

文章编号: 2095-2163(2019)05-0050-04

中图分类号: TP391.41

文献标志码: A

一种改进的稀疏编码模型图像分类算法

刁琦

(浙江东方职业技术学院, 浙江温州 325000)

摘要: 针对传统稀疏编码方法对图像分类, 本文采用 SIFT 算法提取的图像特征, 分类器主要通过构造多尺度小波核极限学习机进行图像分类。采用该方法对 wine 数据集与微软 Corel1K 图像库进行测试, 实验表明, 较单尺度小波核, 多尺度小波核具有更好的分类效果。同时, 多尺度小波核极限学习机的分类性能优于多尺度支持向量机、支持向量机与极限学习机的分类性能。

关键词: 稀疏编码; 图像分类; 极限学习机; 支持向量机

An improved image classification approach of sparse coding

DIAO Qi

(Zhejiang Dongfang Polytechnic, Wenzhou Zhejiang 325000, China)

[Abstract] According to the traditional sparse coding method for image classification, the image features extracted by SIFT algorithm are used in this paper. The classifier mainly constructs multi-scale wavelet kernel limit learning machine for image classification. This method is used to test the wine dataset and the Microsoft Corel1K image library. Experiments show that the multi-scale wavelet kernel has better classification effect than the single-scale wavelet kernel. At the same time, the classification performance of multi-scale wavelet kernel limit learning machine is better than that of multi-scale support vector machine, support vector machine and extreme learning machine.

[Key words] sparse coding; image classification; extreme learning machine; support vector machine

0 引言

稀疏编码(Sparse Coding, SC)算法作为无监督的学习方法之一,其使用基向量的线性组合方式(完备基)来描述图像的输入信息,且能够提取较好的数据集特征,广泛应用于图像分类、图像检索、数据预测等问题。张立和等人^[1]提出核拉普拉斯稀疏编码,在分类效果上优于拉普拉斯稀疏编码;谢成军等人^[2]采用稀疏编码金字塔模型对农田害虫图像进行识别,较传统方法识别精度提高 14.1%;张勇等人^[3]提出一种非负弹性网稀疏编码算法,较传统的稀疏编码算法的有效性更高,分类的效果更好;徐佳庆等人^[4]提出基于二阶矩空谱联合稀疏编码的遥感图像分类方法,与支持向量机(Support Vector Machine, SVM)方法相比有较高的准确性。在分类方法上, SVM 是一种常用的分类器^[5]。满瑞君等人^[6]将多尺度小波支持向量机(Multi-scale wavelet SVM)应用于交通流数据的预测,指出该方法的预测准确性高于 BP 神经网络和高斯 SVM。随着极限学习机(Extreme Learning Machine, ELM)的提出,也被

研究者广泛应用于图像分类问题^[7]。王杰等人^[8]将小波核极限学习机(Wavelet ELM)应用于 UCI 图像集分离,并指出 WELM 的分类性能优于 ELM。为此,本文将多尺度小波核函数(Multi-scale wavelet kernel)作为 ELM 的核函数,以在测试集中获得更好的分类效果。对此拟展开研究论述如下。

1 稀疏编码描述

SC 概念来源于仿生学,其作为一种特征的代表方法,目的在于求解基向量的系数,采用基向量的线性组合来表示输入特征。其数学公式即如式(1)所示:

$$X = \sum_{i=1}^k a_i \Phi_i, \quad (1)$$

其中, Φ_i 代表基向量, a_i 为基向量的系数。

类似于主成分分析(Principal Component Analysis, PCA)描述信息特征,采用 SC 也是为了使用较少的数据去构造一个新的数据。根据式(1)中的变量数量来看,需要求解基向量以及相应系数两个变量。由于基向量个数大于输入向量的维数,这

基金项目: 浙江省社科规划课题成果(19NDJC396YBM); 校级课题(DF2017YB08)。

作者简介: 刁琦(1989-),男,硕士,助教,主要研究方向:计算机应用技术、智能计算及应用。

收稿日期: 2019-07-30

哈尔滨工业大学主办 ◆ 学术研究与应用

使得求解基向量的系数不再唯一取决于输入向量。为了能够求解2个变量,需要对基向量系数进行约束。那么,稀疏编码的目标函数表达式见式(2):

$$\min_{a_i^{(j)}, \Phi_i} \sum_{j=1}^m \|x^{(j)} - \sum_{i=1}^k a_i^{(j)} \Phi_i\|^2 + \lambda \sum_{i=1}^k S(a_i^{(j)}), \quad (2)$$

分析可知,式(2)中包含2部分,第一项可理解为构造项,第二项为系数的惩罚系数, λ 为常量,用以平衡上述两项间的代价权重。由于系数 a 的无限减小与基值无限大使得第一项基本保持不变,而第二项会很小。为了获得最优解,需对基向量进行约束,最终的目标函数描述如式(3)所示:

$$\min_{a_i^{(j)}, \Phi_i} \sum_{j=1}^m \|x^{(j)} - \sum_{i=1}^k a_i^{(j)} \Phi_i\|^2 + \lambda \sum_{i=1}^k S(a_i^{(j)})$$

subject to $\|\Phi_i\|^2 \leq C, \forall i = 1, \dots, k.$ (3)

2 本文算法

2.1 SIFT 特征

本文在特征提取上主要采用尺度不变特征变换(Scale Invariant Feature Transform, SIFT)算法,其本质是一种局部特征的提取方法,主要优势在于对图像的旋转、尺度缩放、亮度变化等保持不变形^[9]。采用 SIFT 算法提取图像特征主要包括4个步骤,即:

- (1) 尺度空间的关键点检测。
- (2) 定位关键点。
- (3) 确定关键点位置。
- (4) 生成特征描述符。

限于篇幅,此处将不再详述 SIFT 算法的特征提取过程。

2.2 多尺度小波核 ELM 分类器

极限学习机的表达式如式(4)所示:

$$\begin{aligned} \sum_{i=1}^L \beta_i G(a_i \cdot x_1 + b_i) &= t_1; \\ &\vdots \\ \sum_{i=1}^L \beta_i G(a_i \cdot x_N + b_i) &= t_N; \end{aligned} \quad (4)$$

$i = 1, 2, \dots, L.$

其中, $G(\cdot)$ 为激活函数; a_i 为输入权值; β_i 为输出权值; b_i 为第 i 个隐含层单元的偏置,其矩阵形式如式(5)所示:

$$\mathbf{H}(a_1, \dots, a_L, b_1, \dots, b_L, x_1, \dots, x_N) = \begin{pmatrix} G(a_1 \cdot x_1 + b_1) \cdots G(a_L \cdot x_1 + b_L) \\ \vdots & \ddots & \vdots \\ G(a_1 \cdot x_N + b_1) \cdots G(a_L \cdot x_N + b_L) \end{pmatrix}_{N \times L}, \quad (5)$$

其中, \mathbf{H} 为隐含输出层。

较 SVM 学习机制有所不同,ELM 不仅需要考虑结构风险最小化,同时还需要考虑经验误差最小化。可构造出式(6):

$$\min: \|\beta\|^2 \sum_{i=1}^N \|\beta \cdot \mathbf{h}(x_i) + t_i\|, \quad (6)$$

为便于采用拉格朗日定理求解最值问题,式(6)可转换为式(7)的形式:

$$\min: L = \frac{1}{2} \|\beta\|^2 + \frac{1}{2} C \sum_{i=1}^M \|\xi\|^2 \quad (7)$$

$$\text{s. t. } \mathbf{h}(x_i) \beta = \mathbf{t}_i^T - \xi_i^T, i = 1, \dots, N.$$

其中, ξ_i 是训练样本 x_i 对应的网络输出值和实际值间的误差。式(7)又等同于式(8):

$$\min: L_{DELM} = \frac{1}{2} \|\beta\|^2 + \frac{1}{2} C \sum_{i=1}^M \|\xi_i\|^2 - \quad (8)$$

$$\sum_{i=1}^N \sum_{j=1}^m \alpha_{i,j} (\mathbf{h}(x_i) \beta_j - t_{i,j} + \xi_{i,j}),$$

其中, α_i 和 u_i 为拉格朗日乘子,均大于零。 β_j 为第 j 个输出节点的权值。

用式(8)分别对未知量求偏导,可得式(9):

$$\frac{\partial L_{DELM}}{\partial \beta_j} = 0 \rightarrow \beta_j = \sum_{i=1}^N \alpha_i \mathbf{h}(x_i)^T \rightarrow \beta = \mathbf{H}^T \alpha; \quad (a)$$

$$\frac{\partial L_{DELM}}{\partial \xi_i} = 0 \rightarrow \alpha_i = C \xi_i, i = 1, 2, \dots, N; \quad (b)$$

$$\frac{\partial L_{DELM}}{\partial \alpha_i} = 0 \rightarrow \mathbf{h}(x_i) \beta_i - t_i^T + \xi_i^T = 0, i = 1, 2, \dots, N. \quad (c)$$

通过式(9a)、(9b)带入式(9c),进一步可得式(10):

$$\mathbf{h}(x_1) \mathbf{H}^T C \xi_1 - t_1^T + \xi_1^T = 0; \quad (10)$$

\vdots

$$\mathbf{h}(x_N) \mathbf{H}^T C \xi_N - t_N^T + \xi_N^T = 0.$$

为简化表达式,合并为式(11):

$$\left(\frac{\mathbf{I}}{C} + \mathbf{H} \mathbf{H}^T \right) \alpha = \mathbf{T}, \quad (11)$$

$$\text{其中, } \mathbf{T} = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix} = \begin{bmatrix} t_{11} & \cdots & t_{1m} \\ \vdots & \vdots & \vdots \\ t_{N1} & \cdots & t_{Nm} \end{bmatrix}, \mathbf{H} = \begin{bmatrix} \mathbf{h}(x_1) \\ \vdots \\ \mathbf{h}(x_N) \end{bmatrix},$$

那么,输出权值表达式如式(12)所示:

$$\beta = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T + \frac{\mathbf{I}}{C})^{-1} \mathbf{T}, \quad (12)$$

极限学习机的逼近函数如式(13)所示:

$$f(x_i) = \mathbf{h}(x_i) \mathbf{H}^T (\mathbf{H} \mathbf{H}^T + \frac{\mathbf{I}}{C})^{-1} \mathbf{T}. \quad (13)$$

$$\text{其中, } \mathbf{H} = \begin{bmatrix} h(\mathbf{x}_1) \\ \vdots \\ h(\mathbf{x}_N) \end{bmatrix}_{N \times L} \quad \circ$$

隐层输出可视为样本的非线性映射,可以是线性核的形式,也可以采用 RBF 核的形式。于是可得式(14):

$$\mathbf{H}^T \mathbf{H} = \begin{bmatrix} h(\mathbf{x}_1) \\ \vdots \\ h(\mathbf{x}_N) \end{bmatrix}_{N \times L}^T \cdot \begin{bmatrix} h(\mathbf{x}_1) \\ \vdots \\ h(\mathbf{x}_N) \end{bmatrix}_{N \times L} = \begin{bmatrix} h(\mathbf{x}_1) \cdot h(\mathbf{x}_1) \cdots h(\mathbf{x}_1) \cdot h(\mathbf{x}_N) \\ \vdots & \ddots & \vdots \\ h(\mathbf{x}_N) \cdot h(\mathbf{x}_1) \cdots h(\mathbf{x}_N) \cdot h(\mathbf{x}_N) \end{bmatrix}_{N \times N}, \quad (14)$$

根据核函数理论,通过构造一个隐式的映射来代替 $\mathbf{H}\mathbf{H}^T$,如式(15)所示:

$$\mathbf{H}\mathbf{H}^T(i, j) = K(\mathbf{x}_i, \mathbf{x}_j);$$

$$\mathbf{H}\mathbf{H}^T = \mathbf{\Omega}_{ELM} = \begin{bmatrix} K(\mathbf{x}_1, \mathbf{x}_1) \cdots K(\mathbf{x}_1, \mathbf{x}_j) \\ \vdots & \ddots & \vdots \\ K(\mathbf{x}_N, \mathbf{x}_1) \cdots K(\mathbf{x}_N, \mathbf{x}_N) \end{bmatrix};$$

$$h(\mathbf{x})\mathbf{H}^T = \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_N) \end{bmatrix}, \quad (15)$$

又因式(16):

$$f(\mathbf{x}) = h(\mathbf{x})\mathbf{H}^T(\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}}{C})^{-1}\mathbf{T}, \quad (16)$$

极限学习机的求解公式经变换后可写成式(17):

$$f(\mathbf{x}) = \begin{bmatrix} K(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ K(\mathbf{x}, \mathbf{x}_N) \end{bmatrix}^T \left(\frac{\mathbf{I}}{C} + \mathbf{\Omega}_{ELM} \right)^{-1} \mathbf{T}, \quad (17)$$

为了方便,本文将 SVM 的核函数应用在 ELM 中。已知一个母小波函数 $h(x)$,其伸缩因子和平移因子分别是 a 和 b ,那么小波基函数可以表示为式(18),即:

$$h_{a,b}(x) = \sqrt{|a|} h\left(\frac{x-b}{a}\right), \quad (18)$$

根据张量积理论,一个多维的小波函数可写成多个一维小波函数的张量积,由此得到:

$$h(\mathbf{x}) = \prod_{i=1}^n h(x_i), \quad (19)$$

根据式(19)可以构造出平移不变的核函数,如式(20)所示:

$$K(x, x') = K(x + x') = \prod_{i=1}^n h\left(\frac{x_i - x'_i}{a}\right), \quad (20)$$

本文选用 Morlet 小波函数 $h(x) = \cos(1.75x) \exp(-x^2/2)$,那么小波核函数的表达式如式(21)所示:

$$\text{waveletkernel}(x, x') =$$

$$\prod_{i=1}^n \left[\cos\left(1.75 \times \frac{(x_i - x'_i)}{a}\right) \exp\left(-\frac{(x_i + x'_i)^2}{2a^2}\right) \right], \quad (21)$$

由于单个核函数不能在大规模图像分类中获得较好的分类效果,本文采用多个核函数叠加形式来构造混合的小波核函数,以提高分类效果。如式(22)所示:

$$K = a_1 * K_1 + \cdots + a_n * K_n, \quad (22)$$

同时,本文在小波核函数的基础上提出多尺度小波核,如式(23)所示:

$$K = \prod_i^n \left[\cos\left(1.75 \times \frac{(x_i - x'_i)}{a_1}\right) \exp\left(-\frac{(x_i - x'_i)^2}{2a_1^2}\right) \right] + \prod_i^n \left[\cos\left(1.75 \times \frac{(x_i - x'_i)}{a_2}\right) \exp\left(-\frac{(x_i - x'_i)^2}{2a_2^2}\right) \right] + \prod_i^n \left[\cos\left(1.75 \times \frac{(x_i - x'_i)}{a_N}\right) \exp\left(-\frac{(x_i - x'_i)^2}{2a_N^2}\right) \right] \quad (23)$$

最终可简写成式(24):

$$K = \sum_l^L \prod_i^n \left[\cos\left(1.75 \times \frac{(x_i - x'_i)}{a_l}\right) \exp\left(-\frac{(x_i - x'_i)^2}{2a_l^2}\right) \right]. \quad (24)$$

3 实验结果与分析

首先,本文对 Wine 数据集进行测试。Wine 数据集包含了 3 类葡萄酒数据,共计 178 个样本,每类葡萄酒有 13 个属性特征。第一类训练样本为 1 ~ 30,第二类训练样本为 60 ~ 95,第三类训练样本为 131 ~ 153,其余为测试样本。分别对比单尺度、二尺度以及三尺度的分类性能。采用不同尺度小波核的分类结果见表 1,采用文献[6]获得的分类精度为 93.09%,这也表明采用多尺度小波核 ELM 分类性能优于小波核 ELM 和小波核 SVM。分类的具体情况如图 1 所示。

表 1 不同尺度小波核极限学习机的分类性能

Tab. 1 Classification performance of Wavelet kernel limit learning machines with different scales %

尺度	分类精度
单尺度小波核	94.91
二尺度小波核	96.61
三尺度小波核	96.61

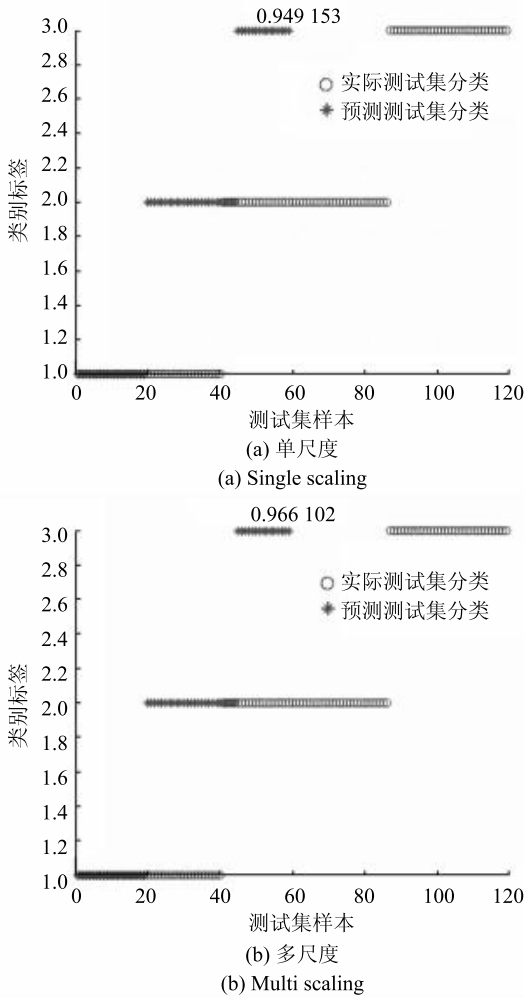


图1 不同尺度小波核极限学习机的分类效果

Fig. 1 Classification effect of different scale wavelet kernel limit learning machines

其次,采用微软 Corel 图像库进行测试。其中,Corel 图像库包含 10 类图像,每类图像为 100 张,共计 1 000 张图像。方法实现中主要包括 2 部分,分别是:对图像进行 sift 特征提取,图像分类。每类图像的分类精度见表 2。

表2 Corel 各类图像的分类精度

Tab. 2 Classification accuracy of Corel images

Corelk	样本数量	分类精度
Africa	30	0.771 4
beaches	30	0.828 6
buildings	30	0.757 1
buses	30	1
dinosaurs	30	1
elephants	30	0.928 6
flowers	30	0.957 1
food	30	0.985 7
horses	30	0.975 1
mountains	30	0.890 0

采用不同分类器方法的对比情况如图 2 所示。从图 2 中可看出,本文的分类精度要高于文献[6]方法、SVM 和 ELM。对于 buses 与 dinosaurs 两个类别,4 种分类器的分类精度相同,主要由于这 2 类图片背景较为简单,对于复杂图像的分类,多尺度小波核 ELM 具有较好的分类效果。




图2 不同分类器的分类效果

Fig. 2 Classification effect of different classifiers

4 结束语

本次研究及实验表明,多尺度小波核极限学习机具有较高的分类性能。由于核函数在分类问题方面具有较强的映射能力和非线性分类能力,但对于解决实际复杂背景及大规模图像分类问题效果不佳,在实际应用中可采用多个核函数由组合形式来获得更好的结果。

参考文献

- [1] 张立和,潘磊,刘涛,等. 基于核拉普拉斯稀疏编码的图像分类[J]. 大连理工大学学报,2015,55(2):192-197.
- [2] 谢成军,李瑞,董伟,等. 基于稀疏编码金字塔模型的农田害虫图像识别[J]. 农业工程学报,2016,32(17):144-151.
- [3] 张勇,张阳阳,程洪,等. 基于非负弹性网稀疏编码算法的图像分类方法[J]. 计算机工程,2017,43(7):239-243,249.
- [4] 徐佳庆,万文,吕启. 基于二阶矩稀疏编码的高光谱遥感图像分类[J]. 计算机科学,2018,45(9):288-293.
- [5] 吴园园,申立勇. 基于类重叠度欠采样的不平衡模糊多类支持向量机[J]. 中国科学院大学学报,2018,35(4):536-543.
- [6] 满瑞君,梁雪春. 基于多尺度小波支持向量机的交通流预测[J]. 计算机仿真,2013,30(11):156-159.
- [7] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/3):489-501.
- [8] 王杰,郭晨龙. 小波核极限学习机分类器[J]. 微电子学与计算机,2013,30(10):73-76,80.
- [9] 李兵,刘磊,魏志强. 一种具有强实时性、强鲁棒性的图像匹配算法[J]. 软件学报,2014,25(7):1583-1592.