

1-8-2019

Image Classification Based on Sparse Autoencoder and Support Vector Machine

Liu Fang

College of Information and Communication Engineering, Beijing University of Technology, Beijing 100124, China;

Lixia Lu

College of Information and Communication Engineering, Beijing University of Technology, Beijing 100124, China;

Hongjuan Wang

College of Information and Communication Engineering, Beijing University of Technology, Beijing 100124, China;

Wang Xin

College of Information and Communication Engineering, Beijing University of Technology, Beijing 100124, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Image Classification Based on Sparse Autoencoder and Support Vector Machine

Abstract

Abstract: A new algorithm of image classification based on the sparse autoencoder and the support vector machine was proposed in view of the drawbacks that the single layer sparse autoencoder for feature learning is easy to lose the deep abstract feature and the features lack the robustness. The deep sparse autoencoder is constructed to learn each image layer and the feature of each layer is automatically extracted. The each feature weights and the reorganized set of feature are obtained according to the feature weighting method. By combining the strong global search ability of genetic algorithm and the excellent performance of support vector machine, the image classification is completed efficiently and accurately. The experimental results show that the proposed algorithm can automatically learn the deep feature of the image, and the reorganized feature has high feature discrimination ability, which effectively improves the accuracy of image classification.

Keywords

sparse autoencoder, feature learning, genetic algorithm, support vector machine, image classification

Recommended Citation

Liu Fang, Lu Lixia, Wang Hongjuan, Wang Xin. Image Classification Based on Sparse Autoencoder and Support Vector Machine[J]. Journal of System Simulation, 2018, 30(8): 3007-3014.

基于稀疏自动编码器和支持向量机的图像分类

刘芳, 路丽霞, 王洪娟, 王鑫

(北京工业大学信息与通信工程学院, 北京 100124)

摘要: 针对单层稀疏自动编码器在特征学习时容易丢失深层抽象特征, 特征缺乏鲁棒性的缺点, 提出一种新的基于稀疏自动编码器和支持向量机的图像分类方法。构建深度稀疏自动编码器对图像逐层学习并自动提取每层特征, 根据特征集权值重组法得到每层特征权值和重组特征集。将遗传算法强大的全局搜索能力和支持向量机分类优势结合, 高效、准确的完成图像分类。实验结果表明, 该算法能自动地学习图像深层特征, 重组特征集具有较高的特征识别力, 有效地提高了图像分类准确率。

关键词: 稀疏自动编码器; 特征学习; 遗传算法; 支持向量机; 图像分类

中图分类号: TP391.41

文献标识码: A

文章编号: 1004-731X (2018) 08-3007-08

DOI: 10.16182/j.issn1004731x.joss.201808023

Image Classification Based on Sparse Autoencoder and Support Vector Machine

Liu Fang, Lu Lixia, Wang Hongjuan, Wang Xin

(College of Information and Communication Engineering, Beijing University of Technology, Beijing 100124, China)

Abstract: A new algorithm of image classification based on the sparse autoencoder and the support vector machine was proposed in view of the drawbacks that the single layer sparse autoencoder for feature learning is easy to lose the deep abstract feature and the features lack the robustness. The deep sparse autoencoder is constructed to learn each image layer and the feature of each layer is automatically extracted. The each feature weights and the reorganized set of feature are obtained according to the feature weighting method. By combining the strong global search ability of genetic algorithm and the excellent performance of support vector machine, the image classification is completed efficiently and accurately. The experimental results show that the proposed algorithm can automatically learn the deep feature of the image, and the reorganized feature has high feature discrimination ability, which effectively improves the accuracy of image classification.

Keywords: sparse autoencoder; feature learning; genetic algorithm; support vector machine; image classification

引言

随着信息技术的发展, 图像数据急剧增长, 对图像处理的需求也大大增加, 为了实现对大量图像

的准确分类, 提高分类技术的鲁棒性和准确率, 研究图像分类技术具有重要的现实意义。近年来, 随着神经网络成为机器学习新热点, 基于稀疏自动编码器的图像分类算法因对数据有降维作用和突出的分类准确率被学术界所关注。

文献[1]利用堆栈自动编码器(Stacked Auto Encoder, SAE)提取图像深层特征, 并且根据提取特征的分类效果为特征分配权值进行特征融合, 该



收稿日期: 2017-01-04 修回日期: 2017-02-20;
基金项目: 国家自然科学基金(61171119), 北京工业大学研究生科技基金(ykj-2015-12083);
作者简介: 刘芳(1971-), 女, 陕西西安, 博士, 副教授, 研究方向为计算机智能和可视导航等; 路丽霞(1992-), 女, 山东济宁, 硕士, 研究方向为图像处理。

<http://www.china-simulation.com>

• 3007 •

方法取得了较高的分类准确率。文献[2]将基于单层稀疏自动编码器(Sparse AutoEncoder, SAE)的算法应用到过电压波形分类中,并在过电压波形数据集上取得了不错的分类效果。文献[3]提出将堆栈稀疏自动编码器运用到光谱图像分类,利用稀疏自动编码器对光谱特征进行提取,在分类时采用五倍交叉验证对 SVM 参数寻优,分类准确率得到一定的提高。文献[4]采用单层稀疏自动编码器进行特征提取,并使用粒子群算法对支持向量机(Support Vector Machine, SVM)进行参数寻优并完成场景图像分类。

为了提取深层图像特征,出现了用卷积方法训练稀疏自动编码器进行特征提取^[5-6]。文献[7]采用非监督的卷积深度置信网络解决大尺寸、高维图像问题,并提出了随机最大池化方法,用概率的方法对图像深层特征进行表达。文献[8]采用堆栈降噪自动编码器无监督局部去噪准则对图像进行特征学习。此外,降噪自动编码器在特征提取及图像分类上也取得了不错的分类效果^[9-10]。

综上所述,以上算法都取得了较高的分类准确率,但是单隐含层的稀疏自动编码器对高维数据进行特征学习时,特征提取的效果比较一般,提取的特征不完整,并且不能较好的学习到图像的深层特征,因此会丢失一部分特征,使得特征缺乏鲁棒性,进而影响图像分类准确率;此外 SVM 分类器的性能受到其参数影响,只有选择合适的优化算法,并且选择出适合特定样本的 SVM 参数,才能将 SVM 的最优分类性能发挥出来。

针对现有方法的不足,本文提出一种新的基于稀疏自动编码器与支持向量机的图像分类方法。通过构建深度稀疏自动编码器(Deep Sparse AutoEncoder, DSAE),模拟人类大脑感知外界信号的层次结构对图像进行特征学习,提出特征集权重重组法得到每层特征权重值以及重组的特征集。SVM 在解决非线性及高维分类问题时具有明显优势,遗传算法^[11](Genetic Algorithm, GA)作为一种全局寻优算法,其强大的全局搜索能力和并行性搜

索方式能在较短时间内选择出最优解。因此,针对图像的多分类问题,本文将 GA 引入到 SVM 分类器的训练中,将 GA 强大的搜索能力和 SVM 优良性能结合,高效、准确的完成图像分类。实验表明,该算法(以下简称为 DSAE-SVM(GA)算法)能自动地学习图像深层复杂、抽象特征,重组的特征具有较高的特征识别力,有效地提高了图像分类准确率。实验还表明,深度稀疏自动编码器、特征集权重重组法以及遗传算法共同提高了图像分类准确率。

1 自动编码器

自动编码器^[12](AutoEncoder, AE)是人工神经网络的一种特殊学习模型,它的输出与输入是相同的。自动编码器通过训练调整其参数,使得输入的样本经过编码后又通过解码尽可能的复现原来的特征。自动编码器由编码器、解码器和隐含层组成,编码器是输入数据 x 到隐含层 h 的映射,隐含层 h 为:

$$h = f(x) = S_f(W + b_n) \quad (1)$$

式中: S_f 是非线性激活函数,一般是逻辑函数,如:

$$\text{sigmoid}(z) = 1 / (1 + z^{-1}) \quad (2)$$

当隐含层 h 传递到解码器后,解码器函数 $g(h)$ 将隐含层数据映射重构出数据 y , y 表示为:

$$y = g(h) = S_g(W'h + b_y) \quad (3)$$

式中: S_g 是解码器的激活函数,一般为线性函数或者是 sigmoid 函数。训练自动编码器的过程是训练样本集 D 在样本集上寻找参数 $\theta = \{W, b_y, b_h\}$ 的最小重构误差,重构误差为:

$$J_{AE} = \sum_{x \in D} L(x, g(f(x))) \quad (4)$$

式中: L 为重构误差函数,可用平方误差函数或交叉熵损失函数表示,两个函数分别为:

$$L(x, y) = \|x - y\|^2 \quad (5)$$

$$L(x, y) = \sum_{i=1}^{d_x} x_i \log y_i + (1 - x_i) \log(1 - y_i) \quad (6)$$

2 基于稀疏自动编码器和支持向量机的图像分类

本文提出一种新的基于稀疏自动编码器和支持向量机的图像分类算法, 该算法的基本原理是: 首先, 构建深度稀疏自动编码器并进行训练, 之后将测试图像输入到训练好的深度稀疏自动编码器中, 学习得到多个图像的特征集 S_1 、 S_2 、 $S_3 \dots S_n$; 然后利用本文提出的特征集权值重组法得到每层特征权值 W_1 、 W_2 、 $W_3 \dots W_n$, 将权值和对应的特征集重组得到新的特征集 T ; 最后, 用训练图像训练线性 SVM 分类器, 将 GA 强大的全局搜索能力和 SVM 分类优势结合, 选择出 SVM 最优参数, 完成图像分类。该算法的基本流程如图 1。

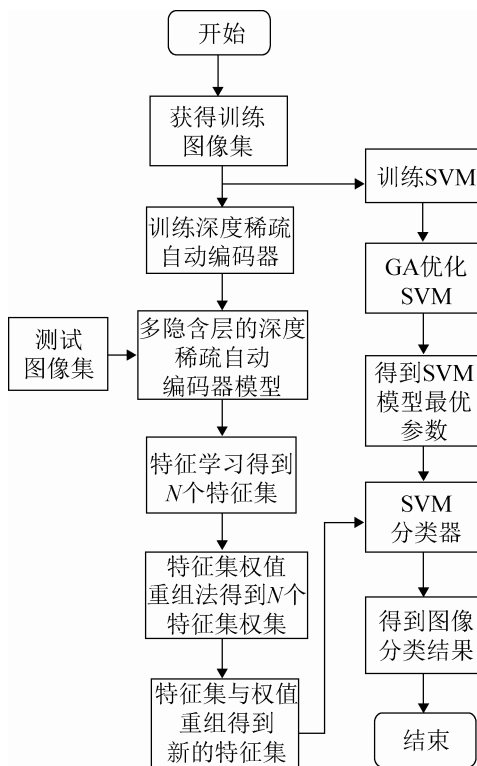


图 1 本文算法流程图

Fig. 1 Algorithm flow chart in this paper

2.1 深度稀疏自动编码器网络

稀疏自动编码器是自动编码器的一种改进, 是稀疏理论和自动编码器结合得到的, 由输入层、隐含层和输出层组成。当设定的隐含层节点数大于输

入层节点数时, 加入一定的限制条件, 将大部分节点随机置零, 构成了稀疏自动编码器^[13]。稀疏自动编码器采用无监督学习算法, 一般激活函数为 Sigmoid 函数, 当函数值为 1 时则认为神经元被激活, 反之, 函数值为 0 时神经元被抑制。

令 $W_{ji}^{(l)}$ 为第 l 层第 i 个节点与第 $l+1$ 层第 j 个节点之间的权重, $b_i^{(l)}$ 是第 l 层第 i 个节点的偏置, $z_i^{(l+1)}$ 是第 $l+1$ 层第 i 个节点输入的总加权和, 公式表示为:

$$z_i^{(l+1)} = \sum_{j=1}^{n_l} W_{ji}^{(l)} x_j + b_i^{(l)} \quad (7)$$

式中: n_l 是网络的总层数。

$a_j^2(x)$ 表示输入为 x 时, 隐含层神经元 j 的激活度, 则 j 隐含层神经元平均激活度为:

$$\widehat{\rho}_j = \frac{1}{m} \sum_{i=1}^m [a_j^2(x^{(i)})] \quad (8)$$

为了达到稀疏性, 用最少的隐含单元表示输入层的特征, 使隐含层单元的平均激活度接近于 0。因此, $\widehat{\rho}_j = \rho$, 用 KL 距离表示 $\widehat{\rho}_j$ 偏离 ρ 的情况。

稀疏自动编码器的惩罚函数 $J(W, b)$ 和 KL 相对熵表达式分别为:

$$J(W, b) = [\frac{1}{m} \sum_{j=1}^m |y_j - h_{w,b}(x)|^2] + \frac{1}{\lambda} \sum_{i,j,l} (W_{ji}^{(l)})^2 \quad (9)$$

$$KL(\rho \parallel \widehat{\rho}_j) = \sum_{j=1}^{s_2} \rho \log \frac{\rho}{\widehat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \widehat{\rho}_j} \quad (10)$$

稀疏自编码器的总损失函数为:

$$J_{\text{sparse}}(W, b) = J(W, b) + \beta \sum_{j=1}^{s_2} KL(\rho \parallel \widehat{\rho}_j) \quad (11)$$

稀疏自动编码器对数据具有降维作用, 而且具有良好的特征表达能力。但是单隐含层的稀疏自动编码器在特征学习时不能完全提取到深层次抽象、复杂特征, 为了更好的提取深层图像特征, 构建多隐含层深度稀疏自动编码器。稀疏自动编码器采用非监督贪婪逐层学习^[14], 在特征学习中, 每层隐含层学习到的特征代表一种特征表示, 经过逐层对图像进行特征学习, 实现了特征从形象描述到抽象表示的一种过程。首先要训练深度学习网络, 本文

中稀疏系数 ρ 设为 0.01, 隐含层层数 N 设为 3, 将训练集图像输入到深度稀疏自动编码器中进行训练, 训练步骤为:

- 1) 将训练集作为输入层, 将 $x = h^0$ 作为稀疏自动编码器模型的可视层, 训练出第一层隐含层。
- 2) 用第一层得到的特征作为数据输入到第二层中。
- 3) 利用第2步得到的数据训练第二层隐含层。
- 4) 重复上述 2、3 步骤, 直到训练完所需要的层数。
- 5) 用 BP 算法对网络进行微调, 优化网络的所有参数。

2.2 特征学习

深度学习网络是模拟人类大脑神经系统感知外界信号的层次结构, 经过多层网络的学习, 提取简单的边缘特征以及深层复杂的特征信息。针对单层稀疏自动编码器在特征学习时容易丢失深层特征信息、特征缺乏鲁棒性、图像分类准确率低的缺点。本文构建三隐含层的深度稀疏自动编码器对图像进行特征学习, 并采用 SVM 分类器进行分类, 如图 2 所示。在深度稀疏自动编码器中, 每经过一层隐含层学习到一个特征集 S_i (i 为某一层隐含层), 随着隐含层层数的增多, 提取的特征由模糊、简单的边缘特征向复杂、清晰的深层特征转变。

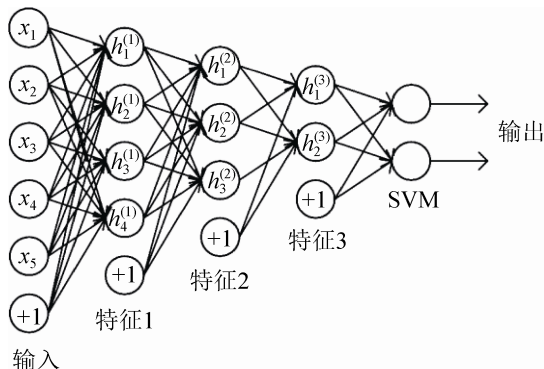


图2 DSAE-SVM(GA)模型
Fig. 2 DSAE-SVM (GA) model

将 MNIST、Caltech-101 数据库输入到本文构建的深度稀疏自动编码器中进行特征学习, 得到

图 3~4 的可视化特征图。图中分别表达了从第一层隐含层大体模糊的轮廓特征到第三层隐含层逐渐清晰、准确的特征。随着层数增加, 提取的特征越精确, 表达的特征越清晰, 越容易分辨图像的特征信息。




图3 MNIST 可视化特征
Fig. 3 MNIST visualization features




图4 Caltech-101 可视化特征
Fig. 4 Caltech-101 visualization features

为了提高特征的识别力, 本文提出了特征集权值重组法, 每层隐含层学习得到特征集 S_i , 根据特征集 S_i 的精确度分配每层的特征权值。分配规则是: 层数值越大, 提取的特征越精确, 分配的特征权值越大, 层数值越小, 提取的特征大多为边缘轮廓等一些模糊的特征, 分配的特征权值越小。根据公式(12)~(13)得到每层特征权值。令第 i 层隐含层得到的特征集在整个深度稀疏自动编码器所占权值为 W_i , 权值 W_i 满足下式:

$$W_i = i \cdot W \quad i = 1, \dots, N \quad (12)$$

$$\sum_{i=1}^N W_i = 1 \quad i = 1, \dots, N \quad (13)$$

深度稀疏自动编码器隐含层作用就像人类大脑的神经元, 学习的层数越多提取的特征越完整、精确。因此, 按照上式, 层数值大的隐含层得到的特征集具有较大权值, 反之则具有较小权值。本文中, 隐含层层数 $N=3$, 因此, 计算可得 $W=1/6$ 。最

后将每层的特征权值和特征集 S_i 重组为一个新的特征集 T 的表达式为:

$$T = \sum_{i=1}^N W_i \cdot S_i \quad i=1, \dots, N \quad (14)$$

2.3 GA-SVM 算法

SVM 是线性可分最优分类面发展来的, 所谓的最优分类面就是要求分类面对所有的样本正确分类的前提下, 满足两类间的分类间隔最大^[15]。根据最大间隔原则, 找出最终决策面, 构造决策函数, 将训练集正确分开。

设 $Y = \{(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i)\}$, 其中 $i=1, \dots, n$ 。 n 维欧式空间中的超平面表示为:

$$Y = \{x \in R^n \mid (w \cdot x) + b = 0\} \quad (15)$$

对应的决策函数为:

$$f(x) = \text{sign}(w \cdot x + b) \quad (16)$$

在样本正确分类的同时保证分类间隔最大, 即 $\|w\|^2$ 最小, 即求解下述优化问题:

$$\Phi(w) = \frac{1}{2} \|w\|^2 \quad (17)$$

$$y_i [(w^f \cdot x_i) + b] - 1 \geq 0 \quad i=1, \dots, n \quad (18)$$

在实际应用中, 往往存在线性不可分或不知道是否线性可分的情况。因此, 引入一个非负松弛变量 $\xi_i (i=1, \dots, n)$ 允许错分样本的存在。所以, 上述问题变为:

$$y_i [(w^f \cdot x_i) + b] - 1 + \xi_i \geq 0 \quad i=1, \dots, n \quad (19)$$

$$\Phi(w) = \frac{1}{2} \|w\|^2 + C \left[\sum_{i=1}^n \xi_i \right] \quad (20)$$

式中: C 为惩罚因子, 表示对错分样本的惩罚程度, C 越大, 对错分样本的惩罚就越大, 且对错分样本的约束程度就越大。

SVM 解决非线性及高维分类问题表现出特有的优势, 具有较高分类准确率。SVM 有三个影响因素: 核函数、核函数参数和惩罚因子, 它们在很大程度上影响 SVM 分类效果, 例如, 如果惩罚参数过高会造成分类器的过学习状态^[16]。因此, 选择合适的函数及参数, 才能获得特定样本中具有最高分类性能的 SVM 分类器。

GA 是一种借鉴生物界进化规律演化而来算法, 是人工智能领域用于解决最优化的搜索启发式算法。GA 作为一种全局寻优算法, 具有强鲁棒性, 其强大的全局搜索能力和并行性搜索方式能在较短时间内选择出最优解, 使种群的个体向着更好的解进化。因此, 本文采用 GA 对 SVM 的参数寻优, 进而提升 SVM 的分类性能。本文 GA 对 SVM 参数寻优的具体步骤如下:

1) 确定种群大小、最大迭代次数等参数, 随机产生初始化种群, 生成种群个体;

2) 将种群中个体基因串解码为相应的核函数、核函数参数及错误惩罚因子, 并带入 SVM 进行训练和测试;

3) 适应度函数计算初始种群中每个个体的适应度值, 本文将测试样本中的 10 折交叉验证 (10-fold cross validation) 的分类准确率作为适应度函数值。并且保留当前种群中最优和最差个体;

4) 判断是否满足终止条件, 若满足则终止迭代, 得到最优个体, 种群选出最优解; 否则, 执行第 5) 步;

5) 执行选择、交叉和变异操作, 采用自适应的交叉变异方法;

6) 计算新生成的子代种群中个体的适应度值, 并保留当前种群中的最优和最差个体;

7) 执行最优保留, 最差替换准则。

3 实验结果与分析

为了验证本文提出的 DSAE-SVM(GA) 算法的有效性, 在 CIFAR-10 和 MNIST 数据库上测试本算法的分类准确率, 并与其他现有方法进行对比。CIFAR-10 数据库是一个普适物体识别的数据库, 有 10 类 32×32 的图像, 50 000 张图像作为训练集, 10 000 张图像作为测试集。MNIST 数据集是手写数字数据库, 包含 10 类共 70 000 张图像, 其中 60 000 张是训练集, 10 000 张是测试集。

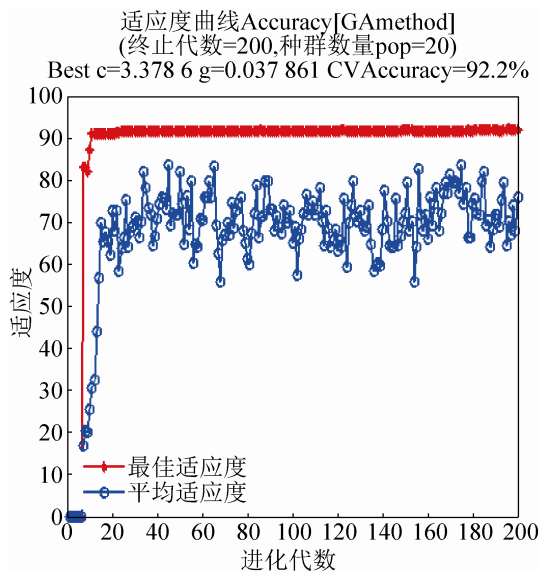
实验采用图 2 所示的三隐含层深度稀疏自动编码器的网络结构。实验所用操作系统为

Windows 7、处理器为 Inter(R) Core(TM)、主频为 2.8 GHz、内存为 16 GB 的计算机，仿真平台为 MATLAB R2014a, SVM 工具箱为台湾林智仁教授提供的 libsvm 工具箱。


3.1 GA-SVM 算法参数寻优

SVM 受到核函数、核函数参数及错误惩罚因子三个影响因子的影响, 本文就核函数参数 γ 及错误惩罚因子 C 数值的变化对 SVM 分类器的影响以及 SVM 最优参数的选择进行研究。为了验证 GA-SVM 算法的参数寻优效果, 在 CIFAR-10、MNIST 两个数据库上进行 SVM 参数寻优的实验。

本文中, 进化代数设为 200, 参数 C 的变化范围设为(0, 100], 参数 γ 的变化范围为(0, 1], 寻优结果如图 5 所示, 图(a)是在 MNIST 数据库上参数寻优结果图, 通过 10 折交叉验证, 当 C 和 γ 取值分别为 3.378 6、0.0378 61 时, 得到最高的交叉验证准确率为 92.2%, 图(b)是在 CIFAR-10 数据库上参数寻优结果图, 通过 10 折交叉验证得到测试精度为 90.566%时, C 和 γ 取值分别为 9.421 4、0.111 68。从两图均可看出种群进化到 10 代左右, 参数开始接近最优。



(a) MNIST 数据库



(b) CIFAR-10 数据库

图 5 GA-SVM 算法在两种数据库上的参数寻优
Fig. 5 Optimization of GA - SVM algorithm on two kinds of database

3.2 GA 对分类准确率的影响

为了进一步分析 GA 对图像分类准确率的影响, 将经过 GA 优化后的 SVM 与未经过 GA 优化的 SVM 进行实验比较。结果如表 1 所示, 从表中可以看出 GA 优化得到的参数应用到 SVM 中, 分类器的分类效果明显优于未经过 GA 优化的 SVM 分类器。因为 GA-SVM 算法能在全局范围内的最短时间搜索到最优参数值, 所以具有较高的优化效率, 提高了 SVM 的泛化能力。因此, 经过 GA 优化参数后的 SVM 分类器从整体上性能优于未经 GA 优化参数的 SVM 分类器, 提高了图像的分类准确率。

表 1 SVM 分类器优化前后的分类率

Tab. 1 Classification accuracies of SVM classifier before and after optimizations

SVM 分类器	CIFAR-10 分类率	MNIST 分类率
SVM 未优化	76.56%	97.19%
SVM 优化	79.25%	99.21%

3.3 特征集权值重组法的作用

单层稀疏自动编码器不易提取到图像抽象特征信息, 为了更好的提取深层图像特征, 本文构建

了多隐含层的深度稀疏自动编码器,逐层对图像进行特征学习,实现了特征从形象描述到抽象表达的一种过程。为了提高图像的特征识别力,提高图像分类率,本文提出特征集权值重组法,为了说明重组法在 DSAE-SVM(GA)算法中的作用,将该方法与各隐含层的特征集进行实验比较。

实验结果如表 2 所示,经过特征学习得到的 S_1 、 S_2 、 S_3 三个特征集与特征集权值重组法得到的新特征集分类准确率进行比较。在本组实验中, MNIST 数据库中所用的 C 和 γ 的最优值分别为 3.378 6、0.0378 61, CIFAR-10 数据库中的 C 和 γ 的最优值分别为 9.421 4、0.111 68。从表中可以看出,随着隐含层层数增多,特征识别率提高,分类效果越好,此外,本文提出的特征集权值重组法的分类准确率高于稀疏自动编码器提取到的单个特征集的分类准确率。

表 2 各特征集的分类率

特征集	CIFAR-10 分类率	MNIST 分类率
S_1	70.19	96.03
S_2	72.98	97.47
S_3	76.56	98.04
$W_1*S_1+W_2*S_2+W_3*S_3$	79.25	99.21

3.4 本文算法与其他已有算法的比较

表 3 是不同方法在 CIFAR-10 数据库上的分类性能比较,在同一设备、同一仿真平台的条件下进行实验。从表中可以看出, DSAE-SVM(GA)在 CIFAR-10 数据库上的分类准确率均高于其他方法的分类准确率,且本方法分类时间均低于其他方法的分类时间。本文方法比文献[7]中方法分类准确率高 3.35%,但分类时间约缩短 4.7 分钟,与文献[8]中方法相比,分类准确率提高 8.14%,分类时间约缩短 3.4 分钟。本文方法与 SAE-SVM、DBN 方法相比,分别提高了 9.36%和 13.64%,因为 DSAE-SVM(GA)是逐层对图像进行特征学习,提出的特征集权值重组法融合了图像不同尺度的特征信息,因此更加准确的反映图像信息,从而具有较好的分类性能。

表 3 现有方法在 CIFAR-10 数据库的分类性能比较

Tab. 3 Classification performance of the CIFAR-10 datasets and comparison with existing methods

分类方法	分类率/%	分类时间/min
CDBN ^[7]	75.90	15.38
SDAE ^[8-9]	71.11	14.03
SAE-SVM	69.89	16.64
DBN	65.61	15.95
DSAE-SVM(GA)	79.25	10.62

表 4 是不同方法在 MNIST 数据库上的分类性能比较,在同一设备、同一仿真平台的条件下进行实验。从表中可以看出,目前分类算法对 MNIST 数据库的图像分类准确率都能达到 97%以上, DSAE-SVM(GA)在 MNIST 数据库上的分类准确率均高于其他方法的分类准确率。本文方法与文献[8]相比,本文方法的分类准确率提高了 0.15%,分类时间约缩短了 2.7 min,比 DBN 方法分类准确率提高了 1.92%,分类时间约缩短了 3.5 min。由于稀疏自动编码器对数据具有降维作用,且遗传算法利用内在并行性,进行分布式计算,加快了求解速度,从而缩短了网络的分类时间。

表 4 现有方法在 MNIST 数据库的分类性能比较

Tab. 4 Classification performance of the MNIST datasets and comparison with existing methods

分类方法	分类率/%	分类时间/min
CDBN ^[7]	99.18	11.08
SDAE ^[8]	99.06	10.52
SAE-SVM	97.69	12.96
DBN	97.29	11.14
DSAE-SVM(GA)	99.21	7.79

综上,与其他各方法比较,本文方法分类性能优于其他方法,实验结果说明了本文提出的 DSAE-SVM(GA)方法的有效性。

4 结论

本文提出的 DSAE-SVM(GA)方法,将基于稀疏自动编码器的特征学习引入到基于支持向量机的分类中,充分发挥两者优点,实现了分类准确率的提升。本文通过构建深度稀疏自动编码器网络,逐层学习特征信息,利用提出的特征集权值重组法

得到新的重组特征集,有效的提高了图像特征识别力。采用遗传算法来优化支持向量机参数,提高了支持向量机的分类性能,高效、准确的完成图像分类。未来的研究工作将进一步对稀疏自动编码器的特征提取进行研究,通过对特征提取算法改进或者改进稀疏自动编码器的网络结构,进一步提高 DSAE-SVM(GA)的分类准确率。

参考文献:

- [1] Xiong M, Chen J, Wang Z, et al. Deep Feature Representation via Multiple Stack AutoEncoders[M]. Advances in Multimedia Information Processing-PCM, 2015: 275-284.
- [2] Chen Kunjin, Hu Jun, He Jinliang, et al. A Framework for Automatically Extracting Overvoltage Features Based on Sparse Autoencoder[J]. IEEE Transactions on Smart Grid (S1949-3053), 2016: 1-1.
- [3] Tao Chao, Pan Hongbo, Li Yansheng, et al. Unsupervised Spectral-Spatial Feature Learning With Stacked Sparse Autoencoder for Hyperspectral Imagery Classification[J]. IEEE Geoscience and Remote Sensing Letters (S1545-598X). 2015: 2438-2442.
- [4] Yin Hongpeng, Jiao Xuguo, Chai Yi, et al. Scene classification based on single-layer SAE and SVM[J]. Expert Systems with Applications (S0957-4174), 2015, 42(7): 3368-3380.
- [5] Esam Othman, Yakoub Bazi, Naif Alajlan, et al. Using convolutional features and a sparse autoencoder for land-use scene classification[J]. International Journal of Remote Sensing (S0143-1161), 2016: 2149-2167.
- [6] Makhzani A, Frey B. Winner-Take-All Autoencoders[J]. Eprint Arxiv(S1049-5258), 2014: 2773-2781.
- [7] H Lee, R Grosse, R Ranganath, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations-[C]// Proceedings of the 26th Annual International Conference on Machine Learning. Canada, 2009: 609-616.
- [8] Pascal Vincent, Hugo Larochelle, Yoshua Bengio, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research (S1532-4435), 2010: 3371-3408.
- [9] Du Bo, Xiong Wei, Wu Jia, et al. Stacked Convolutional Denoising AutoEncoders for Feature Representation[J]. IEEE Transactions on Cybernetics(S2168-2267), 2016: 1-11.
- [10] Pascal Vincent, Hugo Larochelle, Yoshua Bengio, et al. Extracting and composing robust features with denoising autoencoders[C]// Proceedings of the 25th International Conference on Machine Learning, 2008: 1096-1103.
- [11] Chow R, Zhong W, Blackmon M, et al. An efficient SVM-GA feature selection model for large healthcare databases[C]// Genetic and Evolutionary Computation Conference. USA, 2008: 1373-1380.
- [12] Rifai S, Vincent P, Muller X, et al. Contractive Auto-Encoders: Explicit Invariance During Feature Extraction[C]// Proceedings of the 28th International Conference on Machine Learning, 2011: 833-840.
- [13] Ju Y, Guo J, Liu S. A Deep Learning Method Combined Sparse Autoencoder with SVM[C]// International Conference on Cyber-Enabled Distributed Computing and Knowledge Discovery. IEEE, 2015: 257-260.
- [14] Bengio Y, Lamblin P, Popovici D, et al. Greedy layer-wise training of deep networks[C]// Proceedings of the 19th International Conference on Neural Information Processing Systems. Canada, 2007: 153-160.
- [15] Dai C. SVM Visual Classification Based on Weighted Feature of Genetic Algorithm[C]// Sixth International Conference on Intelligent Systems Design and Engineering Applications. IEEE Computer Society, 2015: 786-789.
- [16] Huang C L, Wang C G. A GA-based feature selection and parameters optimization for support vector machines[J]. Expert Systems with Applications (S0957-4174), 2006: 231-240.