

基于 SVM 的医学图像分类器的设计

华 翔¹, 孙 蕾²

(1 西安工业大学 电子信息工程学院, 陕西 西安 710032; 2 西安电子科技大学, 陕西 西安 710071)

摘 要: 提出了一个基于支持向量机的医学图像分类器. 能提取形状和纹理特征作为分类算法的特征输入, 进行计算机辅助诊断. 提出了一种支持向量机新算法, 解决了当两类中的样本数量差别较大时, 支持向量机的分类能力将会下降的问题. 实验表明, 在小样本、两类样本数量严重不均衡的情况下, 该算法有着较强的分类能力, 可以极大地提高医学图像分类的效率和准确性.

关键词: 支持向量机; 医学图像分类; 特征提取; 图像分割; 梯度矢量流

中图分类号: TP393

文献标识码: A

文章编号: 1000-7180(2011)06-0171-05

Design of Medical Image Classifier Based on SVM

HU Xiang¹, SUN Lei²

(1 College of Technological Information Engineering, Xi'an Technological University, Xi'an 710032, China;

2 Xidian University, Xi'an 710071, China)

Abstract: A medical image classifier is proposed in this paper. Gradient Vector Flow (GVF) is used to segment tumor area, and the texture and shape features are the inputs to classifier. A novel SVM algorithm is presented in this paper, which solves the problem that SVM has a poor performance when the two-class problem samples are very unbalanced. The experimental results indicate that the modified algorithm has a strong capability of classification for the unbalanced samples, and the efficiency and accuracy in the medical images are greatly improved.

Key words: SVM; medical image classifier; feature extraction; image segmentation; Gradient Vector Flow

1 引言

由于医学图像的分类需要很高的精确度, 目前尚不能广泛用于医学图像的分类器. 本文采用基于均匀度的图像增强算法, 并用梯度矢量流算法对肿块进行分割, 提取了个基于形状和纹理的特征, 构建数据库, 采用改进的 SVM 算法进行肿瘤辅助诊断. 统计学习理论是一种专门的小样本统计理论, 同时也发展了一种有限样本情况下的模式识别方法, 即支持向量机(SVM)^[1]. 近年来, SVM 被广泛地应用于模式识别、信号处理与图像处理以及人工智能和控制领域^[2-3], 与此同时也出现了多种 SVM 的实现算法. 然而在实际运用中发现在样本量有限且两类样本数量悬殊的情况下, 算法的分类能力比较低. 就此问题, 本文提出了 DFP-SVM 算法来提高 SVM

对于不平衡数据的分类能力.

2 基于可变形模型的分割算法

传统的边缘提取方法大多可归结为图像高频成分的增强过程, 如 Sobel 算子, Priwitt 算子等, 微分运算也自然成为提取边缘信息的重要手段. 而基于主动轮廓模型的图像分割方法也给我们在乳腺肿瘤边界提取方面, 提供了另外一种思路, 值得进一步探讨, 主动轮廓模型分割整个乳腺, 采用蛇形算法提取了肿块边界^[4]. 但是这些算法都存在两大缺点: 由于传统算法的外力的作用范围很小, 所以其初始主动轮廓线必须接近于目标轮廓; 在目标轮廓的凹陷处, 由于水平方向的作用力与外力方向相反而互相抵消, 因此主动轮廓线不能收敛于目标轮廓的凹陷处. 也有一些方法可以解决这两个问题中的一个, 但同

时又带来另外的问题. 如加大的值, 外力的作用范围扩大了, 但是边界的定位却变得模糊和不准确了, 最终当很大时, 边缘凹陷处也会被模糊掉. 而基于欧氏距离的算法, 它只是改变了外力的大小, 而没有改变外力的方向, 所以并不能解决主动轮廓线在目标轮廓凹陷处的收敛问题. 外部能量的选择是可变形轮廓线变形行为的关键. 梯度矢量流方法 (Gradient Vector Flow, GVF)^[5] 正是基于亥姆霍兹最小能量损耗原理的一种新的外部能量, 从而使可变形轮廓线收敛于目标边缘凹陷处. 梯度向量流就是使得以下能量方程最小的静态外部力量场 $V(x, y) = [u(x, y), v(x, y)]$:

$$\varepsilon = \iint (\mu(u_x^2 + u_y^2 + v_x^2 + v_y^2) + |\nabla f|^2 |v - \nabla f|^2) dx dy$$

$$f = -\nabla E_{\text{ext}} \quad (1)$$

与其相对应的动态可变形轮廓线方程如下:

$$X_t(s, t) = \alpha X''(s) - \beta X''(s) + V \quad (2)$$

经分析式(1)可以看出, 当 ∇f 很小时, 能量主要由向量场的二阶偏导数平方和决定, 因此产生一个缓慢变化的场. 而当 ∇f 很大时, 被积函数主要由后一项决定, 在 $v = \nabla f$ 时能量达到最小, 此时得到了我们所期望的结果, 即梯度矢量流近似等于边缘梯度. 图像的噪声越大, 权重参数 μ 的取值就应越大. 应用变分方法, 求解以下欧拉方程得到梯度矢量流的解:

$$\mu \nabla^2 u - (u - f_x)(f_x^2 + f_y^2) = 0$$

$$\mu \nabla^2 v - (v - f_y)(f_x^2 + f_y^2) = 0 \quad (3)$$

式中, ∇^2 是拉普拉斯算子. 在图像灰度变化很小或没有变化的区域, $f(x, y)$ 的梯度等于零, μ 和 v 的值可以通过离散和迭代来得到, μ 和 v 由拉氏方程来决定.

$$\mu_t(x, y, t) = \mu \nabla^2 u(x, y, t) - (u(x, y, t) - f_x(x, y, t))(f_x^2(x, y, t) + f_y^2(x, y, t))$$

$$v_t(x, y, t) = \mu \nabla^2 v(x, y, t) - (v(x, y, t) - f_y(x, y, t))(f_x^2(x, y, t) + f_y^2(x, y, t)) \quad (4)$$

算法描述:

step1: 读入原始乳腺 X 光片位图;

step2: 初始化;

step3: 应用二维高斯函数 ($\sigma = 2.5$), 模糊原始图像;

Step4: 对模糊过的图像计算其梯度, 并归一化;

Step5: 迭代计算梯度矢量流, 得到 u 和 v , 公式如下:

$$v_{i,j}^n = (1 - b_{i,j} \Delta t) v_{i,j}^{n-1} + r(v_{i+1,j}^{n-1} + v_{i-1,j}^{n-1} + v_{i,j-1}^{n-1} - 4v_{i,j}^{n-1} + d_{i,j} \Delta t) \quad (5)$$

$$u_{i,j}^n = (1 - b_{i,j} \Delta t) u_{i,j}^{n-1} + r(u_{i+1,j}^{n-1} + u_{i-1,j}^{n-1} + u_{i,j-1}^{n-1} - 4u_{i,j}^{n-1} + C_{i,j} \Delta t) \quad (6)$$

其中

$$r = \frac{\mu \Delta t}{\Delta x \Delta y} \quad b = f_x(x, y)^2 + f_y(x, y)^2$$

$$c = b f_x(x, y) \quad d = b f_y(x, y)$$

Step6: 对式(2) 迭代计算可变形轮廓.

该算法的过程和结果如图 1 ~ 4 所示.




图 1 边缘梯度




图 2 梯度矢量流




图 3 轮廓线迭代过程




图 4 算法最终结果

3 特征提取

本文提取了纹理特征及形状特征.

3.1 纹理特征提取

本分类器提取以下 9 个纹理特征:

(1) 角二阶矩

$$f_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} [p(i, j)]^2 \quad (7)$$

(2) 对比度

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \right\} \quad (8)$$

(3) 相关性

$$f_3 = \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} i \times j \times p(i, j) - \mu_x \mu_y \right\} / \delta_x \delta_y \quad (9)$$

式中, μ_x, δ_x 为 $\{p_x(i); i = 1, 2, \dots, N_g\}$ 的均值和均方差, μ_y, δ_y 为 $\{p_y(j); j = 1, 2, \dots, N_g\}$ 的均值和均方差.

(4) 方差

$$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i-u)^2 p(i,j) = \sum_{i=1}^{N_g} (i-u)^2 p_x(i) \quad (10)$$

式中, u 是 $p(i,j)$ 的均值.

(5) 逆差矩

$$f_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)^2} p(i,j) \quad (11)$$

(6) 和平均

$$f_6 = \sum_{i=2}^{2N_g} i \times p_{x+y}(i) \quad (12)$$

(7) 熵

$$f_9 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) \log[p(i,j)] \quad (13)$$

(8) 差熵

$$f_{11} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log[p_{x-y}(i)] \quad (14)$$

(9) 最大相关系统

f_{14} = 矩阵 Q 的第二最大特征值

$$Q(i,j) = \sum_{k=1}^{N_g} \frac{p(i,k)p(j-k)}{p_x(i)p_y(j)} \quad (15)$$

上面关于灰度共生矩阵的纹理特征与方向 θ 密切相关. 在图像纹理分析的许多应用中, 希望所提取的纹理特征在图像发生旋转时能保持不变, 称这种特征具有旋转不变性.

本研究对每一特征 $f_i (i = 1, 2, \dots, 13)$ 计算四个方向的平均值和均方差, 得到 26 个与旋转方向无关的纹理特征, 作为分类器的输入. 这样就抑制了方向分量, 从而得到的纹理特征与方向无关.

3.2 形状特征提取

(1) 似圆度 (Compactness)

似圆度定义如下:

$$C = 1 - \frac{4\pi A}{P^2} \quad (16)$$

式中, P 为边界的周长, A 为区域的面积. 在实际应用时, 边界周长取值为边界点的数量, 区域面积取值为区域所含像素点的数量.

由上式可知, 当 $C \rightarrow 0$ 时, 形状接近于圆. 似圆度提供了边界复杂性的一个简单度量, 如果一个形状的边界比较粗糙, 则 C 的值较大, 表现为较低的似圆度, 即似圆度 C 在一定程度上反映了区域边缘的粗糙程度. 形状相同或相似的区域边界具有相似的似圆度, 但对于形状相差较大的区域边界, 其似圆度变化比较大. 同时上式也表明, 似圆度 C 与平移、旋转和缩放无关.

(2) 矩 (Moment)

矩也是一个广泛使用的模式特征. p 阶矩定义为

$$m_p = \frac{1}{N} \sum_{i=1}^N [z(i)]^p \quad (17)$$

p 阶中心矩定义为

$$M_p = \frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^p \quad (18)$$

相应的归一化矩定义为

$$\bar{m}_p = \frac{m_p}{(M_2)^{\frac{p}{2}}} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i)]^p}{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{\frac{p}{2}}} \quad (19)$$

$$\bar{M}_p = \frac{M_p}{(M_2)^{\frac{p}{2}}} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^p}{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{\frac{p}{2}}} \quad (20)$$

由于高阶矩对噪声很敏感, 从而降低了结果分类器对噪声的承受能力. 因此在实际应用中往往使用如下的低阶矩:

$$F_1 = \frac{(M_2)^{\frac{1}{2}}}{m_1} = \frac{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{\frac{1}{2}}}{\frac{1}{N} \sum_{i=1}^N z(i)} \quad (21)$$

$$F_2 = \frac{M_3}{(M_2)^{\frac{3}{2}}} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^3}{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{\frac{3}{2}}} \quad (22)$$

$$F_3 = \frac{M_4}{(M_2)^2} = \frac{\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^4}{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^2} \quad (23)$$

实验表明, 对于不同种类的边缘形状 F_2 和 F_3 的变化不是很明显, 同时, 对同一种类中的不同对象, F_2 却表现了较大的差异, 因此 F_2 不是一个好的形状描述. 为了克服上述缺点, R. M. Rangayyan 等定义了如下新的矩^[6]:

$$F'_1 = F_1 \quad (24)$$

$$F'_2 = \frac{(M_3)^{\frac{1}{3}}}{m_1} = \frac{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^3 \right]^{\frac{1}{3}}}{\frac{1}{N} \sum_{i=1}^N z(i)} \quad (25)$$

$$F'_3 = \frac{(M_4)^{\frac{1}{4}}}{m_1} = \frac{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^4 \right]^{\frac{1}{4}}}{\frac{1}{N} \sum_{i=1}^N z(i)} \quad (26)$$

新矩具有如下特点:

(1) 三个新矩都是无量纲的. 因此, 可以直接对它们做比较, 也可以对它们进行组合.

(2) F'_3 比 F_3 更好地描述了边界的粗糙程度.

由实验结果表明, 对于一个给定的形状类型来说, F'_2 表现了比 F_2 更好的形状和旋转不变性, 但对于不同类型之间它却没有表现出比 F_2 更好的变化. 因此, 在本研究中, 我们没有使用该特征. F'_3 描述了边界的粗糙程度, 但从实验数据看, $F'_3 - F'_1$ 比单独使用 F'_3 和 F'_1 表现出了更好的性质, 而且 $F'_3 - F'_1$ 介于 0 和 1 之间, 计算如式(27) 所示.

$$f = F'_3 - F'_1 = \frac{\left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^4 \right]^{\frac{1}{4}} - \left[\frac{1}{N} \sum_{i=1}^N [z(i) - m_1]^2 \right]^{\frac{1}{2}}}{\frac{1}{N} \sum_{i=1}^N z(i)} \quad (27)$$

针对感兴趣区域(肿瘤区域) 提取了肿块弦长的四个统计特征: 均值、方差、偏斜度和峰值:

均值(Mean):

$$M_{c1} = \frac{1}{K} \sum_{i=1}^K L_i \quad (28)$$

方差(Variance):

$$M_{c2}^2 = \frac{1}{K} \sum_{i=1}^K (L_i - M_{c1})^2 \quad (29)$$

偏度(Skewness):

$$M_{c3} = \frac{1}{M_{c2}^3} \sum_{i=1}^K (L_i - M_{c1})^3 \quad (30)$$

峰值(Kurtosis):

$$M_{c4} = \frac{1}{M_{c2}^4} \sum_{i=1}^K (L_i - M_{c1})^4 \quad (31)$$

式中, K 是边缘上点的数量, L_i 是边缘上点和点之间的欧氏距离. 偏度反映以平均值为中心数据分布的不对称程度. 峰值反映与正态分布相比数据分布的尖锐度或平坦度. 峰值越大, 峰形越尖锐; 峰值越小, 峰形越平坦.

4 非平衡分布数据的支持向量机算法

采用 MIAS 库中的乳腺肿瘤 X 光图像, 其中良性样本 85 个而恶性样本 15 个. 首先对所有样本进行去噪、增强与分割等预处理, 然后提取纹理和肿瘤形状特征, 在这些特征构成的特征库上进行分类. 本文应用传统的 SVM 算法进行乳腺肿瘤良性/恶性分类, 只有 83% 的分类准确率, 在 15 个恶性样本中

只有 1 个样本被正确分类, 在 85 个良性样本中有 82 个被正确分类. 由于各种主客观原因, 这种两类样本数量悬殊的情况在有限样本的实际问题中经常发生. 因此本文提出了以下 DFP-PSVM 算法很好地解决了此问题.

Vapnik 给出的标准线性 SVM(其核函数为线性核)如下^[7]:

$$\begin{aligned} \text{Min } v' y + \frac{1}{2} \omega' \omega \quad v \text{ 是大于 0 的参数} \\ \text{s. t. } D(A\omega - e\gamma) + y \geq e \text{ and } y \geq 0 \end{aligned} \quad (32)$$

DFP-PSVM 算法是通过将约束性数学规划问题转换为无约束性规划问题来实现的. 式(32) 中的两个约束条件可以用 $y = (e - D(A\omega - e\gamma))_+$ 替换, 得到如下无约束最小化问题:

$$\min \frac{v}{2} \| (e - D(A\omega - e\gamma))_+ \|^2 + \frac{1}{2} \left\| \begin{bmatrix} \omega \\ \gamma \end{bmatrix} \right\|^2 \quad (33)$$

$(e - D(A\omega - e\gamma))_+ = 0$ 表示 $(e - D(A\omega - e\gamma))$ 的负成分为零, 即

$$(e - D(A\omega - e\gamma))_+ = \max\{0, (e - D(A\omega - e\gamma))\}$$

设 $\begin{bmatrix} \bar{\omega} \\ \bar{\gamma} \end{bmatrix}$ 是式(34) 的唯一解, 用 $\lambda \bar{\omega}$ 代换 ω 就把此问题转换成了一个简单的二维空间的凸规划问题:

$$\begin{aligned} \min f(\lambda, \gamma) = \frac{v}{2} \| (e - D(\lambda A \bar{\omega} - e\gamma))_+ \|^2 + \\ \frac{1}{2} \left\| \begin{bmatrix} \lambda \bar{\omega} \\ \gamma \end{bmatrix} \right\|^2 \end{aligned} \quad (34)$$

就以上问题, 本文提出了 DFP-PSVM 算法, 有效、快速地求解无约束极小问题, 这样避免了牛顿法在每步确定搜索方向时, 都要计算 Hesse 矩阵及其逆矩阵. 算法首先定义:

$$d(\lambda, \gamma) = e - D(\lambda A \bar{\omega} - e\gamma)$$

DFP-SVM 算法所需要的偏导数如下:

$$\nabla f(\lambda, \gamma)$$

$$= \begin{bmatrix} -v \bar{\omega}' A' D(d(\lambda, \gamma))_+ + \|\bar{\omega}\|^2 \lambda \\ v' D(d(\lambda, \gamma))_+ + \gamma \end{bmatrix}$$

该算法的具体步骤如下:

(1) 用第二节的算法计算出 $\bar{\omega}$ 和 $\bar{\gamma}$;

(2) 令 $\lambda^0 = 1, \gamma^0 = \bar{\gamma}, H_0 = I, j = 0$;

(3) 求 $g_0 = \nabla f(\lambda^j, \gamma^j)$, 若 $\nabla f(\lambda^j, \gamma^j) = 0$ 则停机, 否则 $p_0 = -g_0$;

$$(4) \text{ 用 } \frac{d\left(f\left(\begin{bmatrix} \lambda^j \\ \gamma^j \end{bmatrix} + \alpha p_j\right)\right)}{d\alpha} = 0 \text{ 确定 } \alpha_j;$$

$$(5) \begin{bmatrix} \lambda^{j+1} \\ \gamma^{j+1} \end{bmatrix} = \begin{bmatrix} \lambda^j \\ \gamma^j \end{bmatrix} + \alpha_j p_j$$

$$(6) \delta_{j+1} = \begin{bmatrix} \lambda^{j+1} \\ \gamma^{j+1} \end{bmatrix} - \begin{bmatrix} \lambda^j \\ \gamma^j \end{bmatrix} = \alpha_j p_j, \text{ 如果 } \|\delta_{j+1}\|$$

$$\leq \epsilon \text{ 则停机, } \begin{bmatrix} \omega \\ \gamma \end{bmatrix} = \begin{bmatrix} \lambda^{j+1} \bar{\omega} \\ \gamma^{j+1} \end{bmatrix};$$

(7) 否则,

$$g_{j+1} = \nabla f(\lambda^{j+1}, \gamma^{j+1}),$$

$$\Delta g_j = g_{j+1} - g_j$$

(8) 利用 DFP 公式求 H_{j+1}

$$H_{j+1} = H_j + \frac{\delta_{j+1} \delta_{j+1}^T}{\delta_{j+1}^T \Delta g_{j+1}} - \frac{H_j \Delta g_{j+1} \Delta g_{j+1}^T H_j}{\Delta g_{j+1}^T H_j \Delta g_{j+1}};$$

$$(9) p_{j+1} = -H_{j+1} g_{j+1}, j = j + 1;$$

(10) 返回第(4)步;

(11) 应用所得到的最优解 $\begin{bmatrix} \omega \\ \gamma \end{bmatrix}$ 进行分类。

而对于非线性问题,也就是求解以下无约束条件的数学规划问题,再用 DFP-PSVM 算法求解。

$$\text{Min } \frac{\nu}{2} \|e - D(K(A, A')D\mu - e\gamma)\|^2 + \frac{1}{2} \left\| \begin{bmatrix} \mu \\ \gamma \end{bmatrix} \right\|^2 \quad (35)$$

同样采用 MIAS 库中的乳腺肿瘤 X 线图像,其中良性样本 85 个,而恶性样本 15 个。用 DFP-PSVM 方法的分类准确率提高到 89%,其中 81 个良性样本和 8 恶性样本被正确分类。实验证明,在小样本情况下,对分布极不平衡的数据,本文提出的 DFP-PSVM 算法能减弱多样本类对少样本类的影响,从而具有较高的分类能力。

5 结束语

本文采用基于可变形模型的梯度矢量流方法分割乳腺 X 光片的肿瘤区域,提取形状和纹理特征作为分类算法的特征输入,从而构造了一个基于支持向量机的医学图像分类器。

支持向量机利用接近边界的少数向量来构造一个最优分类面。然而当两类中的样本数量差别悬殊时,PSVM 算法则会过度拟合样本量大的那一类,而对样本量很小的那一类的错分率相当高。为解决此问题,本文提出了一种改进的支持向量机算法——DFP-PSVM 算法。提高了分类能力。

参考文献:

- [1] 边肇祺,张学工. 模式识别[M]. 北京:清华大学出版社,2000.
- [2] 李向军,庄彬,孟志青. 基于 V-SVM 的时态周期模式发现[J]. 微电子学与计算机,2009,26(11):169-176.
- [3] 汪健,张虹. MSSFD——一种递进式人脸检测算法[J]. 微电子学与计算机,2007,24(12):195-198.
- [4] Nakagawa T, Hara T, Fujita H, et al. Automated contour extraction of mammographic mass shadow using an improved active contour mode[C]// Proceedings of the 15th International Congress Series. New York: Computer Assisted Radiology and Surgery, 2004(1268):882-885.
- [5] Xu C, Prince J L. Global optimality of gradient vector flow[C]// Proc of 34th Annual Conference on Information Sciences and Systems (CISS'00), Princeton University, Ciss, 2000:624-629.
- [6] Rangayyan R M, Nema M, El-faramawy, onsy A. alim, measures of acutance and shape for classification of breast tumors[J]. IEEE Transactions on Medical Imaging, 1997, 16(6):799-810.
- [7] Fung G, Mangasarian O L. Proximal support vector machine classifiers[C]// Proceedings of the seventh ACM SIGKDD international conference on knowledge discovery and data mining. NY, USA: ACM, 2001:77-86.

作者简介:

华翔女, (1979-), 博士, 讲师. 研究方向为图像提取、边缘检测。

(上接第 170 页)

- [5] Dean J, Ghemawat S. MapReduce: simplified data processing on large clusters[C]// Proc 6th Symp on Operating System Design and Implementation, New York, ACM Press, 2004:137-150.
- [6] 杨文志. 云计算技术指南—应用、平台与架构[M]. 北京:化学工业出版社, 2010.

作者简介:

江学男, (1976-), 讲师. 研究方向为分布式系统和 Web 技术。

张璟男, (1952-), 博士, 教授, 博导. 研究方向分布式计算和计算机网络。

王志明男, (1971-), 教授. 研究方向为网络技术。