

基于短波近红外高光谱和深度学习的籽棉地膜分选算法

倪超¹ 李振业¹ 张雄¹ 赵岭² 朱婷婷¹ 蒋雪松¹

(1. 南京林业大学机械电子工程学院, 南京 210037; 2. 聊城大学机械与汽车工程学院, 聊城 252000)

摘要: 采用膜下滴灌棉花种植模式,在机械采摘过程中地膜易混入籽棉,对后续棉花加工影响极大。地膜无色透明且无荧光效应,常规方法很难识别。为了解决地膜的分选问题,提出一种基于短波近红外高光谱和深度学习的籽棉地膜分选算法。首先,针对高光谱图像中地膜与非地膜像素点光谱特征区分不明显的问题,利用堆叠自适应加权自编码器逐层提取与输出相关的低维非线性高阶特征;然后,将此高阶特征作为分类器的输入,采用粒子群优化的极限学习机实现初步分类;最后,对分类结果进行类型合并,运用形态学方法以及连通域分析,剔除误识别区域,得到优化后的地膜分类结果。经仿真试验及现场测试,算法对地膜识别率达到95.5%,地膜选出率达95%,满足实际生产需求。

关键词: 籽棉; 地膜; 短波近红外高光谱成像; 分选; 自适应加权自编码器; 极限学习机

中图分类号: O657.33; TP391.41 **文献标识码:** A **文章编号:** 1000-1298(2019)12-0170-10

Film Sorting Algorithm in Seed Cotton Based on Near-infrared Hyperspectral Image and Deep Learning

NI Chao¹ LI Zhenye¹ ZHANG Xiong¹ ZHAO Ling² ZHU Tingting¹ JIANG Xuesong¹

(1. College of Mechanical and Electronic Engineering, Nanjing Forestry University, Nanjing 210037, China

2. College of Mechanical and Automotive Engineering, Liaocheng University, Liaocheng 252000, China)

Abstract: As the main cotton-producing province in China, Xinjiang has widely applied film-covering technology. In the process of cotton mechanical picking, a large amount of film is also collected along with the seed cotton. If the film could not be thoroughly separated, it would be subsequently transformed into the ginned cotton together, which would reduce the quality of the textile. However, it is difficult to identify the film by using traditional methods, because the film is colorless and transparent without fluorescent effect. In order to detect the film covering the seed cotton, a novel algorithm was proposed based on shortwave near-infrared hyperspectral imaging and deep learning. Firstly, considering the advantage of multi-channel and model complexity, the variable-wise weighted autoencoder was developed to weight hyperspectral image channel and transform them into low-dimension feature. Comparing with selecting one or deleting some channels directly, VW-AE was used to achieve information that was more useful and less influence on the negative feature. Then, several variable-wise weighted autoencoders were stacked layer by layer to form deep networks, and a two-layer neural network combined with the BP algorithm was used to update the deep network weights. Next, the high-level features from the deep network were set as the inputs of an extreme learning machine (ELM) whose parameters were determined by a particle swarm optimization method. Finally, the classification results of the ELM were merged into film and non-film two classes by morphology and connected domain technologies. Simulation experiments and a field test were carried out to evaluate the performance of the proposed algorithm. The results showed that the recognition rate of the presented algorithm was up to 95.5% and the separating rate of the film was 95%, which met the actual production requirements.

Key words: seed cotton; film; shortwave near-infrared hyperspectral imaging; sorting; variable-wise weighted autoencoder; extreme learning machine

收稿日期: 2019-08-15 修回日期: 2019-09-28

基金项目: 江苏省“六大人才高峰”项目(013040315)和中国纺织工业联合会科技指导性项目(2017107)

作者简介: 倪超(1979—),男,副教授,博士,主要从事图像处理与模式识别研究,E-mail: chaoni@njfu.edu.cn

0 引言

采用地膜覆盖技术以及机械化采摘技术进行棉花种植,极大地提高了生产效率。然而在籽棉机械采摘过程中容易混杂大量地膜残片,如清理不彻底,则随着加工环节进入皮棉,极大地影响纺织品质量^[1-2]。目前,地膜残片是国内机采棉与进口棉在质量上存在差距的重要原因,严重阻碍了国内机采棉的加工、收储和销售,导致纺织企业在选择棉花时首选进口棉、再选手摘棉、慎选国内机采棉的局面。因此,地膜清理是新疆棉花产业亟待解决的技术难题^[3]。

目前,常用的地膜清除设备根据其基本原理可分为 3 类:①利用机械缠绕方法^[4-5]清理籽棉中的地膜,该方法精度不高,无法清除小尺寸的地膜。②利用籽棉与残膜不同的荷电特性^[6-7]、采用静电吸附的方法实现籽棉残膜的分离,该方法受外部不确定因素影响较多,难以长期稳定可靠运行。③基于机器视觉的方法,部分学者^[8-10]利用 CCD 相机获取棉流图像,实现了有色塑料膜的检测,但对于无色透明薄地膜尚未实现有效识别。

随着近红外高光谱技术发展,JIANG 等^[11]尝试采用近红外高光谱技术检测棉花中的杂质,特别是短波近红外高光谱技术的应用^[12-14],使得塑料膜的检出率相比常规方法有明显的提高。高光谱成像技术是基于非常多窄波段的影像数据技术,样本成像的同时能够获得样本的图像信息与光谱信息^[15]。常用的高光谱数据处理方法包括偏最小二乘法(Partial least squares, PLS)^[16]、支持向量机(Support vector machine, SVM)^[17]和人工神经网络(Artificial neural network, ANN)^[18]。PLS 能描述光谱和数据之间的线性关系,在光谱领域被广泛使用。SVM 具有较强的泛化能力和自学习能力,适用于小数据集分析^[19]。ANN 能够建立非线性关系,通常认为 ANN 是一种浅层学习方法,对于简单模型有效,但难以用于复杂系统^[20]。多层深度神经网络可用来提取高阶非线性特征,但在实际应用中,其训练过程需要大量已标记数据。文献[21]提出新的深度神经网络训练方法,首先对神经网络进行逐层预训练,然后在此基础上对整个深度神经网络进行有监督的微调,最终能够显著提高分类预测精度。深度学习能有效地提取复杂任务的高阶非线性特征^[22],在许多领域取得了令人满意的成果^[23-24]。卷积神经网络(Convolutional neural network, CNN)和堆叠自编码器(Stacked autoencoder, SAE)是深度学习中两种常用模型。CNN 通常被用于实现二维图像的分类。

SAE 是深度学习的一种模型,文献[25-26]尝试将其用于高光谱数据的特征提取和降维,取得了很好的分类效果。

本文提出一种基于短波近红外高光谱和深度学习的籽棉地膜分选算法。首先,对自适应加权堆叠自编码器(Variable-wise weighted stacked autoencoder, VW-SAE)进行预训练,逐层提取与输出相关的高阶特征,在预训练之后将两层 ANN 连接到 VW-SAE 上进行有监督的微调,获得优化后的高阶特征;然后,采用粒子群优化(Particle swarm optimization, PSO)的极限学习机(Extreme learning machine, ELM)作为特征分类器,实现地膜的初步分类;最后,将初步分类结果合并为地膜和非地膜两类,再运用形态学处理和连通域分析去除误识别区域,得到地膜分类结果,确定地膜在图像中的坐标,最终输出到剔除装置,实现地膜分选。

1 材料与分选系统

1.1 材料

新疆生产建设兵团农一师某棉花加工厂提供大约 10 kg 来自南疆地区的机采籽棉,该公司熟练工人从籽棉中挑选地膜残片,最终选出 49 片大小不同的地膜。地膜、籽棉以及混合物被投入籽棉地膜分选系统,总计采集到 107 幅 384 像素×210 像素×288 像素(宽×高×谱段)高光谱图像构建为数据集。地膜与籽棉的实物图像如图 1 所示,由于地膜是无色透明的,在可见光下地膜与籽棉难以区分。



图 1 地膜与籽棉的实物图像
Fig. 1 Image of film and seed cotton

1.2 分选系统

籽棉地膜分选系统主要由配棉箱、输送带、穹顶卤素灯、高光谱成像仪、高速喷阀、工控机、驱动箱、废料收集箱、伺服电机与编码器和风机组成,如图 2 所示。首先籽棉被放入进棉口自由下落进入配棉箱,配棉箱中装有的多层梳棉装置实现籽棉的开松,

使得籽棉中的地膜充分暴露,此后籽棉团被摊铺成单层籽棉下落到输送带。输送带为黑色橡胶材质,带宽 1 m,作为高光谱成像的使用背景,能有效减少反射,由伺服电机以 1 m/s 的速度驱动。




图2 籽棉地膜分选系统示意图

Fig. 2 Schematic of film sorting system of seed cotton

1. 配棉箱 2. 进棉口 3. 输送带 4. 穹顶卤素灯 5. 高光谱相机 6. 高速喷阀 7. 工控机 8. 驱动箱 9. 籽棉收集箱 10. 废料收集箱 11. 伺服电机与编码器 12. 风机 13. 籽棉 14. 地膜

高光谱成像系统位于输送带正上方,利用芬兰 SPECIM 公司 SWIR3 系列的高速高光谱相机获取高光谱图像,分辨率 384 像素 × 210 像素,光谱范围为 1 000 ~ 2 500 nm,有 288 个谱段。相机配有 15 mm 镜头,其视场为 1 m。相机配备 2 条线性穹顶卤素光源实现场景的照射,穹顶光源能实现 360° 无死角照射,避免棉流高低起伏的影响。工控机配有图像采集卡,通过 Camera - Link 线与高光谱相机相连。编码器的输出脉冲触发相机拍摄,从而实现相机与输送带的同步,在输送带速度为 1 m/s 时相机帧率大约 384 f/s。剔除装置位于输送带的正前方,48 个高速喷阀排成一列与输送带对齐,每个喷阀的喷嘴直径大约 20.8 mm。在通常情况下,籽棉由于惯性的作用能够飞过废料收集箱的入口到达籽棉收集箱;相反零散孤立的地膜由于质量轻、空气阻力大,当飞到废料收集箱入口时受到负压的作用将会被吸入废料收集箱。一旦工控机在采集的高光谱图像中识别出地膜,其将延时计数,当地膜运动到喷嘴正下方时,给驱动箱发出相应喷阀驱动信号,电磁阀打开,地膜在一吹一吸的作用下进入废料收集箱,最终实现籽棉中地膜的分选。

2 籽棉地膜分选识别算法

籽棉地膜分选识别算法包括高光谱图像黑白校正、基于深度学习的地膜初分类和分类结果的后处理 3 部分,如图 3 所示。

2.1 高光谱图像黑白校正

由于光照角度、强度、相机中暗电流影响,高光




图3 分选算法结构图

Fig. 3 Structure chart of sorting algorithm

谱图像存在很多噪声,需要对光谱图像进行校正,图像校正公式为

$$I_{ref} = \frac{I_{raw} - I_{dark}}{I_{white} - I_{dark}} \quad (1)$$

式中 I_{ref} ——校正后的图像

I_{raw} ——原始图像

I_{white} ——白板校正图像

I_{dark} ——黑板校正图像

高光谱图像黑白校正可以消除图像中的大部分噪声,有助于提高后续模型的分类识别精度。

2.2 基于深度学习的地膜初步分类

2.2.1 自适应加权自编码器

自编码器 (Autoencoder, AE) 的基本结构是一个具有一个隐层的无监督神经网络,它由输入层、隐层和输出层组成,如图 4 所示^[27]。AE 是为了在输出层中尽可能精确地重建原始输入。




图4 AE 的典型结构

Fig. 4 Typical structure of AE

定义输入 $\mathbf{x} = (x_1, x_2, \dots, x_d)'$, 其中 d 是输入层的维数,编码器通过函数 f 将 $\mathbf{x}$ 映射到隐层 $\mathbf{h} = (h_1, h_2, \dots, h_{d_h})'$, d_h 为隐层向量 $\mathbf{h}$ 的维数,即

$$\mathbf{h} = f(\mathbf{x}) = S_f(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (2)$$

式中 $\mathbf{W}$ —— $d_h \times d$ 维的矩阵

$\mathbf{b}$ ——偏置向量

S_f ——非线性激活函数,可以是 sigmoid 函数、tanh 函数、ReLU 函数等

然后隐含层 $\mathbf{h}$ 通过函数 $\tilde{f}$ 映射到输出层 $\tilde{\mathbf{x}}$,即

$$\tilde{\mathbf{x}} = \tilde{f}(\mathbf{h}) = S_{\tilde{f}}(\tilde{\mathbf{W}}\mathbf{h} + \tilde{\mathbf{b}}) \quad (3)$$

式中 $\widetilde{W}$ —— $d \times d_h$ 维的矩阵

$\widetilde{b}$ ——输出层的偏置向量

$S_{\widetilde{f}}$ ——解码器的非线性激活函数

自编码器的目标是找到参数集 $\theta = \{W, \widetilde{W}, b, \widetilde{b}\}$ 满足方程 $\hat{x} = \hat{f}(h) = \hat{f}(f(x)) \approx x$ 。

定义输入 $X = (x_1, x_2, \dots, x_N)$ ，其中 N 是训练样本数，且 $x_i = (x_{i1}, x_{i2}, \dots, x_{id})$ 是第 i 个样本的数据。损失函数定义为

$$J(W, \widetilde{W}, b, \widetilde{b}) = \frac{1}{2N} \sum_{i=1}^N \|x_i - \hat{x}_i\|^2 = \frac{1}{2N} \sum_{i=1}^N \sum_{j=1}^d (x_{ij} - \hat{x}_{ij})^2 \quad (4)$$

通常使用梯度下降算法更新参数集 $\theta = \{W, \widetilde{W}, b, \widetilde{b}\}$ ，使得损失函数尽可能小。尽量使每个变量准确从而保证整体的损失函数最小。然而在光谱分析领域并非所有的波长变量对输出都同样重要，某些波长变量甚至可能对结果产生负面影响。波长选择可以消除具有负面影响的波长，但是仍然存在一些缺点^[28]。首先，具有高噪声的波长范围可能携带对于预测有用的相关信息，简单地删除这些波长将在一定程度上破坏模型的多通道优势。其次，一些波长整体可能代表相似的数据结构，选择单个波长可能导致有用信息的丢失。自适应加权方法的基本思想是分配连续的非负值给波长而不是消除不重要的波长，因此该方法能够保留隐藏在噪声中的有用信息，保持多通道优势，给负面特征赋以小的甚至为 0 的权重来减少负面特征的影响。本文采用一种自适应加权自编码器^[29]（Variable weighted autoencoder, VW-AE）去提取高阶特征的同时实现数据的降维。VW-AE 基本结构如图 5 所示。该方法修改后的损失函数为

$$J_{\lambda}(W, \widetilde{W}, b, \widetilde{b}) = \frac{1}{2N} \sum_{i=1}^N \sum_{j=1}^d \lambda_j (x_{ij} - \hat{x}_{ij})^2 \quad (5)$$

其中

$$\lambda_{(j)} = \frac{|C_{(j)}| - |C|_{\min}}{|C|_{\max} - |C|_{\min}} \quad (6)$$

$$\begin{cases} C_{(j)} = \frac{\sum_{i=1}^N (x_{ij} - \bar{x}_j)(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_{ij} - \bar{x}_j)^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \\ |C|_{\min} = \min |C_j| \\ |C|_{\max} = \max |C_j| \end{cases} \quad (7)$$

式中 λ_j ——第 j 个变量的权重
 C_j ——第 j 个变量的相关系数

$\bar{x}_j, \bar{y}$ ——第 j 个变量的均值

$Y = (y_1, y_2, \dots, y_N)$ 是和输入 X 相关的输出变量。在式(5)中，与输出高度相关的变量被赋予很大的权重。通过对 VW-AE 的训练，可以使与输出相关变量的重构精度更加准确，隐层的特征与输出更加相关。本文将多个 VW-AE 叠加，形成具有多个隐层的深度神经网络，即构成 VW-SAE 使其更适合处理高光谱数据中复杂的非线性关系。




图 5 VW-AE 的基本结构

Fig. 5 Basic structure of VW-AE

2.2.2 粒子群优化的极限学习机

ELM 与常规分类算法相比具有泛化能力强、学习速度快等优点，有学者将其用于高光谱图像分类^[30-32]，效果优于其他分类算法。ELM 通常使用单层前馈网络，基本结构包括输入层、隐层和输出层，如图 6 所示。




图 6 ELM 的典型结构

Fig. 6 Typical structure of ELM

对于一个单隐层神经网络，假设有 N 个任意的样本 (X_i, t_i) ，其中 $X_i = (x_{i1}, x_{i2}, \dots, x_{in})^T$ ， $t_i = (t_{i1}, t_{i2}, \dots, t_{im})^T$ 。一个有 L 个隐节点的单隐层神经网络可以表示为

$$\sum_{i=1}^L \beta_i g(W_i X_j + b_i) = o_j \quad (j = 1, 2, \dots, N) \quad (8)$$

式中 W_i ——输入权重 $g(x)$ ——激活函数

β_i ——输出权重 o_j ——第 j 个输出

b_i ——第 i 个隐层单元的偏置

单隐层神经网络学习的目标是使得输出的误差最小，可以表示为

$$\sum_{j=1}^N \|o_j - t_j\| = 0 \quad (9)$$

即存在 β_i, W_i 和 b_i ，使得

$$\sum_{i=1}^L \beta_i g(W_i X_j + b_i) = t_j \quad (j = 1, 2, \dots, N) \quad (10)$$

用矩阵可表示为

$$\mathbf{H}\boldsymbol{\beta}=\mathbf{T} \tag{11}$$

其中 $\mathbf{H}(W_1, \cdots, W_L, b_1, \cdots, b_L, X_1, \cdots, X_L) =$

$$\begin{bmatrix} g(W_1X_1+b_1) & \cdots & g(W_LX_1+b_L) \\ \vdots & & \vdots \\ g(W_1X_N+b_1) & \cdots & g(W_LX_N+b_L) \end{bmatrix}_{N \times L} \tag{12}$$

$$\boldsymbol{\beta}=\begin{bmatrix} \beta_1 \\ \vdots \\ \beta_L \end{bmatrix}_{L \times m} \tag{13}$$

$$\mathbf{T}=\begin{bmatrix} T_1 \\ \vdots \\ T_N \end{bmatrix}_{N \times m} \tag{14}$$

式中 $\mathbf{H}$ ——隐层节点的输出
 $\boldsymbol{\beta}$ ——输出权重 $\mathbf{T}$ ——输出期望

在 ELM 算法中,一旦输入权重 W_i 和隐层的偏置 b_i 确定,则隐层的输出矩阵 $\mathbf{H}$ 能唯一确定,训练单隐层神经网络可以转换求解线性系统 $\mathbf{H}\boldsymbol{\beta}=\mathbf{T}$,并且输出权重可以确定为

$$\hat{\boldsymbol{\beta}}=\mathbf{H}^+\mathbf{T} \tag{15}$$

式中 $\mathbf{H}^+$ ——矩阵 $\mathbf{H}$ 的广义逆

由于 ELM 的权值和偏置随机确定,精度较差,本文采用 PSO 优化 ELM 的权重和偏置,具体算法步骤参见文献[33]。

2.2.3 基于 VW-SAE 和 ELM 的分类模型

为了识别籽棉中的地膜,提出了一种基于 VW-SAE 和 PSO 优化的 ELM 的分类模型,简称 VW-SAE-PSO-ELM,模型的网络结构如图 7 所示。




图 7 分类模型的网络结构
Fig. 7 Network structure of classification model

具体步骤如下:

(1)将多个 VW-AE 层层叠加,形成深度神经网络。深度神经网络可以将复杂的输入数据转换为一系列简单的高阶特征,从而降低输入数据的维数。第 1 层 VW-AE 进行无监督训练。训练完成后,放弃解码器,将隐层的输出作为第 2 层 VW-AE 的输

入,方式相同,直到所有编码器都训练完成。在对所有的 VW-AE 进行逐层训练之后,这些 VW-AE 的权重被用来初始化深度神经网络。最顶层的隐层输出高光谱图像数据的初始高阶特征。

(2)为了更好地表现输入数据的特征,采用有监督的方法对权重进行微调。在最顶层后增加两层 ANN,该网络的输出为目标输出。然后利用 BP 算法对权重进行逐层更新,得到微调的权重,提高网络性能。最后获得优化后的高阶特征。

(3)将此优化后的高阶特征输入到 ELM 中构建分类模型,模型采用 PSO 算法选择合适的分类参数。

2.3 分类结果的后处理

本文分类模型输出为 4 类:背景、背景上的地膜、籽棉和籽棉上的地膜,然而剔除装置在实现喷阀逻辑时只需地膜的空间坐标位置。因此将初分类结果由 4 类合并为地膜和非地膜两类。合并完成后得到地膜和非地膜二值化图像,受到噪声、光照以及尘土等因素的影响,存在部分误识别的区域,容易造成喷阀误打击,影响分选效果。

首先运用形态学方法对二值化图像进行开运算操作,消除误识别的伪影以及部分小噪声区域。采用 5×5 的全 1 矩阵 $\mathbf{B}$ 对图像 $\mathbf{A}$ 进行开运算操作,运算定义为

$$\mathbf{AB}=(\mathbf{A}\ominus\mathbf{B})\oplus\mathbf{B} \tag{16}$$

其中 $\ominus$ 和 $\oplus$ 分别表示腐蚀和膨胀。

经形态学处理后,仍存在部分噪声区域未被消除。继而采用 two-pass 算法^[34]对图像进行四邻域连通域分析,通过选取合适的面积阈值,剔除面积小于阈值的连通域,得到地膜分类结果,从而确定地膜在图像中的坐标,输出到剔除装置实现地膜分选。

3 结果与讨论

3.1 光谱分析

选择 4 类样本:背景、背景上的地膜、籽棉和籽棉上的地膜,每类样本分别随机选取 50 个样本,其光谱反射图如图 8 所示。从图 8 可以得出,在整个光谱区域内,由于透明薄膜的弱反射特性,背景和背景上的地膜两类样本,籽棉和籽棉上的地膜两类样本反射率非常相近,从而导致后续识别相对困难;由于受到籽棉与背景反射率差异的影响,背景上的地膜和籽棉上的地膜光谱谱线差异很大,因此初步分类时将两者归为两类样本;籽棉上的地膜和背景上的地膜均在 1 740 nm 和 2 350 nm 有较明显的吸收峰,与文献[35]结论一致,可作为地膜识别的依据。




图 8 光谱反射曲线

Fig. 8 Spectral reflection curves

3.2 分类模型的参数设置

为了构建和测试分类模型,将 107 幅图像随机划分,其中 21 幅作为训练集,86 幅作为测试集,并根据每个像素的光谱反射曲线,人工将图像中所有像素点标记为 4 类:背景、背景上的地膜、籽棉和籽棉上的地膜。将高光谱图像中的每个像素点对应的 288 维数据作为一个样本,为保持各类样本数目均衡,找出训练集中样本数最少的标记类别,然后随机抽取数量相同的其他类别样本,最终选取 331 224 个训练样本,每类样本数为 82 806。

通过训练样本确定模型的各项参数设置,包括隐层数目和每个隐层的神经元数目以及模型权重和偏置。先给定隐层数目和隐层的神经元数目,随机产生模型权重和偏置,以均方根误差作为性能评价指标,采用逐层预训练技术和梯度下降算法更新每层 VW - AE 的权重和偏置,并通过十折交叉验证法来确定模型的参数。在每层 VW - AE 训练完成后,将两层神经网络连接到 VW - SAE 的编码器输出部分对网络进行整体微调。

经多次试验,分类模型由 3 层 VW - AE 组成,神经元个数分别为 144、72、36,采用 sigmoid 作为激活函数,可获得较为理想的分类结果。图 9 为在 Batch Size 设置为 1 000 的情况下每个 VW - AE 的训练误差与迭代次数的关系,可以看出,3 个 VW - AE 模型都可以在 200 次迭代内快速收敛。因此迭代训练次数设置为 200。




图 9 VW - AE 的迭代损失函数曲线

Fig. 9 Iterative loss function curves of VW - AE

最后 ELM 隐层神经元个数设定为 14,激活函数为 sigmoid,利用 PSO 算法对 ELM 进行权重和偏置的优化,实现样本的初步分类。

3.3 性能测试与讨论

以 intel i7 CPU 和 Nvidia RTX2080Ti GPU 计算机为平台,测试所提出的分类算法性能。试验时的计算机运行在 Linux 系统下,主频 2.6 GHz,内存 32 GB,显存 11 GB,软件环境为 TensorFlow - gpu 1.1.0、Keras 2.2.2、cuda8.0、cudnn6.0,采用 python3.6 编程语言。

为了验证本文所提出的 VW - SAE - PSO - ELM 算法的性能,使用不同算法对籽棉高光谱图像数据进行分类,对准确性与实时性进行比较分析。对比算法包括 PLS、SVM、ANN、VW - SAE - ELM、SAE - ELM、VW - SAE - ANN、SAE - ANN,其中,ANN 隐层节点数分别设置为 144、72、36、20,VW - SAE 和 SAE 网络结构相同,节点个数分别为 144、72、36,VW - SAE - ANN 和 SAE - ANN 模型中的 ANN 为 2 层结构,节点数为 20、10。每种算法采用相同的训练集,由十折交叉验证法选取参数。

表 1 是各类算法的混淆矩阵,主对角线显示了各类算法对每类样本的平均识别率。表中第 1 行是模型分类的结果,第 2 列是实际的标签。PLS 的分类效果最差,这是因为 PLS 是线性分类器,难以处理高光谱数据中复杂的非线性关系;SVM 与 ANN 的分类效果相近,略逊于基于 SAE 的分类模型,均优于 PLS 线性分类器;VW - SAE - ELM/ANN 在识别背景上的地膜时明显优于 SAE - ELM/ANN,说明 VW - SAE 模型对于高光谱数据有着优异的特征提取能力,更适用于高光谱数据的特征降维;尽管 ELM (SAE - ELM、VW - SAE - ELM) 的分类精度低于 ANN (SAE - ANN、VW - SAE - ANN),但经过 PSO 优化后的 ELM 分类模型取得了最优分类效果。

从表 1 可得出,背景上的地膜容易错分成背景,这是由于地膜的弱反射特性,光线直接透过薄膜被黑色背景吸收,几乎没有产生反射,所以这些样本在光谱图像中与背景相似,难以区分。背景错分为背景上的地膜是因为训练过程中的背景数据较为理想,而测试时部分背景样本沾染了杂质,与训练样本存在一定的差异,又恰好与背景上的地膜特性类似,因此被错分为背景上的地膜。籽棉与籽棉上的地膜也存在相似的情况。

为了更直观地区分分类效果,将高光谱数据与算法分类结果转换成伪彩色图。试验时棉花未铺满输送带,故从伪彩色图中截取了一幅完整的棉花图像,结果如图 10 所示,图像尺寸为 115 像素 × 199 像素

表 1 验证集预测结果的混淆矩阵

Tab.1 Confusion matrix of predicting outcome on validation set

算法	类别	1	2	3	4	算法	类别	1	2	3	4
VW - SAE - PSO - ELM	1	0.99	0.01	0	0	SAE - ELM	1	0.92	0.08	0	0
	2	0.05	0.95	0	0		2	0.13	0.84	0	0.03
	3	0	0.01	0.97	0.02		3	0	0.02	0.92	0.06
	4	0	0	0.04	0.96		4	0	0.04	0.06	0.90
VW - SAE - ANN	1	0.96	0.04	0	0	ANN	1	0.91	0.09	0	0
	2	0.06	0.93	0	0.01		2	0.11	0.89	0	0
	3	0	0.01	0.96	0.03		3	0	0.02	0.90	0.08
	4	0	0	0.04	0.96		4	0	0.07	0.03	0.90
VW - SAE - ELM	1	0.94	0.06	0	0	SVM	1	0.95	0.05	0	0
	2	0.08	0.91	0	0.01		2	0.16	0.75	0	0.09
	3	0	0.01	0.95	0.04		3	0	0.01	0.93	0.06
	4	0	0	0.05	0.95		4	0	0	0.04	0.96
SAE - ANN	1	0.92	0.08	0	0	PLS	1	0.90	0.10	0	0
	2	0.10	0.88	0	0.02		2	0.18	0.79	0	0.03
	3	0	0.02	0.94	0.04		3	0	0.03	0.54	0.43
	4	0	0.04	0.04	0.92		4	0	0.07	0.03	0.90

注:类别 1. 背景,类别 2. 背景上的地膜,类别 3. 籽棉,类别 4. 籽棉上的地膜。

(宽×高)。图 10a 是高光谱数据伪彩色图。图 10b 是按照光谱反射曲线人工标记的图像,图中数字标记了 5 处地膜,其中 1、2 保存完好没有风化,3、4、5 已风化且部分沾染泥土杂质。由于风化的地膜和未风化的地膜两者光谱反射曲线没有明显的差距,故人工标记时地膜风化情况不做区分,只按背景上的地膜和籽棉上的地膜进行标记。

从分类结果看,图 10 的分类结果与表 1 数据相符合。对于黑色背景,各类算法分类效果均较好,但都存在将小块背景识别成背景上的地膜的错误;对于保存完好没有风化的地膜,如果其是籽棉上的地膜,那么各类算法都可以取得较好的分类效果,反之

如果是背景上的地膜,只有本文提出的 VW - SAE - PSO - ELM 算法识别错误最少,其他算法都容易误分为背景;对于已风化的地膜,如果其位于籽棉上,基于 VW - SAE 的算法效果优于其他算法,不易错分为籽棉;如果位于背景上,VW - SAE - PSO - ELM 与 VW - SAE - ANN 分类错误最少,其他算法容易误分为背景上的地膜或籽棉上的地膜;对于籽棉,在与背景的交界处各类算法误分成了背景上的地膜,这是因为边缘像素点中包含了背景与籽棉的反射光谱,算法出现了误判,另外由于风化地膜吸收峰很弱,籽棉与位于籽棉上的风化地膜特征区分不明显,各类算法容易将籽棉误分为籽棉上的地膜,其中




图 10 分类结果的伪彩色图
Fig.10 Pseudo-color image of classification results

PLS 分类效果最差,本文提出的 VW - SAE - PSO - ELM 算法效果最好。

各类算法图像识别时间和对地膜平均识别准确率如表 2 所示,其中地膜平均识别率是背景上的地膜和籽棉上的地膜两类样本识别率的平均值。从表 2 可以看出,PLS、SVM 的识别时间,地膜平均识别准确率均不佳;相比于其他 ELM (VW - SAE - ELM、SAE - ELM) 算法,本文提出的算法在保证识别时间的同时,提高了地膜的识别率;相比于其他 ANN (ANN、VW - SAE - ANN、SAE - ANN) 算法,本文算法不仅在分类精度上有一定的提高,而且缩短

表 2 模型执行时间和识别准确率

Tab.2 Running time and recognition rate of model

算法	执行时间/ms	识别准确率/%
VW - SAE - PSO - ELM	518.7	95.5
VW - SAE - ELM	518.7	93.5
SAE - ELM	518.7	87.0
VW - SAE - ANN	806.4	94.5
SAE - ANN	806.4	90.0
ANN	806.4	89.5
SVM	861.0	85.5
PLS	924.0	84.5




图 11 分类结果的后处理图像

Fig. 11 Post-processing of classification results

算法的实际效果,在新疆生产建设兵团农一师某棉花加工厂进行现场试验,图 12 为现场试验图,其中图 12a 红色圈内是分选机器,图 12b 红色圈出了棉流中的地膜,图 12c 是经过机器分选后干净的籽棉,图 12d 是选出的地膜杂质。经过反复测试在产量 3 t/h 时,地膜选出率达 95% ,满足设计要求。



图 12 现场试验图

Fig. 12 Pictures of field tests

了识别时间。

综合上述分析,选定 VW - SAE - PSO - ELM 算法作为最终的分类模型。考虑到剔除装置在实现喷阀逻辑时只需地膜的空间坐标位置,因此首先将初分类结果由 4 类合并为地膜和非地膜 2 类,即将背景上的地膜和籽棉上的地膜归类为地膜、背景和籽棉归类为非地膜。合并后得到地膜和非地膜的二值化图像,如图 11b 所示。受噪声、光照以及尘土等因素的影响,存在部分误识别的微小区域,容易造成喷阀误打击,影响分选效果。运用形态学方法对二值化图像进行开运算操作,消除误识别的小区域和图像边缘的伪影,结果如图 11c 所示。可以看出,经过形态学处理,还存在部分相对较大的噪声区域未被消除。再对图像进行连通域分析,按连通域面积设定阈值,面积大小设为 10,剔除小于 10 的连通域,得到最终的地膜分类结果,如图 11d 所示,与图 11a 人工标记图得到的标准二值化图像比较,识别准确率达到 96%。最后将地膜在图像中的坐标传输给剔除装置实现地膜分选。

为了验证本文提出的 VW - SAE - PSO - ELM

4 结束语

提出了一种基于近红外高光谱和深度学习的籽棉地膜分选算法。采用高光谱成像系统获取籽棉 1 000 ~ 2 500 nm 的高光谱数据,并运用深度学习中的自编码器模型对高光谱数据进行特征提取和降维,解决了高光谱数据信息量大、维度高的问题;引入自适应加权方法,降低了高光谱数据噪声的影响,保持高光谱数据多通道的优势;以 ELM 作为分类器,实现对样本的快速四分类(背景、背景上的地膜、籽棉、籽棉上的地膜),并利用 PSO 优化 ELM 模型参数,提高算法分类精度;完成初步分类后,通过形态学开运算处理和连通域分析,得到地膜分类结果,可以直接用于地膜剔除。试验表明,算法对地膜的识别准确率达 95.5%。在新疆农一师某棉花加工厂进行现场测试,产量 3 t/h 时,地膜选出率达 95%。

参 考 文 献

- [1] 叶戡春. 棉纺企业对棉花质量的需求[J]. 中国纤检, 2018, 37(1): 24-29.
YE Jianchun. Cotton spinning enterprises' demand for cotton quality [J]. China Fiber Inspection, 2018, 37(1): 24-29. (in Chinese)
- [2] 盖文桥, 徐雷, 丁曰东. 浅析棉花异性纤维形成的原因, 分类, 危害和解决措施[J]. 中国纤检, 2017, 36(9): 85-86.
GAI Wenqiao, XU Lei, DING Yuedong. Analysis of the causes, classification, hazards and solutions of cotton heterogeneous fibers[J]. China Fiber Inspection, 2017, 36(9): 85-86. (in Chinese)
- [3] 孟俊婷, 魏守军, 唐淑荣, 等. 浅析残膜对棉田及棉花产品的危害与风险[J]. 棉花科学, 2014, 36(4): 9-11.
MENG Juntao, WEI Shoujun, TANG Shurong, et al. Analysis of the damage and risk of residual film on cotton fields and cotton products[J]. Cotton Science, 2014, 36(4): 9-11. (in Chinese)
- [4] 李慧, 王昊鹏. 籽棉异性纤维清理机多目标清理自适应控制模型[J]. 农业工程学报, 2015, 31(7): 39-46.
LI Hui, WANG Haopeng. Multi-objective cleaning adaptive control model for seed cotton heterogeneous fiber cleaning machine [J]. Transactions of the CSAE, 2015, 31(7): 39-46. (in Chinese)
- [5] 坎杂, 郭文松, 张若宇, 等. 网状滚筒式机采籽棉残膜分离机的设计[J]. 农业工程学报, 2011, 27(6): 95-99.
KAN Za, GUO Wensong, ZHANG Ruoyu, et al. Design of seed cotton disc residual film separator for mesh drum machine[J]. Transactions of the CSAE, 2011, 27(6): 95-99. (in Chinese)
- [6] 郭淑霞, 坎杂, 张若宇, 等. 机采籽棉残膜静电分离装置分离试验[J]. 农业工程学报, 2011, 27(增刊2): 6-10.
GUO Shuxia, KAN Za, ZHANG Ruoyu, et al. Separation test of electrostatic separation device for seed cotton residual film[J]. Transactions of the CSAE, 2011, 27(Supp. 2): 6-10. (in Chinese)
- [7] 张洪洲, 刘媛杰, 王宪磊, 等. 机采棉残地膜电磁分离规律研究[J]. 农机化研究, 2017, 39(11): 164-168.
ZHANG Hongzhou, LIU Yuanjie, WANG Xianlei, et al. Study on electromagnetic separation law of machine-made cotton residual film[J]. Journal of Agricultural Mechanization Research, 2017, 39(11): 164-168. (in Chinese)
- [8] 季宏斌, 刘培艳, 陈涛. 基于机器视觉技术的机采棉地膜清理机的研制[J]. 中国棉花加工, 2010, 22(6): 28-31.
JI Hongbin, LIU Peiyan, CHEN Tao. The cleaning machine of mulch film in seed cotton based on machine vision technology [J]. China Cotton Processing, 2010, 22(6): 28-31. (in Chinese)
- [9] FANG Jingjing, JIANG Yu, YUE Jun, et al. A hybrid approach for efficient detection of plastic mulching films in cotton[J]. Mathematical and Computer Modelling, 2013, 58(3-4): 834-841.
- [10] ZHAO Xuehua, LI Daoliang, YANY Bo, et al. An efficient and effective automatic recognition system for online recognition of foreign fibers in cotton [J]. IEEE Access, 2016, 4: 8465-8475.
- [11] JIANG Yu, LI Changying. mRMR-based feature selection for classification of cotton foreign matter using hyperspectral imaging [J]. Computers and Electronics in Agriculture, 2015, 119: 191-200.
- [12] ZHANG Mengyun, LI Changying, YANG Fuzeng. Classification of foreign matter embedded inside cotton lint using short wave infrared (SWIR) hyperspectral transmittance imaging[J]. Computers and Electronics in Agriculture, 2017, 139: 75-90.
- [13] ZHANG Ruoyu, LI Changying, ZHANG Mengyun, et al. Shortwave infrared hyperspectral reflectance imaging for cotton foreign matter classification[J]. Computers and Electronics in Agriculture, 2016, 127: 260-270.
- [14] 郭俊先, 李雪莲, 黄华, 等. 基于可见短波近红外高光谱图像的梳棉杂质关键波长的优选[J]. 新疆农业科学, 2016, 53(2): 352-358.
GUO Junxian, LI Xuelian, HUANG Hua, et al. Optimization of key wavelengths of carding impurities based on visible short-wave near-infrared hyperspectral image [J]. Xinjiang Agricultural Sciences, 2016, 53(2): 352-358. (in Chinese)
- [15] DAMIEN E, BENJAMIN D, VINCENT B, et al. Quantification of leghaemoglobin content in pea nodules based on near infrared hyperspectral imaging spectroscopy and chemometrics[J]. Journal of Spectral Imaging, 2018, 7: 1-10.
- [16] 王海江, 刘凡, YUNGER J A, 等. 不同粒径处理的土壤全氮含量高光谱特征拟合模型[J/OL]. 农业机械学报, 2019, 50(2): 195-204.
WANG Haijiang, LIU Fan, YUNGER J A, et al. Fitting model of soil total nitrogen content in different soil particle sizes using hyperspectral analysis[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(2): 195-204. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20190222&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2019.02.022. (in Chinese)
- [17] 岳学军, 凌康杰, 洪添胜, 等. 基于高光谱图像的龙眼叶片叶绿素含量分布模型[J/OL]. 农业机械学报, 2018, 49(8): 18-25.
YUE Xuejun, LING Kangjie, HONG Tiansheng, et al. Distribution model of chlorophyll content for Longan leaves based on hyperspectral imaging technology[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(8): 18-25. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180802&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.08.002. (in Chinese)
- [18] 石吉勇, 张芳, 胡雪桃, 等. 基于高光谱技术的乳杆菌快速鉴别[J]. 中国食品学报, 2018, 18(8): 208-213.

- SHI Jiyong, ZHANG Fang, HU Xuetao, et al. Rapid identification of *Lactobacillus* based on hyperspectral technique[J]. Chinese Journal of Food Science, 2018, 18(8): 208 – 213. (in Chinese)
- [19] MALEK S, MELGANI F, BAZI Y. One-dimensional convolutional neural networks for spectroscopic signal regression[J]. Journal of Chemometrics, 2018, 32(5): e2977.
- [20] CUI Shaoqing, LING Peter, ZHU Heping, et al. Plant pest detection using an artificial nose system: a review[J]. Sensors, 2018, 18(2): 378.
- [21] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527 – 1554.
- [22] YU Xinjie, TANG Lie, WU Xiongfei, et al. Nondestructive freshness discriminating of shrimp using visible/near-infrared hyperspectral imaging technique and deep learning algorithm[J]. Food Analytical Methods, 2018, 11(3): 768 – 780.
- [23] CIRESAN D, MEIER U. Multi-column deep neural networks for offline handwritten Chinese character classification[C] // International Joint Conference on Neural Networks (IJCNN), 2015: 1 – 6.
- [24] SZGEDY C, TOSHEV A, ERHAN D. Deep neural networks for object detection[C] // Advances in Neural Information Processing Systems, 2013, 26: 2553 – 2561.
- [25] 孙俊, 靳海涛, 武小红, 等. 基于低秩自动编码器及高光谱图像的茶叶品种鉴别[J/OL]. 农业机械学报, 2018, 49(8): 316 – 323.
- SUN Jun, JIN Haitao, WU Xiaohong, et al. Tea variety identification based on low-rank stacked auto-encoder and hyperspectral image[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(8): 316 – 323. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180837&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2018.08.037. (in Chinese)
- [26] 张号遼, 李映, 姜晔楠. 深度学习在高光谱图像分类领域的研究现状与展望[J]. 自动化学报, 2018, 44(6): 961 – 977.
- ZHANG Haokui, LI Ying, JIANG Yenan. Research status and prospects of deep learning in the field of hyperspectral image classification[J]. Acta Automatica Sinica, 2018, 44(6): 961 – 977. (in Chinese)
- [27] ZHANG Junfeng, HU Haifeng. Exemplar-based cascaded stacked auto-encoder networks for robust face alignment[J]. Computer Vision and Image Understanding, 2018, 171(1): 95 – 103.
- [28] XU Lu, JIANG Jianhui, WU Hailong, et al. Variable-weighted PLS[J]. Chemometrics and Intelligent Laboratory Systems, 2007, 85(1): 140 – 143.
- [29] YUAN Xiaofeng, HUANG Biao, WANG Yalin, et al. Deep learning-based feature representation and its application for soft sensor modeling with variable-wise weighted SAE[J]. IEEE Transactions on Industrial Informatics, 2018, 14(7): 3235 – 3243.
- [30] 芦兵, 孙俊, 杨宁, 等. 基于荧光透射谱和高光谱图像纹理的茶叶病害预测研究[J]. 光谱学与光谱分析, 2019, 39(8): 2515 – 2521.
- LU Bing, SUN Jun, YANG Ning, et al. Prediction of tea disease based on fluorescence transmission spectrum and hyperspectral image[J]. Spectroscopy and Spectral Analysis, 2019, 39(8): 2515 – 2521. (in Chinese)
- [31] HERAS D B, FRANCISCO A, PABLO Q B. Exploring ELM-based spatial-spectral classification of hyperspectral images[J]. International Journal of Remote Sensing, 2014, 35(2): 401 – 423.
- [32] ERGUL U, BILGIN G. HCKBoost: hybridized composite kernel boosting with extreme learning machines for hyperspectral image classification[J]. Neurocomputing, 2019, 334: 100 – 113.
- [33] AHILA R, SADASIVAM V, MANIMALA K. An integrated PSO for parameter determination and feature selection of ELM and its application in classification of power system disturbances[J]. Applied Soft Computing, 2015, 32: 23 – 37.
- [34] 伊少梁, 周昕, 李金玺, 等. 利用连通域标记法消除光学扫描全息离焦噪声的实验研究[J]. 光学与光电技术, 2019, 17(1): 51 – 55.
- YI Shaoliang, ZHOU Xin, LI Jinxi, et al. Experimental study to eliminate defocus noise of optical scanning hologram using connected component labelling [J]. Optics and Optoelectronic Technology, 2019, 17(1): 51 – 55. (in Chinese)
- [35] FORTIER C, RODGERS J, FOULK J, et al. Near-infrared classification of cotton lint, botanical and field trash[J]. Journal of Cotton Science, 2012, 16(1): 72 – 79.