

基于低秩自动编码器及高光谱图像的茶叶品种鉴别

孙俊¹ 靳海涛¹ 武小红¹ 陆虎² 沈继锋¹ 戴春霞¹

(1. 江苏大学电气信息工程学院, 镇江 212013; 2. 江苏大学计算机科学与通信工程学院, 镇江 212013)

摘要: 提出一种基于低秩自动编码器及高光谱图像技术的茶叶品种鉴别方法。应用高光谱成像系统采集 5 个品种的茶叶样本高光谱图像数据, 利用 ENVI 软件确定高光谱图像的感兴趣区域 (ROI), 并提取茶叶样本在 ROI 的平均光谱作为该样本的原始光谱数据。由于高光谱信息量大、冗余性强且存在噪声, 运用自动编码器和低秩矩阵恢复结合的低秩自动编码器 (LR-SAE) 对原始光谱数据进行降维, 在自动编码器降维基础上加入去噪处理, 提取鲁棒判别特征。在此基础上应用支持向量机 (SVM) 和 Softmax 分类算法对降维后的茶叶样本高光谱数据分类。通过 5 折交叉试验验证, LR-SAE-SVM 模型的预测集准确率达到 99.37%, SAE-SVM 模型的预测集准确率为 98.82%; LR-SAE-Softmax 模型的预测集准确率达 99.04%, SAE-Softmax 模型的预测集准确率为 97.99%。研究结果表明, 相较于未进行去噪处理的传统自动编码器, LR-SAE 降维之后的分类建模效果有所提升, 将其应用于茶叶品种鉴别是可行、高效的。

关键词: 茶叶; 品种鉴别; 自动编码器; 低秩矩阵恢复; 高光谱; 降维
中图分类号: S126 **文献标识码:** A **文章编号:** 1000-1298(2018)08-0316-08

Tea Variety Identification Based on Low-rank Stacked Auto-encoder and Hyperspectral Image

SUN Jun¹ JIN Haitao¹ WU Xiaohong¹ LU Hu² SHEN Jifeng¹ DAI Chunxia¹

(1. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China

2. School of Computer Science and Telecommunication Engineering, Jiangsu University, Zhenjiang 212013, China)

Abstract: Five different varieties of tea samples were classified with the method combining stacked auto-encoder (SAE) with low-rank matrix recovery (LRMR). The hyperspectral imaging system with spectrum range of 431 ~ 962 nm was used to collect five kinds of tea samples containing 618 bands of hyperspectral images, including Huangshan green tea, Longjing, Yixing Mao Feng, Yunwu green tea and Biluochun. The ENVI software was used to determine the region of interest (ROI) of the hyperspectral images, and the average spectral data of the sample in ROI were extracted as the raw spectral information of the sample. Due to the large amount, strong redundancy and much noise of the hyperspectral information, the low-rank stacked auto-encoder (LR-SAE), which combined the stacked auto-encoder and the low-rank matrix recovery, was used to reduce the dimensionality of the hyperspectral data of the tea samples. Support vector machine (SVM) and Softmax classification model were applied to identify the tea samples after dimensionality reduction. The 5-fold cross validation experiment results showed that the accuracy of prediction set of LR-SAE-SVM model was 99.37%, and that of SAE-SVM model was 98.82%. As for Softmax classification, the accuracy of prediction set of LR-SAE-Softmax model was 99.04%, and that of SAE-Softmax model was 97.99%. The results showed that the accuracy of the classification model based on LR-SAE was improved on some degree and the LR-SAE had better robustness than the traditional SAE without de-noising. It was feasible and efficient to apply the classification model based on LR-SAE into tea variety identification.

Key words: tea; variety identification; stacked auto-encoder; low-rank matrix recovery; hyperspectral; dimensionality reduction

收稿日期: 2018-02-25 修回日期: 2018-04-16
基金项目: 国家自然科学基金项目 (31471413)、江苏高校优势学科建设工程项目 (苏政办发 (2011) 6 号)、江苏省六大人才高峰项目 (ZBZZ-019) 和江苏大学大学生科研立项项目 (Y15A038)
作者简介: 孙俊 (1978—), 男, 教授, 博士生导师, 主要从事计算机技术在农业工程中的应用研究, E-mail: sun2000jun@ujs.edu.cn

0 引言

茶叶以其清热、解毒等功效深受广大消费者喜爱^[1-2],但目前茶叶市场存在以次充好的现象,严重损害消费者权益,也影响经营者的管理,因此,有效、准确的茶叶品种鉴别是十分有必要的^[3]。传统的鉴别方法主要是感官判别法和化学试验分析法,这些方法主观性较强、破坏性大、不易推广^[4]。视觉图像技术^[5]可以通过外部特征进行茶叶品种鉴别,但该方法无法获取茶叶内部的特征信息^[6];光谱技术^[7]因能检测样品内部特征信息,且具有速度快、成本低等优点在农副产品品种鉴别领域得到广泛关注,但光谱技术在处理数据时缺少样本的空间信息,这两种技术的侧重点不同,所带来的局限性必然会影响最终的鉴别效果。因此,如何结合各种鉴别手段,提高茶叶品种鉴别的精度是一个新的研究方向。

高光谱图像技术作为一种快速无损检测的方法,将图像技术和光谱技术结合,融合两种技术的优势,对研究对象的内外部特征同时进行检测,近些年已被广泛应用于农副产品的定性分析中^[8-11]。然而,因为高光谱数据量庞大,波段繁多,且相邻波段间相关性强^[12],所以对数据进行降维处理显得极其重要。随着深度学习技术的发展^[13-15],自动编码器(Stacked auto-encoder,SAE)通过输出对输入的重构从而对高维数据进行特征学习,该技术已被推广到图像处理、数据分类的应用场合中^[16-17],与高光谱图像技术的结合也越来越受到关注。

但是,高光谱图像在获取过程中不可避免地受到各种干扰,例如高斯白噪声、稀疏的冲击噪声、坏死的线条等^[18-19]。这不仅使图像的视觉效果变差,更对高光谱图像的实际应用造成很大的影响。因此对高光谱图像进行去噪处理^[20-21]至关重要。传统的自动编码器也常被应用于降噪处理,降噪自动编码器(DAE)^[22-23]假设训练数据是干净的,它所针对的噪声是人为添加来训练的。然而,受噪声影响的真实数据是不符合上述假设的。因此,从实际的

已被破坏的数据中学习深层特征,对于构建鲁棒的特征提取器来说是非常关键的。就目前所知,这种基于自动编码器的深度学习方案以前并没有被讨论过。

近几年来,低秩矩阵恢复(Low-rank matrix recovery,LRMR)的方法被引入到高光谱图像恢复领域中,取得较好的效果。LU 等^[24]采用低秩矩阵恢复的方法去除高光谱图像中的坏死线噪声,考虑局部的几何结构并添加了图的正则化;ZHANG 等^[25]基于低秩矩阵恢复的方法较为成功地去除了高光谱图像的混合噪声,其正是得益于无噪的高光谱图像数据低秩的特性。由于这些技术的优点,低秩矩阵恢复已经成功地应用于不同的场景,例如多视点学习、转移学习和字典学习^[26-27]。然而,并没有相关文献将低秩矩阵恢复与深度学习框架联系起来。

为更加有效地进行茶叶高光谱图像品种鉴别,本文联合优化自动编码器和低秩矩阵恢复,构建低秩自动编码器(LR-SAE),在自动编码器的降维基础上加入去噪处理,提取高光谱数据鲁棒判别特征,建立茶叶品种的鉴别模型。

1 材料与方法

1.1 材料准备

试验前于镇江某大型超市购买 5 个不同品种的绿茶:炒青茶(安徽黄山)、龙井茶(浙江)、毛峰(江苏宜兴)、云雾绿茶(浙江)、碧螺春(江苏苏州),样本如图 1 所示。每种茶叶取 80 个样本,分别放入广口试剂瓶中,并贴上标签,共计 400 个样本。将其密封保存立即送往高光谱实验室进行高光谱图像采集。

1.2 高光谱数据采集及处理

本试验所采用的高光谱成像系统结构如图 2 所示,主要包括光纤、2 个光纤卤素灯(2900 型, Illumination Technologies, USA)、高光谱图像摄影仪(ImSpector V10E, Spectral Imaging Ltd., Oulu, Finland)、移动平台控制器(北京光学仪器厂,中国)和处理器等部分。高光谱图像摄影仪中的摄像机为




图 1 茶叶样本
Fig. 1 Tea samples






图 2 高光谱成像系统结构图

Fig.2 Configuration diagram of hyperspectral imaging system
1. 移动平台控制器 2. 高光谱图像摄影仪 3. 光纤 4. 卤素灯
光源 5. 处理器 6. 样本 7. 移动平台



(a) 感兴趣区域提取



(b) 感兴趣区域光谱提取

图 3 感兴趣区域提取与分析

Fig.3 Extraction and analysis of region of interest

高光谱图像数据的采集使用 Spectral cube 软件平台 (Spectral Imaging Ltd. , Finland) ;ROI 提取采用 ENVI. 5.1 (Research System, Inc. , USA) ;最终试验模型训练是在 CPU 为 Intel Core i5 3230M 2.60 GHz、内存为 8 GB 的 Windows 10 系统下,利用 Matlab R2014b 软件完成的。

1.3 低秩自动编码器

1.3.1 SAE 深度模型

自动编码器 (AE) 自 RUMELHART 等^[28] 初次使用之后,就广泛应用于特征学习。自动编码器主要由编码器和解码器两部分构成,在对输入数据进行学习时,其目的是通过编码和解码将输入数据在输出中重构出来。从某种程度而言,AE 是一个小型的深度学习模型,该模型主要包括输入层、隐含层和输出层 3 部分。

假设无标签训练样本 x ,自动编码器的编码任务是将输入的训练样本通过非线性映射函数映射到隐含层,其数学表达式为

$$h=f(x)=s_f(\mathbf{W}x+\mathbf{b}_h)$$
 (1)

式中 h ——隐含层激活值
 s_f ——编码激活函数
 $\mathbf{W}$ ——输入层与隐藏层之间的权值矩阵

CCD 相机,光谱仪为可见-近红外光谱仪,光谱范围为 431 ~ 962 nm,光谱分辨率为 2.9 nm,图像分辨率为 1 628 像素 × 1 125 像素。

采用直径 6.4 cm、高 0.7 cm 的塑料圆形器皿均匀放置茶叶样品,将圆形器皿放置在移动速度为 2.1 mm/s 的移动平台上进行数据采集,将光源与样本距离设置为 6 cm,相机镜头距样本 12 cm。

感兴趣区域 (ROI) 是样本图像中选取分析的重点区域,感兴趣区域的选取对后续的试验质量至关重要。如图 3a 所示,为系统扫描得到的茶叶样品高光谱图像,本文统一提取高光谱图像中心区域 100 像素 × 100 像素部分为感兴趣区域。图 3b 为茶叶样本高光谱数据。

$\mathbf{b}_h$ ——输入层与隐藏层之间的偏移向量

自动编码器的解码任务是将激活值 h 逆向转换成对输入 x 的重构 y ,其数学表达式为

$$y=g(h)=s_g(\mathbf{W}'h+\mathbf{b}_y)$$
 (2)

式中 y ——激活值反向变换成对原始输入的重构
 s_g ——解码激活函数

$\mathbf{W}'$ ——隐含层与输出层之间的权值矩阵

$\mathbf{b}_y$ ——隐含层与输出层之间的偏移向量

平均重构函数为

$$L=\|x-y\|^2$$
 (3)

通过不断修改参数来最小化平均重构函数 L 。对于最小平均重构 L , y 就可以被认为保留了原始数据的大部分信息^[29]。

实际应用中,多采用包含多个隐含层的自动编码器网络进行数据处理,即堆叠自动编码器 (SAE)。通过引入神经网络天然的非线性,SAE 更适用于高光谱数据处理等非线性任务。

1.3.2 低秩矩阵恢复

当高光谱图像受到高斯白噪声的微小扰动时,含噪的高光谱数据 $\mathbf{Y} \in \mathbf{R}^{n \times b}$ 可以分解成一个低秩的矩阵 $\mathbf{X}$ 和一个微小扰动的矩阵 $\mathbf{E}$,低秩矩阵恢复的目的就是以一种最优手段将 $\mathbf{Y}$ 分解出含尽量少噪

声的 $\mathbf{X}$ 和噪声矩阵 $\mathbf{E}$ 。

当矩阵 $\mathbf{E}$ 服从独立同分布的高斯分布时,可用经典主成分分析通过奇异值分解来完成数据降维^[25],即求解优化问题

$$\begin{cases} E_{\min} = \min_{\mathbf{X}, \mathbf{E}} \|\mathbf{E}\|_F \\ \text{s. t. } \begin{cases} r(\mathbf{X}) \leq r(\mathbf{Y}) \\ \mathbf{Y} = \mathbf{X} + \mathbf{E} \end{cases} \end{cases} \quad (4)$$

式中 $E_{\min}$ ——矩阵 $\mathbf{E}$ 的最小范数

$\|\cdot\|_F$ ——矩阵范数 $r(\cdot)$ ——矩阵的秩

然而,当数据中存在比较大的噪声或异常时, $\mathbf{E}$ 的元素为任意大小,此时主成分分析的效果不够准确。针对这种情况,恢复低秩矩阵 $\mathbf{X}$ 成为一个双目标优化问题。

$$\begin{cases} E_{0\min} = \min_{\mathbf{X}, \mathbf{E}} (r(\mathbf{X}), \|\mathbf{E}\|_0) \\ \text{s. t. } \mathbf{Y} = \mathbf{X} + \mathbf{E} \end{cases} \quad (5)$$

式中 $\|\cdot\|_0$ ——矩阵 0 范数,为矩阵中非零元素的个数

$E_{0\min}$ ——矩阵 $\mathbf{E}$ 的最小 0 范数

通过引入折中因子 λ ,并对目标函数进行松弛,将双目标优化问题转换为单目标问题

$$\begin{cases} E_{1\min} = \min_{\mathbf{X}, \mathbf{E}} \|\mathbf{X}\|_* + \lambda \|\mathbf{E}\|_1 \\ \text{s. t. } \mathbf{Y} = \mathbf{X} + \mathbf{E} \end{cases} \quad (6)$$

式中 $E_{1\min}$ ——矩阵 $\mathbf{E}$ 的最小 1 范数

$\|\cdot\|_*$ ——矩阵核范数,为矩阵奇异值之和

$\|\cdot\|_1$ ——矩阵 1 范数,为矩阵元素绝对值之和

式(6)也称鲁棒主成分分析法^[30],使用增广的拉格朗日乘子法^[31] (Augmented Lagrange multipliers, ALM)解决上述优化问题,先将其转换为等价问题

$$\begin{aligned} L(\mathbf{X}, \mathbf{E}, \mathbf{Y}, \mu) &= \|\mathbf{X}\|_* + \lambda \|\mathbf{E}\|_1 + \\ &\langle \mathbf{D}, \mathbf{Y} - \mathbf{X} - \mathbf{E} \rangle + \mu \|\mathbf{Y} - \mathbf{X} - \mathbf{E}\|_F^2 / 2 \end{aligned} \quad (7)$$

式中 $L(\cdot)$ ——拉格朗日函数

$\mathbf{D}$ ——拉格朗日算子

μ ——惩罚因子

当 $\mathbf{D} = \mathbf{D}_k, \mu = \mu_k$,使用交替式方法解决优化问题 $\min_{\mathbf{X}, \mathbf{E}} L(\mathbf{X}, \mathbf{E}, \mathbf{Y}, \mu)$ 。

1.3.3 低秩自动编码器模型

本文结合低秩矩阵恢复的去噪优势和自动编码器的降维优势,构建了低秩自动编码器模型,在自动编码器的降维基础上,添加了去噪处理。该模型的训练步骤如下:

(1)采用低秩矩阵恢复的方法,对提取出的 ROI 中的高光谱数据进行 LR 分解,得到一个低秩矩阵 $\mathbf{X}$ 和一个稀疏矩阵 $\mathbf{E}$, $\mathbf{X}$ 是进行去噪处理后的

目标矩阵, $\mathbf{E}$ 是噪声矩阵。

(2)初始化自动编码器网络中权值矩阵 $\mathbf{W}$ 、偏移量 $\mathbf{b}$ 、动量 $\mathbf{m}$ 等模型参数,将低秩矩阵 $\mathbf{X}$ 作为输入进行降维训练,降低到一个较低维度。

(3)用 5 折交叉验证的方法将降维后的数据以 4:1 的比例分成训练集和预测集输入到分类器中,进行品种鉴别。

(4)以最终的预测集准确率为依据,对自动编码器网络中 $\mathbf{W}$ 、 $\mathbf{b}$ 等参数寻优,寻找自动编码器最优参数。

整个算法模型构建算法流程图如图 4 所示。




图 4 算法流程图

Fig. 4 Flow chart of algorithm

1.4 基于线性核函数的支持向量机分类算法

支持向量机(SVM)算法^[32]作为一种经典的分类算法,被广泛应用在高光谱图像的分类中,其主要思想是作一个非线性映射 $F(x)$,将输入数据空间映射到高维空间,通过寻找一个最优分离曲面,使得两类数据的间隔尽可能大,以完成分类任务。在进行训练时,要挑选合适的核函数 $K(x, y) = (F(x), F(y))$,同时,对于样本集 $(\mathbf{X}, \mathbf{Y})$,设置合适的惩罚系数 c 和径向量函数 g ,可以获得优化问题的最优解。

本文结合 SVM 算法和低秩自动编码器算法,将低秩自动编码器处理后的低维高光谱数据采用 5 折交叉验证方法进行交叉验证,以 4:1 的比例分为训练集和预测集,然后和 5 个茶叶样本的标签集构建分类模型进行分类试验。由于本试验样本较少,基于线性核函数的 SVM 模型效果更优,采用灰狼优化算法对 SVM 分类器效果影响较大的参数 c 和 g 的设置进行优化,以期得到最优 SVM 分类模型。

1.5 基于 Softmax 模型分类算法

Softmax 回归是逻辑回归的推广,逻辑回归是处

理二分类问题的,而 Softmax 回归是用来处理多分类问题的^[33]。它是一种监督模型,表示为逻辑回归函数的形式^[34]为

$$f_w(z) = \frac{1}{1 + \exp(-\mathbf{H}^T z)} \quad (8)$$

式中 $\mathbf{H}$ ——激活函数

z ——用自动编码器模型提取出的特征表示
经低秩自动编码器提取的特征输入 Softmax 模型。利用有监督学习获取参数,完成模型的构建,通过分类试验对模型的参数进行微调,得到较优模型。

2 结果与分析

2.1 高光谱特征降维

通过软件 ENVI 5.1 计算 ROI 内各个像素点的反射率,并求其平均值作为每个样本的反射率,据此绘得 5 种茶叶样本的原始光谱曲线,如图 5 所示。不同品种的茶叶样本内部的有效成分(如氨基酸、多酚类和植物碱等)的含量与比例存在差异^[35],这些有效成分大多存在含氢基团(C—H、O—H 和 N—H 等),能在某些特定波长下产生倍频和合频吸收,表现为对光的吸收强度不同,即表现为不同的反射率^[10],在波长为 600 nm 左右和 760 nm 左右处的波峰来看,这种差异尤其明显。




图 5 5 种茶叶样本原始光谱曲线

Fig.5 Raw spectral curves of five kinds of tea samples

对每种茶叶样品的反射率求平均值,得到 5 种茶叶样本的平均光谱曲线如图 6 所示,在 2 个波峰




图 6 5 种茶叶样本平均光谱曲线

Fig.6 Average spectral curves of five kinds of tea samples

处光谱曲线有明显的可分辨性,为茶叶品种鉴别提供了依据。

在茶叶样本高光谱数据分类之前,要对其进行去噪和降维处理。本文采用改进后的低秩自动编码器对高光谱数据进行特征学习,提取低维特征,试验中发现,SAE 的深度、规模等参数都会对其最终的特征学习结果产生影响。本次试验以分类准确率为标准,选取 SAE 网络层数和规模 2 个影响较大的因子进行对比,通过结果的分析来确定最佳参数的设置。本试验中自动编码器的激活函数为 sigmoid 函数,学习率设置为 0.2,由于 SAE 需将输入数据降低到一个较低维度,所以将 SAE 第 1 个隐含层神经元个数设置为 300,第 2 个隐含层神经元个数从 1 取到 300,得出最终的训练集和预测集准确率如图 7a 所示,结果显示,当第 2 个隐含层神经元个数为 193 时,预测集准确率最高为 98.59%。增加 SAE 隐含层数量,用同样的方法在后续增加 SAE 隐含层训练,以最终预测集准确率为标准寻找最优的隐含层神经元个数,结果如图 7b~7d 所示。

每次增加 SAE 隐含层数量,训练获得最优隐含层神经元个数,其对应的训练集准确率和预测集准确率如表 1 所示。

由此可见,预测集准确率并未随着网络层数的增加而提高,当 SAE 隐含层个数为 3,网络规模为 [618-300-193-56] 时,同时,原始高光谱波段数为 618,经过 SAE 特征提取,特征数为 56,SAE-SVM 模型最终预测集准确率达到最大 98.82%,降维效果明显。继续增加隐含层个数,提高了网络复杂度,加大了训练成本,然而最终提取输出的特征数差别并不大,且最终预测集准确率有减小的趋势,故本文选择 4 个自动编码器进行堆叠级联为 SAE,应用于最终模型。

2.2 分类结果验证

根据 SAE、LR-SAE、SAE-LR(对 SAE 输出层进行低秩矩阵恢复处理)降维模型处理之后的低维特征高光谱数据,采用 5 折交叉验证的方法,分别采用 SVM 分类器和 Softmax 回归模型进行分类建模,得出训练集和预测集的准确率如表 2 所示。

首先采用 SAE 对高光谱数据进行降维,对得到的低维特征数据分别应用 SVM 和 Softmax 分类器建模,经过灰狼优化算法,最优 $c = 33.86$,最优 $g = 0.86$,SAE-SVM 模型预测集分类准确率最高为 98.82%,同时,SAE-Softmax 模型预测集分类准确率为 97.99%,较高的分类效果说明了采用深度学习自动编码器模型对于高光谱数据的高效特征提取能力。




图 7 低秩自动编码器降维结果

Fig. 7 Results of dimension reduction with LR-SAE

表 1 低秩自动编码器优化参数

Tab.1 Optimized parameters of LR-SAE

隐含层个数	神经元最优个数	模型规模	训练集准确率/%	预测集准确率/%
2	193	[618-300-193]	99. 23	98. 59
3	56	[618-300-193-56]	99. 88	98. 82
4	37	[618-300-193-56-37]	99. 82	98. 33
5	27	[618-300-193-56-37-27]	99. 56	96. 87

注:模型规模表示 SAE 各层神经元个数,如[618-300-193]表示输入层有 618 个神经元,该网络包含的 2 个隐含层神经元个数分别是 300、193,并以最后一个隐含层作为整个网络的输出。

表 2 各模型分类结果

Tab.2 Results of each model classification

降维算法	分类器	参数优化	模型规模	训练集准确率/%	预测集准确率/%
SAE	SVM	$c = 33.86, g = 0.86$	[618-300-193-56]	99. 30	98. 82
	Softmax		[618-300-292-151]	99. 06	97. 99
LR-SAE	SVM	$c = 42.50, g = 1.56$	[618-300-193-31]	99. 75	99. 37
	Softmax		[618-300-292-266]	99. 37	99. 04
SAE-LR	SVM	$c = 28.57, g = 1$	[618-300-193-266]	98. 87	98. 53
	Softmax		[618-300-292-271]	98. 26	96. 55

从 2 个分类器角度分析,对于 SVM 分类器来说,经过 SAE 降维处理之后,高光谱数据由 618 维降到 56 维,最终训练集准确率为 99.30%,预测集准确率为 98.82%,而经过 LR-SAE 降维之后,高光谱数据由 618 维降到 31 维,维度更低,最终训练集准确率高达 99.75%,预测集准确率高达 99.37%,与 SAE 降维后的数据分类准确率相比,LR-SAE 处理过后的数据的分类准确率有一定的提升,验证了去噪处理的有效性,通过低秩矩阵恢复的处理,提取了原始高光谱数据的低秩少噪声甚至无噪声的鲁棒

特征。

对于 Softmax 回归模型而言,SAE 降维之后的预测集准确率为 97.99%,而应用改进之后的 LR-SAE 降维之后的预测集准确率高达 99.04%,从另一个角度验证了 LR-SAE 降维模型去噪处理的有效性。

同时,无论是 SVM 分类器,还是 Softmax 回归模型,与对 SAE 输入层进行低秩矩阵恢复处理的效果相比,对 SAE 输出层进行低秩矩阵恢复处理的效果略差,这是由于经过 SAE 降维后的数据中,数据的

物理意义弱化,信号与噪声的界限没有原始数据那么明显。

3 结 束 语

以茶叶品种鉴别为研究背景,针对高光谱数据信息量大、维度高的问题,本文提出了一种新的高光谱数据降维方法,该方法应用深度学习中的自动编码器模型,将其处理非线性数据的优势应用于高光谱数据的降维中,结合低秩矩阵恢复,建立了低秩自动编码器(LR-SAE)降维模型。首先采用SAE、LR-SAE和SAE-LR模型分别对茶叶高光谱数据进行降

维,在得到的低维特征的基础上分别建立SVM和Softmax分类模型,对5个茶叶品种进行分类。试验结果显示,低秩自动编码器处理高光谱数据,将最初的618维数据降低到较低维度,并将获得的低维特征用于分类建模,LR-SAE-SVM预测集分类准确率达99.37%,LR-SAE-Softmax预测集分类准确率达99.04%,效果优于改进前的SAE算法。改进之后的低秩自动编码器为高光谱数据的降维提供了一种更加高效的方法,尤其是对于含噪声较大的高光谱数据,对高光谱图像分类来说具有重要的实际意义。

参 考 文 献

1 武斌,崔艳海,武小红,等. 一种广义噪声聚类的红外光谱茶叶品种鉴别研究[J]. 光谱学与光谱分析, 2016, 36(7):2094 – 2097.
WU Bin, CUI Yanhai, WU Xiaohong, et al. Discrimination of tea varieties by using infrared spectroscopy with a novel generalized noise clustering[J]. Spectroscopy and Spectral Analysis, 2016, 36(7):2094 – 2097. (in Chinese)

2 于英杰,王琼琼,王冰玉,等. 基于高光谱技术的铁观音茶叶等级判别[J]. 食品科学, 2014, 35(22):159 – 163.
YU Yingjie, WANG Qiongqiong, WANG Bingyu, et al. Identification of Tieguanyin tea grades based on hyperspectral technology [J]. Food Science, 2014, 35(22):159 – 163. (in Chinese)

3 李清光,李晓钟,钟芳. 基于矿质元素含量和支持向量机的茶叶鉴别分析[J]. 江苏大学学报(自然科学版), 2011, 32(6):636 – 641.
LI Qingguang, LI Xiaozhong, ZHONG Fang. Identification of tea based on mineral content and support vector machines [J]. Journal of Jiangsu University(Natural Science Edition), 2011, 32(6):636 – 641. (in Chinese)

4 陆江锋,单春芳,洪小龙,等. 基于数字图像的茶叶形状特征提取及不同茶叶鉴别研究[J]. 茶叶科学, 2010, 30(6):453 – 457.
LU Jiangfeng, SHAN Chunfang, HONG Xiaolong, et al. Shape extraction and varietal discrimination of tea based on digital image [J]. Journal of Tea Science, 2010, 30(6):453 – 457. (in Chinese)

5 徐海卫,胡长安,汤江文,等. 基于机器视觉的神经网络在茶叶鉴别中的应用[J]. 中国测试, 2014, 40(3):89 – 92.
XU Haiwei, HU Chang'an, TANG Jiangwen, et al. Application of BP neural network in classification of fresh tea grade based on machine vision[J]. China Measurement & Test, 2014, 40(3):89 – 92. (in Chinese)

6 陆江锋,单春芳,裴正军. 茶叶外形特征数字化及不同等级茶叶鉴别研究[J]. 现代农机, 2015(3):49 – 51.

7 廖步岩. 近红外光谱技术在茶叶鉴别中的应用研究[D]. 合肥:安徽农业大学, 2009.
LIAO Buyan. Application of near infrared spectroscopy in tea identification[D]. Hefei: Anhui Agricultural University, 2009. (in Chinese)

8 廖建尚,王立国,郝思媛. 结合 Beltrami 流和递归滤波的高光谱图像分类方法[J/OL]. 农业机械学报, 2018, 49(1):42 – 50. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180105&journal_id=jcsam. DOI:10. 6041/j. issn. 1000-1298. 2018. 01. 005.
LIAO Jianshang, WANG Liguo, HAO Siyuan. Hyperspectral image classification method combined Beltrami flow and recursive filter[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(1):42 – 50. (in Chinese)

9 孙俊,路心资,张晓东,等. 基于高光谱图像的红豆品种 GA-PNN 神经网络鉴别[J/OL]. 农业机械学报, 2016, 47(6): 215 – 221. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160628&journal_id=jcsam. DOI:10. 6041/j. issn. 1000-1298. 2016. 06. 028.
SUN Jun, LU Xinzi, ZHANG Xiaodong, et al. Identification of red bean variety with probabilistic GA-PNN based on hyperspectral imaging[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(6):215 – 221. (in Chinese)

10 马惠玲,王若琳,蔡骋,等. 基于高光谱成像的苹果品种快速鉴别[J/OL]. 农业机械学报, 2017, 48(4):305 – 312. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170440&journal_id=jcsam. DOI:10. 6041/j. issn. 1000-1298. 2017. 04. 040.
MA Huiling, WANG Ruolin, CAI Cheng, et al. Rapid identification of apple varieties based on hyperspectral imaging[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(4):305 – 312. (in Chinese)

11 DJOKAM M, SANDASI M, CHEN W, et al. Hyperspectral imaging as a rapid quality control method for herbal tea blends[J]. Applied Sciences, 2017, 7(3):268.

12 孙俊,金夏明,毛罕平,等. 基于高光谱图像光谱与纹理信息的生菜氮素含量检测[J]. 农业工程学报, 2014, 30(10): 167 – 173.
SUN Jun, JIN Xiaming, MAO Hanping, et al. Detection of nitrogen content in lettuce leaves based on spectroscopy and texture using hyperspectral imaging technology[J]. Transactions of the CSAE, 2014, 30(10):167 – 173. (in Chinese)

13 LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436 – 444.

14 余永维,杜柳青,闫哲,等. 基于深度学习特征的铸件缺陷射线图像动态检测方法[J/OL]. 农业机械学报, 2016,

- 47(7):407–412. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160755&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2016.07.055.
- YU Yongwei, DU Liuqing, YAN Zhe, et al. Dynamic detection of casting defects radiographic image based on deep learning feature[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(7):407–412. (in Chinese)
- 15 谭文学, 赵春江, 吴华瑞, 等. 基于弹性动量深度学习神经网络的果体病理图像识别[J/OL]. 农业机械学报, 2015, 46(1):20–25. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20150104&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.01.004.
- TAN Wenxue, ZHAO Chunjiang, WU Huarui, et al. A deep learning network for recognizing fruit pathologic images based on flexible momentum[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(1):20–25. (in Chinese)
- 16 HASSAIRI S, EJBALI R, ZAIED M. A deep stacked wavelet auto-encoders to supervised feature extraction to pattern classification[J]. Multimedia Tools & Applications, 2018, 77(5):5443–5459.
- 17 SUK H I, LEE S W, SHEN D. Latent feature representation with stacked auto-encoder for AD/MCI diagnosis[J]. Brain Structure & Function, 2015, 220(2):841–859.
- 18 俞珍秒, 杨明. 一种结合空间相似性和 RPCA 的高光谱图像去噪算法[J]. 南京大学学报(自然科学版), 2017, 53(3):518–524.
- YU Zhenmiao, YANG Ming. A hyperspectral image denoising method using spatial similarity and RPCA[J]. Journal of Nanjing University(Natural Sciences), 2017, 53(3):518–524. (in Chinese)
- 19 YANG J, ZHAO Y Q, CHAN C W, et al. Coupled sparse denoising and unmixing with low-rank constraint for hyperspectral image[J]. IEEE Transactions on Geoscience & Remote Sensing, 2016, 54(3):1818–1833.
- 20 薛志祥, 余旭初, 谭熊, 等. 局部超图拉普拉斯约束的高光谱影像低秩表示去噪方法[J]. 光学学报, 2017, 37(5):77–85.
- XUE Zhixiang, YU Xuchu, TAN Xiong, et al. Local hypergraph Laplacian regularized low-rank representation for noise reduction of hyperspectral images[J]. Acta Optica Sinica, 2017, 37(5):77–85. (in Chinese)
- 21 ZHU R, DONG M, XUE J H. Spectral Nonlocal restoration of hyperspectral images with low-rank property[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 8(6):3062–3067.
- 22 王宪保, 何文秀, 王辛刚, 等. 基于堆叠降噪自动编码器的胶囊缺陷检测方法[J]. 计算机科学, 2016, 43(2):64–67.
- WANG Xianbao, HE Wenxiu, WANG Xin'gang, et al. Capsule defects detection based on stacked denoising Auto-encoders[J]. Computer Science, 2016, 43(2):64–67. (in Chinese)
- 23 张素智, 魏萍萍, 徐家兴. 面向聚类的堆叠降噪自动编码器的特征提取研究[J]. 现代计算机, 2016(33):3–8.
- ZHANG Suzhi, WEI Pingping, XU Jiaying. Research on the feature extraction of clustering based on denoising Autoencoders[J]. Modern Computer, 2016(33):3–8. (in Chinese)
- 24 LU X, WANG Y, YUAN Y. Graph-regularized low-rank representation for destriping of hyperspectral images[J]. IEEE Transactions on Geoscience & Remote Sensing, 2013, 51(7):4009–4018.
- 25 ZHANG H, HE W, ZHANG L, et al. Hyperspectral image restoration using low-rank matrix recovery[J]. IEEE Transactions on Geoscience & Remote Sensing, 2014, 52(8):4729–4743.
- 26 HE W, ZHANG H, ZHANG L, et al. Total-variation-regularized low-rank matrix factorization for hyperspectral image restoration[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 54(1):178–188.
- 27 LIU G, LIN Z, YAN S, et al. Robust recovery of subspace structures by low-rank representation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 35(1):171–184.
- 28 RUMELHART D E, HINTON G E, WILLIAMS R J. Learning internal representations by error propagation[R]. LaJolla: University of California Institute for Cognitive Sciences, Report 8506, 1985.
- 29 BALDI P. Autoencoders, unsupervised learning and deep architectures[C]//International Conference on Unsupervised and Transfer Learning Workshop, 2011:37–50.
- 30 杨国亮, 王艳芳, 丰义琴, 等. 基于加权 RPCA 的非局部图像去噪方法[J]. 计算机工程与设计, 2015(11):3035–3040.
- YANG Guoliang, WANG Yanfang, FENG Yiqin, et al. Nonlocal image denoising method based on weighted RPCA[J]. Computer Engineering and Design, 2015(11):3035–3040. (in Chinese)
- 31 LIN Z, CHEN M, MA Y, et al. The augmented Lagrange multiplier method for exact recovery of corrupted low-rank matrices[J]. Eprint Arxiv, 2010:1–22.
- 32 郑一力, 钟刚亮, 王强, 等. 基于多特征降维的植物叶片识别方法[J/OL]. 农业机械学报, 2017, 48(3):30–37. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20170304&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2017.03.004.
- ZHENG Yili, ZHONG Gangliang, WANG Qiang, et al. Method of leaf identification based on multi-feature dimension reduction[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(3):30–37. (in Chinese)
- 33 林少飞, 盛惠兴, 李庆武. 基于堆叠稀疏自动编码器的手写数字分类[J]. 微处理机, 2015(1):47–51.
- LIN Shaofei, SHENG Huixing, LI Qingwu. Handwritten digital classification based on the stacked sparse Autoen-coders[J]. Microprocessors, 2015(1):47–51. (in Chinese)
- 34 PELLEGRINI T. Comparing SVM, Softmax, and shallow neural networks for eating condition classification[C]//Interspeech, 2015.
- 35 陈全胜, 赵杰文, 蔡健荣, 等. 利用高光谱图像技术评判茶叶的质量等级[J]. 光学学报, 2008, 28(3):669–674.
- CHEN Quansheng, ZHAO Jiewen, CAI Jianrong, et al. Estimation of tea quality level using hyperspectral imaging technology[J]. Acta Optica Sinica, 2008, 28(3):669–674. (in Chinese)