

基于偏最小二乘回归的纹理特征线性组合

金淑英¹ 李德仁¹ 龚健雅¹

(1 武汉大学测绘遥感信息工程国家重点实验室, 武汉市珞喻路 129 号, 430079)

摘要: 基于偏最小二乘回归技术对纹理特征进行线性组合, 得到新的纹理特征来进行分类。实验表明, 组合后的纹理特征不但提高了纹理分类的性能, 而且具有一定的数据自适应能力。

关键词: 特征组合; 特征选择; 共生矩阵; 纹理谱; 偏最小二乘回归

中图分类号: P237.3

1 纹理特征提取

1.1 灰度共生矩阵

灰度共生矩阵(gray level co-occurrence matrix, GLCM) 为一定大小的窗口内两个相邻像素的某种灰度关系出现的频率。常用的基于灰度共生矩阵的纹理特征有对比度(contrast, CON)、能量(energy, ENG)、熵(entropy, ENT)、逆差矩(inverse difference moment, IDM)等^[1]。

本文首先将图像灰度降到 8 级, 统计 4 个方向的灰度共生矩阵, 再分别从中提取上述纹理特征。

1.2 纹理谱

纹理单元(texture unit) 是像素周围很小的邻域, 如 3×3 邻域可组成一个纹理单元。纹理单元的取值取决于中心像素与周围像素的灰度关系。纹理单元的取值定义为:

$$TU = \sum_{i=1}^8 T_i \times 3^i \quad (1)$$

T_i 是两相邻像素的灰度关系, 定义为:

$$T_i = \begin{cases} 0, & g(x_0, y_0) < g(x_i, y_i) \\ 1, & g(x_0, y_0) = g(x_i, y_i) \\ 2, & g(x_0, y_0) > g(x_i, y_i) \end{cases} \quad (2)$$

其中, $g(x_0, y_0)$ 是中心像素的灰度; $g(x_i, y_i)$ 是第 i 个相邻像素的灰度。

因此, 纹理单元共有 $3^8 = 6\,561$ 种不同的取值。在一个更大的窗口内统计纹理单元的频率直

方图, 将它定义为纹理谱。这样纹理谱特征就是一个 6 561 维的特征矢量。

文献[2]对纹理谱特征进行了简化, 即纹理单元只比较了 4 个方向像素的灰度, 使纹理谱特征的维数减少到 $3^4 = 81$ 维。

1.3 小波变换

基于小波变换的纹理特征^[3,4]具有多尺度属性, 已广泛应用于图像内容检索、文字种类识别^[5]等领域。本文应用 Mallat 算法对图像进行二级小波分解, 得到 7 个子图像 A_2 (近似)、 H_2 (水平细节)、 V_2 (垂直细节)、 D_2 (对角细节)、 H_1 (水平细节)、 V_1 (垂直细节)、 D_1 (对角细节), 本文使用这些子图像的均值及标准差作为纹理特征值。本文基于小波变换的纹理特征有 $7 \times 2 = 14$ 维, 其中小波函数采用 1 阶 Daubechies 小波^[1]。

2 纹理特征优化组合

2.1 偏最小二乘回归用于特征组合

假设自变量 X 为 n 个 p 维纹理特征矢量组成的样本集合, 因变量 Y 为对应的纹理类别的集合。为了偏最小二乘回归(partial least square regression, PLSR)分析的需要, 本文将 Y 按下列方式表示成 n 个 q 维特征矢量的集合(q 为总类数):

$$Y = [y_1 \ y_2 \ \dots \ y_n]^T$$

其中,

$$y_i = \begin{cases} [1 \ 0 \ \dots \ 0], & \text{若 } y_i \text{ 属于第 1 类} \\ [0 \ 1 \ \dots \ 0], & \text{若 } y_i \text{ 属于第 2 类} \\ \vdots \quad \vdots \quad \vdots \quad \dots & \\ [0 \ 0 \ \dots \ 1], & \text{若 } y_i \text{ 属于 } q \text{ 类} \end{cases} \quad (3)$$

偏最小二乘回归技术与普通的最小二乘回归有很多相似之处,出于方法表述的需要,下面从普通的最小二乘回归技术引出偏最小二乘回归技术。

利用普通的最小二乘回归技术求解方程 $XA = Y$, 得到的系数矩阵 $A = (X^T X)^{-1} X^T Y$, 从而得到估计量 $Y = XA$, Y 是 X 的线性组合, 可以看成是对样本进行线性特征组合得到的新样本的集合。因为同类样本对应的纹理类别相同, 因此可以将纹理类别矢量看成是某类样本经过线性组合后的(虚拟)中心矢量。因为经过最小二乘回归后得到的 Y 是 Y 在均方误差最小原则上的无偏估计, 因此, 同类样本经过线性特征组合后将分布在其(虚拟)中心矢量的附近。

从求解系数矩阵的公式 $A = (X^T X)^{-1} X^T Y$ 可以看出, $(X^T X)$ 必须是可逆矩阵, 即自变量 X 的各个特征之间必须线性无关才能求解。然而实际纹理特征值之间经常存在相关性(特别对于高维纹理特征), 此时最小二乘估计会失效。

为解决此问题, 偏最小二乘回归分析利用了成分提取的办法^[6]。该方法分别从自变量 X 和因变量 Y 中提取出主成分 t_1 和 u_1 。在提取这两个成分时, 为了回归分析的需要, 有下列两个约束条件。

t_1 和 u_1 应尽可能大地携带 X 和 Y 的数据变异信息;

t_1 和 u_1 的相关程度能够达到最大。

这两个条件表明, t_1 和 u_1 应尽可能地代表数据 X 和 Y , 又使得自变量的成分 t_1 对因变量的成分 u_1 有很强的解释能力。

偏最小二乘回归分析将多元线性回归分析、变量的主成分分析和变量之间的典型相关分析有机地结合起来, 在一个算法下, 同时实现了回归建模、数据结构简化和两组变量间的相关分析。可以看出, 偏最小二乘回归求得的 Y (新纹理特征矢量的集合) 其实是 X (常规纹理特征矢量的集合) 的线性特征组合, 显然也分布在各类(虚拟)中心矢量附近。

偏最小二乘回归的主成分个数可采用交叉有效性^[6]确定, 它通过测量某个主成分对预测模型精度的贡献大小来决定该成分是否是显著有益的。本文则根据经验确定主成分数等于类别数 q 。

2.2 基于偏最小二乘回归的组合纹理特征

对比度、能量、逆差矩其实是灰度共生矩阵各元素值的线性组合, 而且组合系数是由矩阵行列

号决定的常数^[2]。由此得到启发, 将 4 个方向的灰度共生矩阵看成是 $4 \times 8 \times 8 = 256$ 维的纹理特征矢量, 利用偏最小二乘回归技术对这些特征进行线性组合, 得到新的纹理特征矢量, 本文称为基于偏最小二乘回归的组合灰度共生矩阵纹理特征 (PLS-Combined GLCM)。与常规的基于灰度共生矩阵的纹理特征 (GLCM-based) 相比, PLS-Combined GLCM 对 GLCM 进行线性组合的系数由偏最小二乘回归求解得到, 是与特定问题相关的, 具有一定的自适应能力。本文比较了灰度共生矩阵 (GLCM) 及其常规的纹理特征 (GLCM-based) 和偏最小二乘回归组合的纹理特征 (PLS-Combined GLCM) 的纹理分类性能。

同样地, 利用偏最小二乘回归技术对 81 维的纹理谱特征进行线性组合, 可得到新的纹理谱特征, 称之为偏最小二乘回归组合的纹理谱特征 (PLS-Combined TS)。本文比较了 PLS-Combined TS 和原始纹理谱特征 (TS) 的纹理分类性能。

3 实验结果及讨论

本文实验的目的是: 利用 PLS 对纹理谱特征和灰度共生矩阵进行线性组合后得到的新纹理特征 (PLS-Combined TS、PLS-Combined GLCM), 与原始特征 (TS、GLCM) 相比, 在纹理分类性能方面是否改进; 利用 PLS 对灰度共生矩阵进行线性组合后得到新纹理特征 (PLS-Combined GLCM) 与常规的基于灰度共生矩阵的纹理特征 (GLCM-based) 相比, 在纹理分类性能方面有何变化; 比较 PLS 组合的纹理特征 (PLS-Combined TS、PLS-Combined GLCM) 与基于小波变换的纹理特征 (WT) 的纹理分类性能。

本研究从 Brodatz 纹理库中随机选取了 4 个复合的二类纹理图像 (图 1), 大小为 512×256 。纹理统计的窗口大小为 16×16 , 每类有 16 个样本。

纹理分类实验采用线性判别分析 (linear discrimination analysis, LDA) 和二次判别分析 (quadratic discrimination analysis, QDA) 算法。样本数据的训练精度列于表 1, 纹理分类的精度列于表 2。其中, GLCM 是原始灰度共生矩阵 (256 维), GLCM-based 是常规基于灰度共生矩阵的纹理特征 (16 维), PLS-Combined GLCM 是偏最小二乘回归组合的灰度共生矩阵纹理特征 (2 维), TS 是原始纹理谱特征 (81 维), PLS-Com-




图 1 从 Brodatz 纹理库选取的图像

Fig. 1 Texture Images from Brodatz Library

PLS 组合的纹理谱特征 (2 维), WT 是基于小波变换的纹理特征 (14 维)。

表 1 样本训练精度

Tab. 1 Training Precision of Texture Samples

纹理特征	GLCM	GLCM-based	PLS-Combined-GLCM	TS	PLS Combined-TS	WT
LDA	94.531	100	100	96.875	100	100
QDA	31.25	100	100	17.187	100	100

表 2 纹理分类精度

Tab. 2 Classification Precision of Texture Features

纹理特征	GLCM	GLCM-based	PLS-Combined-GLCM	TS	PLS Combined-TS	WT
LDA	87.958	91.312	94.162	84.303	92.486	89.288
QDA	—	67.713	93.142	—	91.332	80.042

从表 1 可以看出, GLCM 和 TS 两种高维特征 (分别为 256 维和 81 维) 由于特征之间很大程度上存在相关性, QDA 的训练结果很不理想, LDA 的训练精度也低于其他几种纹理特征。

从表 2 可以看出, LDA 的精度总体上要高于 QDA。偏最小二乘回归组合后的两种新纹理特征 (PLS-Combined-GLCM、PLS-Combined-TS) 的分类精度远高于原始纹理特征 (GLCM、TS) 的分类精度, 其中 PLS-Combined-GLCM 的分类精度要高于常规基于灰度共生矩阵的纹理特征 (GLCM-based) 的分类精度。与基于小波变换的纹理特征 (WT) 相比, 偏最小二乘回归组合后的两种新纹理特征 (PLS-Combined-GLCM, PLS-Combined-TS) 的分类精度更高。总的说来, 对两种判别分析方法而言, PLS-Combined-GLCM 的分类精度都是最高的。

通过偏最小二乘回归对高维特征 (TS, GLCM) 进行线性组合, 不但达到了降维的目的, 还可以提高分类精度。尤其对于 QDA, 原始高维特征之间由于存在高度相关性, 训练精度极低, 已无法分类, 而经过 PLS 线性组合后的新特征的训练

精度均达到了 100%。另外, PLS 组合的新纹理特征比常规的基于灰度共生矩阵的纹理特征的分类精度要高, 这是因为新特征对灰度共生矩阵的组合系数是通过求解特定问题得到的, 一定程度上具有自适应的特点。另外, PLS 组合的新纹理特征只有 2 维, 在大数据量的情况下可以提高分类速度。

4 结 语

本文从纹理特征优化组合的角度出发, 利用偏最小二乘回归技术对纹理特征进行线性组合, 利用线性组合后的新纹理特征进行分类, 从而有效地提高了分类精度。偏最小二乘回归技术用于纹理特征线性组合, 与其他特征选择/组合方法 (滤波法和包装法) 相比, 不但提取出最佳区分能力的特征, 而且计算复杂度低, 能避免局部极值点问题, 有一定的应用前景。

参 考 文 献

- [1] Martino P. Texture Analysis for Urban Pattern Recognition Using Fine-resolution Panchromatic Satellite Imagery [J]. Geographical and Environmental Modelling, 2000, 4(1): 43-63
- [2] 李德仁, 张继贤. 影像纹理分析的现状和方法[J]. 武测科技, 1993(3): 30-37
- [3] Arivazhagan S, Ganesan L. Texture Classification Using Wavelet Transform [J]. Pattern Recognition Letters, 2003, 24: 3 197-3 203
- [4] Manesh K, Chatterji B N, Biswas P K. Cosine-modulated Wavelet Based Texture Features for Content-based Image Retrieval [J]. Pattern Recognition Letters, 2004, 25: 391-398
- [5] 唐远炎, 王玲. 小波分析与文本文字识别[M]. 北京: 科学出版社, 2004
- [6] 王惠文. 偏最小二乘回归方法及其应用[M]. 北京: 国防工业出版社, 1999
- [7] Singh M, Singh S. Texture Algorithms: Performance Variability Across Data Sets [J]. Cybernetics and Systems, 2003, 34: 1-17
- [8] Manish H B, Liu J J, John F M. Image Texture Analysis: Methods and Comparisons [J]. Chemometrics and Intelligent Laboratory Systems, 2004, 72: 57-71
- [9] Gao Ling, Ren Shouxin. Simultaneous Spectrophotometric Determination of Four Metals by the Kernel Partial Least Squares Method [J]. Chemometrics and Intelligent Laboratory Systems, 1999, 45: 87-93

- [10] Ross F W, Paul T J, Dennis L. Genetic Algorithm Optimization of Adaptive Multi-scale GLCM Features[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2003, 17(1): 17-39
- [11] He Dongchen, Wang Li. Texture Unit, Texture Spectrum, and Texture Analysis[J]. IEEE Transactions on Geoscience and Remote Sensing, 1990, 28(4): 509-512

- [12] Heisele B, Serre T, Prentice S, et al. Hierarchical Classification and Feature Reduction for Fast Face Detection with Support Vector Machines[J]. Pattern Recognition, 2003, 36: 2 007-2 017

第一作者简介:金淑英,博士生。现主要从事遥感图像处理研究。
代表成果:遥感图像处理系统 GeoImager。

E-mail: jinshuying@yahoo.com.cn

Linear Combination of Texture Features Based on Partial Least Square Regression

JIN Shuying¹ LI Deren¹ GONG Jianya¹

(1 State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing, Wuhan University, 129 Luoyu Road, Wuhan 430079, China)

Abstract: The paper presents partial least squares (PLS) method. Firstly, texture features (spectrum (TS) and gray-level co-occurrence matrix (GLCM)) are calculated from local image regions. Secondly, the authors apply PLS regression to preparatory texture features to extract linear combined new texture features. Thirdly, both the linear combined texture features and the preparatory texture features, together with the ordinary texture features, are imported into linear discrimination analysis (LDA) and quadratic discrimination analysis (QDA). Finally, classification results are compared and conclusions are drawn.

The experiments show that not only PLS can reduce the dimension of texture features but also the combined texture features efficiently have better discrimination abilities than the ordinary texture features.

Key words: feature combination; feature selection; GLCM; texture spectrum; partial least square regression

About the first author: JIN Shuying, Ph.D candidate, studying on remote sensing imagery processing. Her typical achievements are GeoImager, a remote sensing imagery processing system.

E-mail: jinshuying@yahoo.com.cn

下期主要内容预告

- | | |
|------------------------------|-------|
| ▶ 基于空间数据库的城市网格化管理与服务系统的设计与实现 | 李德仁,等 |
| ▶ 遥感图像相关性及其熵计算 | 卢健,等 |
| ▶ 高精度惯性导航系统对重力场模型的要求 | 李斐,等 |
| ▶ 基于多重变换组合的动态地图符号设计 | 祝国瑞,等 |
| ▶ DSM数据中多层次、多直角房屋的三维重建 | 阎平,等 |
| ▶ 大气折光对水平角测量影响及对策研究 | 张正禄,等 |