 \right)}{P' \times \sum_{p \in \mathbb{N}_h'} \left(\exp\left(-\|\mathbf{x}_{SP_h'} - \mathbf{x}_{SP_p}\|^2 / 2\sigma_p^2\right) \right)}, \text{ 其中, } \mathbb{N}_h' \text{ 表示}$$

SP_h' 的所有相邻区域的序号的集合, $\exp()$ 表示以自然基数 e 为底的指数函数, $\mathbf{x}_{SP_h'}$ 表示 SP_h' 中的中心像素点的坐标位置, \mathbf{x}_{SP_p} 表示 R_{test} 中的第 p 个区域 SP_p' 中的中心像素点的坐标位置, σ_p 表示高斯函数的标准差, 在本实施例中取 $\sigma_p = 0.4$, \bar{d}_p' 表示 R_{test} 中的第 p 个区域 SP_p' 中的所有像素点的视差幅值的均值, P' 表示 SP_h' 的相邻区域的总个数, 符号“ $|||$ ”为求欧式距离符号。

[0099] D1、将 \bar{d}_h' 、 g_h^1 和 g_h^2 按顺序进行排列, 构成 SP_h' 的深度特征矢量。

[0100] 在此, 如 SP_h' 的纹理特征矢量的获取过程为: 计算 SP_h' 中的所有像素点的LBP特征统计直方图, 将以矢量形式表示的LBP特征统计直方图作为 SP_h' 的纹理特征矢量。

[0101] 在此具体实施例中, 步骤②-2中当取 $N_k=3$ 时 $1 \leq m \leq 9$, 则 SP_h' 对应的输入样本的第一个弱分类器的回归函数的核函数为 $k_1(h)$, $k_1(h) = \sum_{h'=1}^{M'} \exp(-\gamma \times \|\mathbf{X}_h^c - \mathbf{X}_{h'}^c\|^2)$; SP_h' 对应的输入样本的第2个弱分类器的回归函数的核函数为 $k_2(h)$, $k_2(h) = \sum_{h'=1}^{M'} \exp(-\gamma \times \|\mathbf{X}_h^d - \mathbf{X}_{h'}^d\|^2)$; SP_h' 对应的输入样本的第3个弱分类器的回归函数的核函数为 $k_3(h)$, $k_3(h) = \sum_{h'=1}^{M'} \exp(-\gamma \times \|\mathbf{X}_h^t - \mathbf{X}_{h'}^t\|^2)$; SP_h' 对应的输入样本的第4个弱分类器的回归函数的核函数为 $k_4(h)$, $k_4(h) = \sum_{h'=1}^{M'} (\mathbf{X}_h^c)^T \mathbf{X}_{h'}^c$; SP_h' 对应的输入样本的第5个弱分类器的回归函数的核函数为 $k_5(h)$, $k_5(h) = \sum_{h'=1}^{M'} (\mathbf{X}_h^d)^T \mathbf{X}_{h'}^d$; SP_h' 对应的输入样本的第6个弱分类器的回归函数的核函数为 $k_6(h)$, $k_6(h) = \sum_{h'=1}^{M'} (\mathbf{X}_h^t)^T \mathbf{X}_{h'}^t$; SP_h' 对应的输入样本的第7个弱分类器的回归函数的核函数为 $k_7(h)$, $k_7(h) = \sum_{h'=1}^{M'} (\gamma \times (\mathbf{X}_h^c)^T \mathbf{X}_{h'}^c + e)^d$; SP_h' 对应的输入样本的第8个弱分类器的回归函数的核函数为 $k_8(h)$, $k_8(h) = \sum_{h'=1}^{M'} (\gamma \times (\mathbf{X}_h^d)^T \mathbf{X}_{h'}^d + e)^d$; SP_h' 对应的输入样本的第9个弱分类器的回归函数的核函数为 $k_9(h)$, $k_9(h) = \sum_{h'=1}^{M'} (\gamma \times (\mathbf{X}_h^t)^T \mathbf{X}_{h'}^t + e)^d$; 其中, $1 \leq h' \leq M'$, $\exp()$ 表示以自然基数 e 为底的指数函数, \mathbf{X}_h^c 、 \mathbf{X}_h^d 和 \mathbf{X}_h^t 对应表示 SP_h' 对应的输入样本中的对比度特征矢量、深度特征矢量和纹理特征矢量, \mathbf{X}_h^c 、 \mathbf{X}_h^d 和 \mathbf{X}_h^t 对应表示 R_{test} 中的第 h' 个区域 $SP_{h'}$ 对应的输入样本中的对比度特征矢量、深度特征矢量和纹理特征矢量, $(\mathbf{X}_h^c)^T$ 为 \mathbf{X}_h^c 的转置矩阵, $(\mathbf{X}_h^d)^T$ 为 \mathbf{X}_h^d 的转置矩阵, $(\mathbf{X}_h^t)^T$ 为 \mathbf{X}_h^t 的转置矩阵, γ 、 e 和 d 均为核参数, 在本实施例中取 $\gamma = 1/10$, $e = 3$, $d = 1$, 符号“ $|||$ ”为求欧式距离符号。

[0102] ②-3、根据训练阶段构造的强分类器 $\Phi(r)$, 获取 R_{test} 中的每个区域的三维视觉显

著值,将 S_{Ph}' 的三维视觉显著值记为 $S_{3D,h}$, $S_{3D,h} = \phi(h)$, $\phi(h) = \sum_{m=1}^L \beta_m^{opt} ((\mathbf{w}_m^{opt})^T \mathbf{k}_m(h) + b_m^{opt})$;再将 R_{test} 中的每个区域的三维视觉显著值作为对应区域中的所有像素点的显著值,对于 S_{Ph}' ,将 S_{Ph}' 的三维视觉显著值作为 S_{Ph}' 中的所有像素点的显著值,从而得到 S_{test} 的立体显著图,记为 $\{S_{3D}(x', y')\}$,其中,(x' , y')表示 S_{test} 中的像素点的坐标位置, $1 \leq x' \leq W'$, $1 \leq y' \leq H'$, W' 和 H' 对应表示 S_{test} 的宽度和高度, S_{test} 的宽度与训练阶段选取的立体图像的宽度可以不一致, S_{test} 的高度与训练阶段选取的立体图像的高度可以不一致,即 S_{test} 与训练阶段选取的立体图像的尺寸大小可以一样也可以不一样,但要保证分割区域相同, $S_{3D}(x', y')$ 表示 $\{S_{3D}(x', y')\}$ 中坐标位置为(x' , y')的像素点的像素值, $S_{3D}(x', y')$ 亦表示 R_{test} 中坐标位置为(x' , y')的像素点的显著值。

[0103] 以下就利用本发明方法对法国南特大学提供的三维人眼跟踪数据库(3D eye-tracking database)中的Image1、Image2、Image3、Image4、Image5和Image6六幅立体图像的立体显著图进行提取。图2a给出了“Image1”的右视点图像、图2b给出了“Image1”的右视点图像的真实眼动图、图2c给出了“Image1”的立体显著图;图3a给出了“Image2”的右视点图像、图3b给出了“Image2”的右视点图像的真实眼动图、图3c给出了“Image2”的立体显著图;图4a给出了“Image3”的右视点图像、图4b给出了“Image3”的右视点图像的真实眼动图、图4c给出了“Image3”的立体显著图;图5a给出了“Image4”的右视点图像、图5b给出了“Image4”的右视点图像的真实眼动图、图5c给出了“Image4”的立体显著图;图6a给出了“Image5”的右视点图像、图6b给出了“Image5”的右视点图像的真实眼动图、图6c给出了“Image5”的立体显著图;图7a给出了“Image6”的右视点图像、图7b给出了“Image6”的右视点图像的真实眼动图、图7c给出了“Image6”的立体显著图。从图2a至图7c中可以看出,采用本发明方法得到的立体显著图由于考虑了对比度特征、深度特征和纹理特征,因此能够很好地符合显著语义的特征。

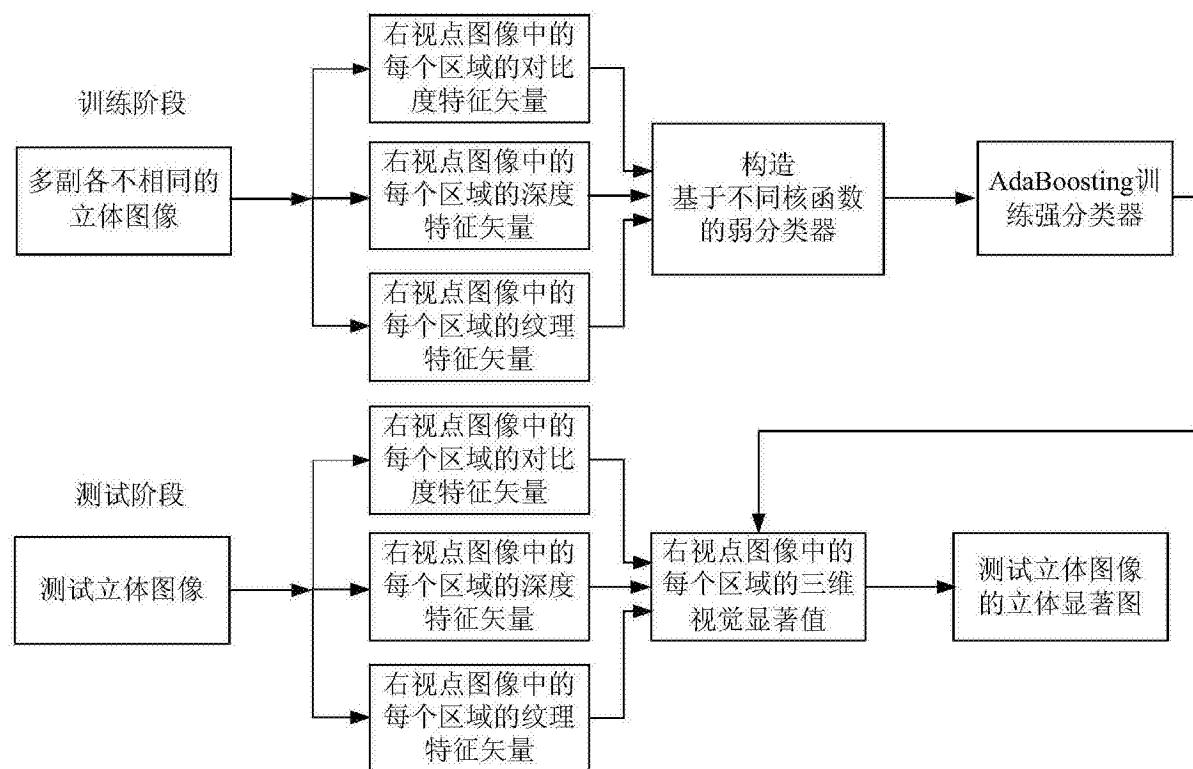


图1



图2a

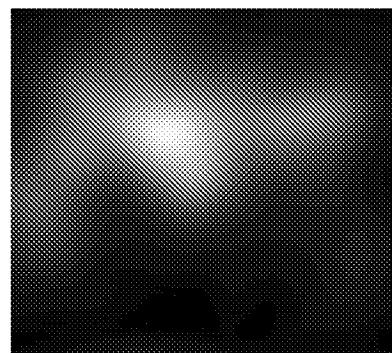


图2b



图2c

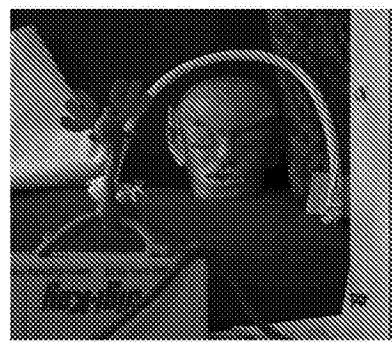


图3a

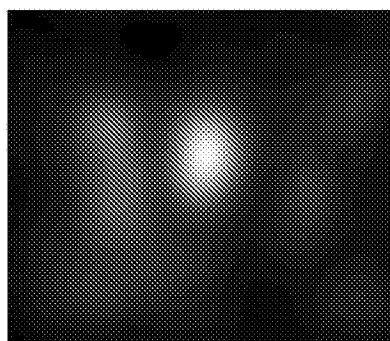


图3b

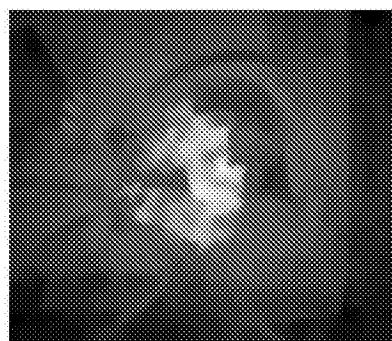


图3c



图4a

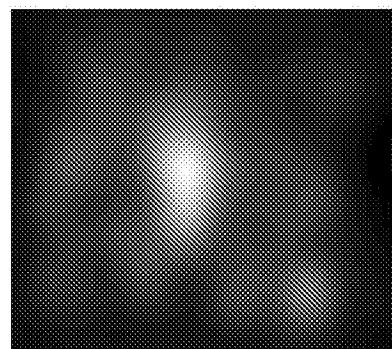


图4b

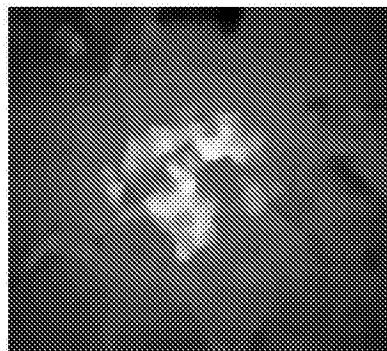


图4c

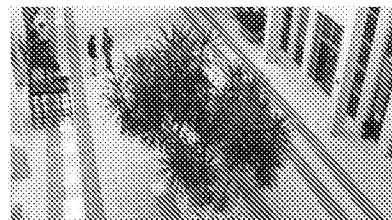


图5a

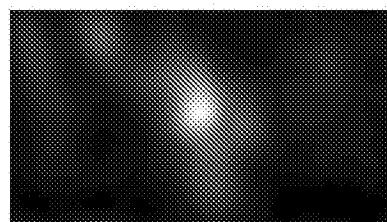


图5b

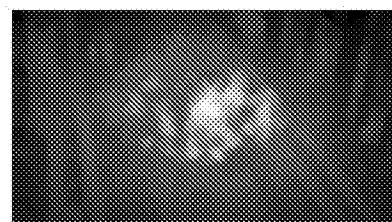


图5c

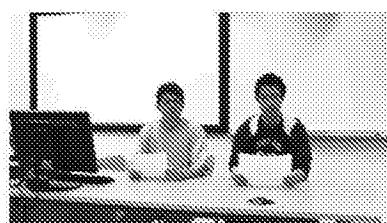


图6a

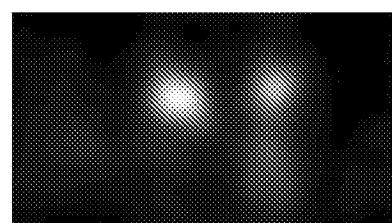


图6b

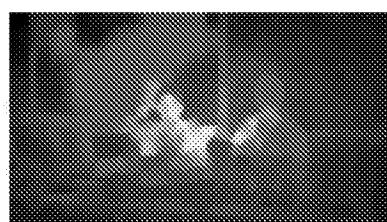


图6c

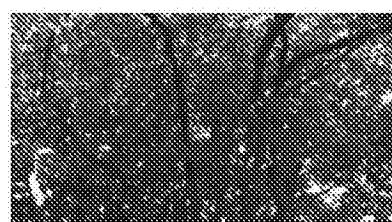


图7a

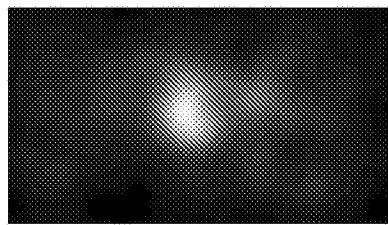


图7b

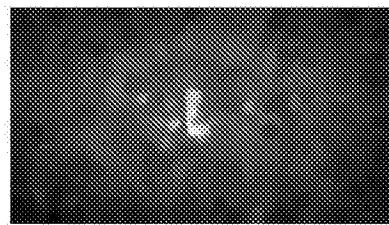


图7c