

基于LDA的类别约束字典学习的织物疵点图像分类方法

王顺政¹, 陈影柔¹, 吕文涛^{1*}, 郭庆², 陈亮亮³, 王成群¹

¹浙江理工大学信息学院, 浙江 杭州

²浙江省技术创新服务中心, 浙江 杭州

³浙江经贸职业技术学院应用工程系, 浙江 杭州

收稿日期: 2022年2月22日; 录用日期: 2022年4月1日; 发布日期: 2022年4月8日

摘要

在基于字典学习的织物疵点图像分类的过程中, 由于复杂纹理的织物图像背景结构的复杂性、瑕疵信息的形态多样性、瑕疵信息的隐蔽性, 导致基于字典学习的织物疵点分类方法存在不能有效提取织物疵点特征问题, 为了解决该问题, 本文提出一种针对织物疵点特征的基于LDA (线性判别分析)的类别约束字典学习分类方法。首先, 重新构建稀疏表示模型, 在抑制类内差异和类间模糊的面向判别性特征的字典学习优势上对稀疏系数进行线性判别约束, 自适应获取织物图像的有效信息进行分析, 使得字典学习中不同织物图像的稀疏系数具有更好的鉴别能力, 获得具有织物判别特征的织物字典。然后, 利用织物字典对测试样本进行稀疏表示得到的重构误差向量构建分类器进行分类。最后, 在阿里云天池布匹疵点检测数据库、实时工厂收集的织物数据集以及本文课题组采集的少量疵点织物图像上验证本文方法的有效性。在不同的织物数据集实验结果表明, 本文提取的织物特征字典分类效果更好。

关键词

字典学习, 疵点图像分类, 织物疵点特征, 线性判别分析, 类别约束

Fabric Defect Image Classification Method Based on LDA Category Constraint Dictionary Learning

Shunzheng Wang¹, Yingrou Chen¹, Wentao Lyu^{1*}, Qing Guo², Liangliang Chen³, Chengqun Wang¹

¹College of Information, Zhejiang Sci-Tech University, Hangzhou Zhejiang

²Zhejiang Technical Innovation Service Center, Hangzhou Zhejiang

*通讯作者。

文章引用: 王顺政, 陈影柔, 吕文涛, 郭庆, 陈亮亮, 王成群. 基于LDA的类别约束字典学习的织物疵点图像分类方法[J]. 软件工程与应用, 2022, 11(2): 223-234. DOI: 10.12677/sea.2022.112024

Abstract

In the process of fabric defect image classification based on dictionary learning, due to the complexity of the background structure of complex texture fabric image, the morphological diversity of defect information and the concealment of defect information, the fabric defect classification method based on dictionary learning cannot effectively extract the characteristics of fabric defects. In order to solve this problem, this paper proposes a category constrained dictionary learning classification method based on LDA (linear discriminant analysis) for the characteristics of fabric defects. Firstly, the sparse representation model is reconstructed. Based on the discrimination oriented dictionary learning advantage of suppressing intra class differences and inter class fuzziness, the sparse coefficients are linearly discriminated and constrained, and the effective information of fabric images is obtained and analyzed adaptively, so that the sparse coefficients of different fabric images in dictionary learning have better discrimination ability. A fabric dictionary with fabric discrimination characteristics is obtained. Then, the fabric dictionary is used to sparse representation of the test samples, and the reconstructed error vector is used to construct a classifier for classification. Finally, the effectiveness of this method is verified on Alibaba cloud Tianchi fabric defect detection database, fabric data sets collected by real-time factories and a small number of defective fabric images collected by our research group. The experimental results on different fabric data sets show that the fabric feature dictionary extracted in this paper has better classification effect.

Keywords

Dictionary Learning, Defect Image Classification, Fabric Defect Characteristics, Linear Discriminant Analysis, Category Constraints

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来,我国作为纺织生产和出口的第一大国,纺织工业正在高速地发展,并在国民经济中发挥着重要作用。但是,由于人眼的主观性和织物图片成像质量差,使得传统的人眼检测手工分类方法已不能满足高质量和高精度的服装生产要求。随着计算机技术的融入,标准织物的疵点分类方法主要分为两部分:织物特征提取和分类器设计。其中织物特征提取过程对瑕疵的检测分类影响力较大,它直接决定了提取的特征是否能够很好地描述该图像。因此,通过采取可靠且精准的织物图像特征提取技术对纹理复杂、差异较小的织物疵点图像进行处理,在纺织工业中具有很强的现实意义和研究价值[1] [2] [3] [4]。

在织物疵点图像分类领域上,学习训练样本方法大致可分为机器学习法[5] [6] [7]和训练法[8] [9]。本文研究基于字典学习的织物疵点分类方法属于训练法,该方法有出色的学习性能、明确的可解释性以及有限的图像数据情况下依然具有较好的分类性能等优点,因此在图像分类领域取得了大量的应用与研究[10] [11] [12]。最近,WU等[13]提出基于通用字典的局部机织物纹理稳定表征应用于织物图像分类中,

但对于复杂纹理织物的疵点分类来说, 目前提出的大部分字典学习模型只适用于简单、均匀纹理的织物图像, 少部分的疵点分类方法也只能针对特定的纹理织物图像, 对复杂纹理织物疵点图像的分类相对较少。这是由于复杂纹理的织物图像背景结构的复杂性、瑕疵信息的形态多样性、瑕疵信息的隐蔽性(瑕疵区域与背景纹理区域在颜色对比度上、结构上可分性较差), 使得复杂纹理织物检测较难实现, 因此针对复杂多样的织物纹理特征检测的字典学习方法仍然需要很大的改进空间。在字典学习方法改进上, Yang 等[14]提出了费舍尔判别字典学习方法(Fisher discrimination dictionary learning, FDDL), 该方法利用判别特征来构建字典, 并将判别准则作用在编码向量上, 以此来提高编码向量的鉴别能力, 提高学习效果; Jiang [15]等提出了基于类别标签一致的 KSVD (Label consistent KSVD, LC-KSVD)的字典学习方法通过引入样本的类别标签信息提升稀疏表示系数判别性, 间接提升字典的判别性能; Vu 等[16]提出了面向判别性特征的字典学习(Discriminative Feature-oriented Dictionary Learning, DFDL)应用于组织病理图像中, 主要强调的是抑制类内差异和类间模糊并有效地提取了组织图像特征。上述方法对提升字典的判别性能作出了较大贡献, 在图像分类中取得了较好的效果。

在 Vu 等[16]提出的 DFDL 实验中表明, DFDL 方法相比其他方法取得了更好的特征提取效果, 在构建鉴别性字典上得到了很大的突破, 强调抑制类内差异和类间模糊的思路十分合理且有效, 于是本文受此启发, 在面向织物图像特征上, 对其进行研究。但由于组织图像与织物图像有差异, 织物图像中存在大量的纹路信息, 布匹的材料各异, 相同类别的织物中纹路与材料结构变化较大, 不同类别的织物中纹路与材料结构也存在一定的相似性, 因此可能会导致不同织物之间的特征距离小于同类织物之间的特征距离。综上, 在 DFDL 方法下所得到的正常织物字典与瑕疵织物字典可能较为相似, 不能有效地判别正常织物样本与瑕疵织物样本。为了面向织物图像, 提高织物特征字典的判别性以及分类性能, 本文在抑制类内差异和类间模糊的面向判别性特征的字典(Discriminative Feature-oriented Dictionary Learning, DFDL)优势上结合对稀疏系数进行线性判别约束[17] [18] (Linear Discriminant Analysis, LDA), 提出了一种基于 LDA 的类别约束字典学习分类方法, 并在阿里云天池布匹疵点检测数据集、工厂实时收集的织物数据集以及本文课题组采集的少量疵点织物图像中进行实验分类。

2. DFDL 基础理论

2.1. DFDL 基础理论介绍

假设有 c 类训练样本, 将图像中的小块矢量化为列向量 $\mathbf{y} \in R^{M \times 1}$, 可以得到第 i 类的训练样本矩阵和互补样本矩阵 $\mathbf{Y}_i \in R^{M \times N_i}$ 和 $\bar{\mathbf{Y}}_i \in R^{M \times N_i}$ 。

本文中 $\mathbf{D}_i = [d_1^i, d_2^i, \dots, d_{K_i}^i] \in R^{M \times K_i}$ 表示类 i 的字典, $\mathbf{S} = [S_1, S_2, \dots, S_c] \in R^{K \times N}$ 表示训练样本 \mathbf{Y} 在字典 \mathbf{D} 分解得到的稀疏系数, 其中 $\mathbf{S}_i = [S_1^i, S_2^i, \dots, S_{N_i}^i] \in R^{K \times N_i}$ 表示第 i 类训练样本 \mathbf{Y}_i 在字典 \mathbf{D} 分解得到的稀疏系数, 字典学习的主要优化方案是为了获得更好的字典 $\mathbf{D} = [D_1, D_2, \dots, D_c] \in R^{M \times K}$ 来更准确的表示训练样本数据。

2.2. DFDL 方法

Vu 等[16]提出了面向判别性特征的字典学习(DFDL)方法主要为了构建特定特征的字典 \mathbf{D}_i , 使得每类的字典都能更大程度的代表第 i 类样本, 但不能表示其互补样本。具体而言, 需要对字典学习:

$$\frac{1}{N_i} \arg \min \|\mathbf{Y}_i - \mathbf{D}_i \mathbf{S}_i\|_F^2 + \lambda \|\mathbf{S}_i\|_1 \quad \text{越小越好,}$$

$$\frac{1}{N_i} \arg \min \|\bar{\mathbf{Y}}_i - \mathbf{D}_i \bar{\mathbf{S}}_i\|_F^2 + \lambda \|\bar{\mathbf{S}}_i\|_1 \quad \text{越大越好。}$$

式中： λ 为尺度因子； N_i 为第 i 类样本特征个数； \bar{N}_i 为互补样本特征个数； $\|S_i\|$ 为稀疏系数的控制稀疏项； $\|\cdot\|_F$ 表示 Frobenius 范数。

DFDL 方法可以看出在字典学习过程中没有考虑样本间稀疏表示系数之间的差异，可能会使得正常字典和瑕疵字典之间的判别性较低，影响对织物图像的学习性能。

3. 基于 LDA 的类别约束字典学习织物疵点图像分类方法

为了设计针对织物疵点特征的分类性能更好的字典学习分类方法，本文改进常规的字典学习模型。在抑制类内差异和类间模糊的 DFDL 模型的优势上，结合对稀疏系数进行线性判别约束[17] [18]，建立具有织物判别特征的字典进行分类，提出基于 LDA 的类别约束字典学习织物疵点图像分类方法。以天池布匹疵点图为例，该方法的整体流程如图 1 所示。




Figure 1. Flow chart of classification method of fabric defect images based on class constraint dictionary learning based on LDA

图 1. 基于 LDA 的类别约束字典学习织物疵点图像分类方法流程图

3.1. 基于 LDA 的类别约束字典学习模型构建

在 DFDL 的基础上，引入线性判别分析[17] [18]的约束，使得同类样本在字典学习中分解的稀疏系数距离尽可能的接近，对应的是不同类分解的稀疏系数距离尽可能的远离，由此来增强字典的判别性。因此，首先定义新的类内散度矩阵 S_w 和类间散度矩阵 S_b ，由线性判别分析[17] [18]可知散度矩阵求的是协方差矩阵。由于协方差矩阵在运算过程中较为复杂，所以利用 F-范数的平方代替协方差矩阵(F-范数的平方为协方差矩阵的迹)。因此，可设稀疏系数的协方差矩阵的迹为第 i 类的类内散度矩阵 S_w ，迹越大说明稀疏系数的离散程度距离越远。虽然新的 S_w 代替协方差矩阵忽略了其结构，但是更易于研究，类间散度矩阵 S_b 也是如此。

综上，所以只需要：

$$S_w = \sum_{i=1}^C \sum_{S_i^{n_i} \subset S_i} \|S_i^{n_i} - \mu_{S_i}\|_F^2 \quad \text{越小越好,}$$

$$S_b = \sum_{i=1}^C N_i \|\mu_{S_i} - \mu\|_F^2 \quad \text{越大越好。}$$

式中: μ_{S_i} 和 μ 分别表示 S_i 和 S 的均值向量(第 i 类稀疏系数的类中心和所有稀疏系数的类中心); N_i 为第 i 类样本数量; $S_i^{n_i} \in R^{k \times 1}$ 为样本的稀疏系数。

为了方便, 以下开始仅考虑一个类, 即使用 Y, D, S, N 代替 Y_i, D_i, S_i, N_i 等。基于上面的论点, 可以定义新的目标函数:

$$\begin{aligned} & \frac{1}{N} \left(\|Y - DS\|_F^2 + \lambda \|S\|_F^2 + \left(\varepsilon \sum_{S_i^{n_i} \subset S} \|S_i^{n_i} - \mu_S\|_F^2 - \beta \|\mu_S - \mu\|_F^2 + \sigma \|S\|_F^2 \right) \right) \\ & - \frac{\rho}{\bar{N}} \left(\|\bar{Y} - D\bar{S}\|_F^2 + \lambda \|\bar{S}\|_F^2 + \left(\varepsilon \sum_{\bar{S}_i^{n_i} \subset \bar{S}} \|\bar{S}_i^{n_i} - \mu_{\bar{S}}\|_F^2 - \beta \|\mu_{\bar{S}} - \mu\|_F^2 + \sigma \|\bar{S}\|_F^2 \right) \right) \end{aligned} \quad (1)$$

式中: λ 为尺度因子; N 为第 i 类样本特征个数; \bar{N} 为互补样本特征个数; $\|S\|_F$ 为稀疏系数的控制稀疏项; $\|\bar{S}\|_F$ 为互补样本的稀疏系数的控制稀疏项; $S_i^{n_i}$ 为第 i 类样本的稀疏系数; $\bar{S}_i^{n_i}$ 为第 i 类互补样本的稀疏系数; μ_S 和 μ 分别表示第 i 类稀疏系数的类中心以及所有稀疏系数的类中心; ρ 为正归化参数; ε 、 β 为了权衡类别内差异和类别间差异; $\sigma \|S\|_F^2$ 为了解决非凸且不稳定的问题; σ 为常量为了权衡 $\|S\|_F^2$ 和等式的关系。

3.2. 基于 LDA 的类别约束字典学习模型优化求解

由于该模型是凸函数, 所以使用迭代方法来找到字典的最佳解决方案。迭代过程中通过在固定字典 D 的同时优化稀疏系数 S 和 \bar{S} 来进行, 然后通过固定稀疏系数 S 和 \bar{S} 优化字典 D , 以此迭代求解。

在稀疏编码步骤中, 可以通过下列式子来解决:

$$S^* = \arg \min_S \|Y - DS\|_F^2 + \lambda \|S\|_F^2 + \left(\varepsilon \sum_{S_i^{n_i} \subset S} \|S_i^{n_i} - \mu_S\|_F^2 - \beta \|\mu_S - \mu\|_F^2 + \sigma \|S\|_F^2 \right) \quad (2)$$

$$\bar{S}^* = \arg \min_{\bar{S}} \|\bar{Y} - D\bar{S}\|_F^2 + \lambda \|\bar{S}\|_F^2 + \left(\varepsilon \sum_{\bar{S}_i^{n_i} \subset \bar{S}} \|\bar{S}_i^{n_i} - \mu_{\bar{S}}\|_F^2 - \beta \|\mu_{\bar{S}} - \mu\|_F^2 + \sigma \|\bar{S}\|_F^2 \right) \quad (3)$$

式(2)~(3)这两个稀疏编码问题相同只需对其中一个问题求解然后进行组合解决。

由于所有类中心是由每一类类中心得到的, 所以类间散度矩阵推导得 $S_b = \sum_{i=1}^C K \|\mu_{S_i}\|_F^2$, 式中 k 为常数。即可得

$$S^* = \arg \min_S \|Y - DS\|_F^2 + \lambda \|S\|_F^2 + \left(\varepsilon \sum_{S_i^{n_i} \subset S} \|S_i^{n_i} - \mu_S\|_F^2 + K \left(\|S\|_F^2 - \sum_{i=1}^C \|\mu_{S_i}\|_F^2 \right) + (\sigma - K) \|S\|_F^2 \right) \quad (4)$$

由 $\mu_{S_i} = S_i^{n_i} E / n_i$, $\|M\|_F^2 = \text{trace}(MM^T)$ 得

$$\begin{aligned} \|S\|_F^2 - \sum_{i=1}^C \|\mu_{S_i}\|_F^2 &= \text{tr} \left(S^T S - (\mu_{S_i})^T \mu_{S_i} \right) \\ &= \text{tr} \left(S (E - E/n_i) (E - E/n_i)^T S^T \right) \\ &= \|S (E - E/n_i)\|_F^2 \\ &= \|S - \mu_S\|_F^2 \end{aligned} \quad (5)$$

经上述讨论将稀疏系数最终目标函数简化为

$$\arg \min_S \|Y - DS\|_F^2 + \lambda \|S\|_1 + \left(\varepsilon + K \left(\|S\|_F^2 - \sum_{i=1}^C \|\mu_{s_i}\|_F^2 \right) + (\sigma - K) \|S\|_F^2 \right) \quad (6)$$

$$= \arg \min_S \|Y - DS\|_F^2 + \lambda_1 \|S\|_1 + \left(\lambda_2 \sum_{S^{N_i} \subset S} \|S^{N_i} - \mu_S\|_F^2 + \eta \|S\|_F^2 \right) \quad (7)$$

从目标函数(7)可以看出，只要在实际应用中选择合适的参数，则目标函数的 Hessian 矩阵可以是半正定的，因此目标函数对于 S 是凸的。由此可以将其一阶导数设为零并获得解析解。令函数 $F(S)$,

$$F(S) = \arg \min_S \|Y - DS\|_F^2 + \lambda_1 \|S\|_1 + \left(\lambda_2 \sum_{S^{N_i} \subset S} \|S^{N_i} - \mu_S\|_F^2 + \eta \|S\|_F^2 \right) \quad (8)$$

其中第一项求和是字典学习的基本目标函数。这里，对 S 利用一个简单的 2-范数约束编码矩阵求解，使得字典学习过程快速有效。

$$F(S) = \arg \min_S \|Y - DS\|_F^2 + \lambda_1 \|S\|_2^2 + \left(\lambda_2 \sum_{S^{N_i} \subset S} \|S^{N_i} - \mu_S\|_F^2 + \eta \|S\|_F^2 \right) \quad (9)$$

求导并设为零 $2D^T(DS - Y) + (2\eta + 2\lambda_1)S + 2\lambda_2(S - \mu_S) = 0$ 最优解为

$$S_i^* = \frac{D^T Y + \lambda_2 \mu_S}{D^T D + \lambda} \quad (10)$$

在更新字典 D 步骤中，需要优化以下目标函数

$$D^* = \arg \min_D \left(\frac{1}{N} \min \|Y - DS\|_F^2 - \frac{\rho}{N} \min \|\bar{Y} - D\bar{S}\|_F^2 \right) = \arg \min_D \left(-2\text{trace}(GD^T) + \text{trace}(DFD^T) \right) \quad (11)$$

由 $\|Y - DS\|_F^2 = \text{trace}(Y - DS)(Y - DS)^T$ ，可得到 $G = \frac{1}{N} YS^T - \frac{\rho}{N} \bar{Y}\bar{S}^T$ ； $F = \frac{1}{N} SS^T - \frac{\rho}{N} \bar{S}\bar{S}^T$ 。

将目标函数(11)更新为如下式子(12)

$$D^* = \arg \min_D \left(-2\text{trace}(GD^T) + \text{trace}(D(F - \lambda_{\min}(F)I_k D^T)) \right) \quad (12)$$

subject to: $\|\delta_i\|_2^2 = 1, i = 1, 2, \dots, k$

式中： λ_{\min} 是 F 的最小特征值，矩阵 $F^* = F - \lambda_{\min}(F)I_k$ 是半正定的， F^* 所有特征值都是非负的，所以目标函数(12)是凸的。

本质上目标函数(12)与目标函数(11)相同，此类更新字典 D 问题[19]采用以下迭代，收敛得到学习字典 F^* 的最优解。

$$d_i^k \rightarrow \frac{g_k - f_k^* D}{F^*(k, k)} + d_i^k \quad (13)$$

$$d_i^k \rightarrow \frac{1}{\max(\|d_i^k\|_2, 1)} d_i^k \quad (14)$$

式中： d_i^k 为第 i 类更新字典的第 k 列； $F^*(k, k)$ 为矩阵 F^* 坐标 (k, k) 处的值； f_k^* 表示矩阵 F^* 的第 k 列。基于 LDA 的类别约束字典学习的优化过程如算法 1 所示。

算法 1: 基于 LDA 的类别约束字典学习优化过程

输入: 原始样本与互补样本 \mathbf{Y}_i 和 $\bar{\mathbf{Y}}_i$; 正则化参数 λ , ρ , λ_2 ;

步骤 1: 初始化字典 \mathbf{D}

步骤 2: 稀疏编码

固定字典 \mathbf{D} , 解决问题(4), 更新稀疏系数 \mathbf{S} 和 $\bar{\mathbf{S}}$

步骤 3: 字典更新

固定稀疏系数解决问题(11), 更新字典 \mathbf{D}

步骤 4: 判断迭代是否完成, 迭代未完成, 进入步骤 2; 迭代完成输出字典 \mathbf{D}^*

输出: 字典矩阵 \mathbf{D}^*

3.3. 织物图像分类器

对不同织物样本进行基于 LDA 的类别约束字典学习, 得到各自的字典矩阵 \mathbf{D}^* 与 $\bar{\mathbf{D}}^*$, 对测试样本分别进行稀疏表示, 求出稀疏重构误差向量, 求得分类统计量构建织物图像分类器实现织物图像的分类, 具体步骤如下:

- 将测试图像分块, 在测试图块中随机选取多个图块组成测试样本 \mathbf{Z} , 通过

$$\arg \min_{\mathbf{S}} \|\mathbf{Z} - \mathbf{D}\mathbf{S}\|_{\text{F}}^2 + \omega \|\mathbf{S}\|_1 \quad (15)$$

式中: ω 是正则项参数。

利用 SPAMS 工具箱中的 OMP [20]算法求解式(15)在字典矩阵 \mathbf{D}^* 与 $\bar{\mathbf{D}}^*$ 下的稀疏编码系数和 \mathbf{S}^* 和 $\bar{\mathbf{S}}^*$ 。

- 计算测试样本稀疏重构误差向量, 即

$$\begin{aligned} \mathbf{e}_1 &= \text{diag} \left[(\mathbf{Z} - \mathbf{D}^* \mathbf{S}^*) (\mathbf{Z} - \mathbf{D}^* \mathbf{S}^*)^{\text{T}} \right] \\ \mathbf{e}_2 &= \text{diag} \left[(\mathbf{Z} - \bar{\mathbf{D}}^* \bar{\mathbf{S}}^*) (\mathbf{Z} - \bar{\mathbf{D}}^* \bar{\mathbf{S}}^*)^{\text{T}} \right] \end{aligned} \quad (16)$$

式中: \mathbf{e}_1 是测试样本在字典矩阵 \mathbf{D}^* 稀疏重构误差向量; \mathbf{e}_2 是测试样本在字典矩阵 $\bar{\mathbf{D}}^*$ 下稀疏重构误差向量; diag 是矩阵对角矩阵。

- 计算分类统计量, 即

$$\mathbf{A}(i) = \begin{cases} 1, & \mathbf{e}_1(i) \leq \mathbf{e}_2(i) \\ 0, & \mathbf{e}_1(i) > \mathbf{e}_2(i) \end{cases}, i = 1, 2, \dots, N; \mathbf{B} = \sum_{i=1}^N \mathbf{A}(i) / N \quad (17)$$

式中: N 是测试样本数; \mathbf{A} 是分类向量; \mathbf{B} 是分类统计量。

- 构建分类器, 分类统计量 \mathbf{B} 与测试样本最佳阈值对比, 分类统计量 \mathbf{B} 大于测试样本最佳阈值测试样本为正常样本, 反之则为疵点样本。

4. 实验结果及分析

为验证本文方法在织物疵点图像的有效性, 采用阿里天池布匹疵点检测数据集中的织物样本、工厂实时收集的织物疵点织物样本以及本文课题组采集的少量疵点织物样本进行实验, 并与其他方法进行对比分析。实验均在 Windows 10 系统电脑上进行, 电脑处理器 Intel(R) Core(TM) i5-6500 CPU@3.20 Gi Hz, 4 Gi 内存, 实验平台为 Matlab R2020a。

4.1. 阿里天池数据集的实验结果及分析

在每个实验中,从训练样本中随机抽取 10,000 个 40 像素 \times 40 像素的小块,每类学习 100 个基础的字典。阿里天池布匹疵点检测数据集分为正常和瑕疵织物,尺寸为 2560 \times 1920 像素,如图 2 所示为同一材质不同的正常织物与瑕疵织物各 4 张。每个类有 500 张,随机选择 300 张图片进行训练,剩下的用于测试。在此数据集中 λ , λ_2 和 ρ 分别设置为 0.01、0.001 和 0.001 分类性能最优。(实验参数分析见第 4.4 节。)




Figure 2. Tianchi cloth defect detection data set
图 2. 天池布匹疵点检测数据集

在阿里天池布匹疵点数据集上应用本文提出的基于 LDA 的类别约束字典学习方法,与 FDDL [14], DF DL [16], SRC [21]和 LC-KSVD [15]进行分类性能比较,表 1 分别为不同字典学习方法下,天池布匹疵点数据集织物样本中分类的平均准确率以及平均运行时间(10 次实验所取的平均值)。

Table 1. Classification accuracy and running time of Tianchi cloth defect dataset
表 1. 天池布匹疵点数据集的分类准确率以及运行时间

方法	分类准确率/%	运行时间/s
LCKSVD	82.28	175.17
SRC	80.55	5.61
FDDL	84.13	624.65
DFDL	87.63	443.91
本文方法	90.00	137.42

由表 1 易得出本文方法与其他方法相比,在天池布匹疵点织物图像中分类准确率最高,而且训练时间都稳定地排在前列。需要注意的是,和 DF DL 方法相比,本文方法不仅分类准确率提升了约 2.37%,而且运行时间仅仅是 DF DL 方法的十分之三。本文方法的训练时间远远不如 SRC 方法,但分类准确率提升约 9.45%。综上,本文字典学习方法判别性更强,提取织物图像的特征更好,对天池布匹疵点数据集具有更好的分类效率和准确率。

4.2. 工厂实时收集的织物数据集的实验结果及分析

为进一步验证该方法对织物的适用性,本节将其应用于工厂实时收集的织物疵点数据集中,所有图像为 640 像素 \times 640 像素,如图 3 所示为同一材质不同的正常与瑕疵织物图像各 4 张。每个类各有 100 张,在正常和瑕疵的图像中各随机选取 50 张为训练样本,剩下的作为测试样本,每张图像提取 200 个小块,每块的尺寸为 20 像素 \times 20 像素,则正常与瑕疵样本分别为 10,000 个小块。

在此数据集中 λ , λ_2 和 ρ 分别设为 0.0001、0.0001 和 0.001 分类性能最优。将本文方法与 FDDL [14],

DFDL [16], SRC [21]和 LC-KSVD [15]在实时工厂数据集进行分类的平均准确率以及平均运行时间(10次实验所取的平均值)如表 2 所示。




Figure 3. Real-time factory fabric defect detection dataset
图 3. 实时工厂的织物疵点检测数据集

Table 2. Classification accuracy and running time of Tianchi cloth defect dataset
表 2. 工厂实时收集的织物数据集的分类准确率以及运行时间

方法	分类准确率/%	运行时间/s
LCKSVD	83.70	52.13
SRC	75.00	3.05
FDDL	88.60	219.50
DFDL	89.00	139.21
本文方法	91.90	46.14

由表 2 易得出本文的方法与其他方法相比, 在工厂实时收集的织物图像中分类准确率最高, 而且训练时间都稳定地排在前列。综上, 本文字典学习方法判别性更强, 提取织物图像的特征更好, 对实时工厂的织物疵点图像分类适用且高效。

4.3. 本文课题组采集的少量疵点织物图像的实验结果及分析

为验证当实际样本量较少时该方法对织物的适用性, 本节将本文方法应用于本文课题组采集的织物图像数据集中如图 4 所示, 所有图像为 256 像素 × 256 像素, 各有 30 张。




Figure 4. A small number of defective fabric images collected by the research group
图 4. 课题组采集的少量疵点织物图像


在黑线和阴影的织物疵点图像中分别随机选取 5、10、15 张图像作为训练样本, 随机从训练样本中抽取 10,000 个 20 像素 × 20 像素的图像小块。 λ , λ_2 和 ρ 分别设为 0.0001、0.0001 和 0.001, 然后对剩下的疵点图片测试可得分类准确率分别为 92.40%, 95.00%, 98.33%。(10 次实验所取的平均值。)

在黑线和裂缝的织物疵点图像中分别随机选取 5、10、15 张图像作为训练样本，随机从中抽取 10,000 个 20 像素 × 20 像素的图像小块。 λ 、 λ_2 和 ρ 分别设为 0.0001、0.0001 和 0.001，然后对剩下的疵点图片测试可得分类准确率分别为 93.00%，96.00%，98.33%。(10 次实验所取的平均值。)


由此可见，该学习方法的分类性能在不同数量的训练样本情况下都连续稳定，并且随着训练样本数量的增加，其分类准确率也在持续上升，表明该方法在不同情况下的织物疵点图像仍然具有实用性和较好的稳定性。

4.4. 实验参数分析

本文中参数 ρ 平衡学习字典的类内差异和类间模糊，参数 ρ 的设定参考了 DFDL [13] 方法给出的经验值 0.001。本文方法不同之处在于增加了稀疏系数约束项的惩罚因子 λ 和 λ_2 。为了阐述惩罚因子 λ 和 λ_2 对分类性能的影响，图 5 给出随参数 λ 和 λ_2 变化时本文方法在不同织物图像的分类效果。由图看出天池布匹图像在 $\lambda = 0.01$ ， $\lambda_2 = 0.001$ 时分类效果最优，实时工厂图像在 $\lambda_2 = 0.0001$ ， $\lambda = 0.0001$ 时分类效果最优。



(a) 参数 λ 和 λ_2 对天池布匹图像分类效果的影响



(b) 参数 λ 和 λ_2 对工厂实时收集的织物图像分类效果的影响

Figure 5. The classification effect of this method on different fabric images when the parameters λ and λ_2 change

图 5. 参数 λ 和 λ_2 变化时本文方法在不同织物图像的分类效果

5. 结论

基于字典学习的织物疵点分类方法存在不能有效提取织物特征字典问题，具体表现在得到的不同类

的织物字典之间相似度高、判别性弱，不能有效地构造具有织物鉴别特征的字典用来分类。为了提高针对织物特征的字典学习方法的判别性以及分类性能，本文提出基于 LDA 的类别约束字典学习的织物疵点图像分类方法。通过施加稀疏性约束来使每个类具有判别性的字典，然后利用线性判别约束同类样本在字典学习中分解的稀疏系数距离尽可能地接近，不同类分解的稀疏系数距离尽可能地远离，增强了字典的判别性。因此，类中的任何样本都更能被关联字典表示，互补样本更不能被该字典表示，最大程度地减少类内差异和增强类间差异。同时，在类间的细微差异上鼓励在该类别中找到代表性的字典，使得较大的类间差异阻止一个类稀疏表示其他类的样本，获得了较好稀疏表示性能。最后，利用学习织物字典对测试样本进行稀疏表示得到的重构误差向量设计了分类方案，实现了织物图像的分类。在阿里天池布匹疵点检测数据集和实时工厂中的数据集中的实验结果表明，本文方法能有效提取织物图像的分类特征，与同类方法相比，具有更好的织物图像分类结果。

基金项目

国家自然科学基金(61601410); 浙江省科技厅重点研发计划项目(2021C01047, 2022C01079); 东北大学流程工业综合自动化国家重点实验室联合基金(2021-KF-21-03, 2021-KF-21-06)。

参考文献

- [1] 赵艳, 左保齐. 机器视觉在织物疵点检测上的应用研究综述[J]. 计算机工程与应用, 2020, 56(2): 11-17.
- [2] 吕文涛, 林琪琪, 钟佳莹, 王成群, 徐伟强. 面向织物疵点检测的图像处理技术研究进展[J]. 纺织学报, 2021, 42(11): 197-206.
- [3] 邹超, 汪秉文, 孙志刚. 基于机器视觉的织物疵点检测方法综述[J]. 天津工业大学学报, 2009, 28(2): 78-82+85.
- [4] 彭涛, 彭迪, 刘军平, 胡新荣, 张自力, 陈常念, 等. 基于图卷积神经网络的织物分类研究[J]. 计算机应用研究, 2021, 38(5): 1581-1585+1594.
- [5] 尹光灿, 罗戎蕾. 基于卷积神经网络的服装领型识别与分类研究[J]. 现代纺织技术, 2020, 28(3): 48-53.
- [6] Jun, X., Wang, J.G., Zhou, J., Meng, S., Pan, R. and Gao, W. (2020) Fabric Defect Detection Based on a Deep Convolutional Neural Network Using a Two-Stage Strategy. *Textile Research Journal*, **91**, 130-142. <https://doi.org/10.1177/0040517520935984>
- [7] Wei, B., Hao, K.R., Tang, X.S. and Ding, Y. (2019) A New Method Using the Convolutional Neural Network with Compressive Sensing for Fabric Defect Classification Based on Small Sample Sizes. *Textile Research Journal*, **89**, 3539-3555. <https://doi.org/10.1177/0040517518813656>
- [8] 练秋生, 石保顺, 陈书贞. 字典学习模型、算法及其应用研究进展[J]. 自动化学报, 2015, 41(2): 240-260.
- [9] Zhan, Z., Li, L.Q., Chen, X. and Wang, J. (2020) Discriminative-Shared Dictionary Learning for Class-Specific Fabric Texture Characterization. *Textile Research Journal*, **90**, 2478-2491. <https://doi.org/10.1177/0040517520921469>
- [10] Xu, J., Xiang, L., Liu, Q.S., Gilmore, H., Wu, J., Tang, J., et al. (2016) Stacked Sparse Autoencoder (SSAE) for Nuclei Detection on Breast Cancer Histopathology Images. *IEEE Transactions on Medical Imaging*, **35**, 119-130. <https://doi.org/10.1109/TMI.2015.2458702>
- [11] 崔振, 山世光, 陈熙霖. 结构化稀疏线性判别分析[J]. 计算机研究与发展, 2014, 51(10): 2295-2301.
- [12] 陈子鑾, 胡高鹏, 王晓明, 黄增喜, 杜亚军. 基于局部类内结构的鉴别性字典学习方法[J]. 计算机应用研究, 2021, 38(2): 489-494.
- [13] 吴莹, 占竹, 汪军. 基于通用字典的局部机织物纹理稳定表征[J]. 纺织学报, 2019, 40(11): 45-49+56.
- [14] Yang, M., Zhang, L., Feng, X.C. and Zhang, D. (2014) Sparse Representation Based Fisher Discrimination Dictionary Learning for Image Classification. *International Journal of Computer Vision*, **109**, 209-232. <https://doi.org/10.1007/s11263-014-0722-8>
- [15] Jiang, Z.L., Lin, Z. and Davis, L.S. (2013) Label Consistent K-SVD: Learning a Discriminative Dictionary for Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **35**, 2651-2664. <https://doi.org/10.1109/TPAMI.2013.88>
- [16] Vu, T.H., Mousavi, H.S., Monga, V., Rao, G. and Rao, U.K.A. (2016) Histopathological Image Classification Using

- Discriminative Feature-Oriented Dictionary Learning. *IEEE Transactions on Medical Imaging*, **35**, 738-751. <https://doi.org/10.1109/TMI.2015.2493530>
- [17] Martinez, A.M., Zhu, M.L. (2005) Where Are Linear Feature Extraction Methods Applicable? *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **27**, 1934-1943. <https://doi.org/10.1109/TPAMI.2005.250>
- [18] Wen, J., Fang, X.Z., Cui, J.R., Fei, L., Yan, K., Chen, Y., *et al.* (2019) Robust Sparse Linear Discriminant Analysis. *IEEE Transactions on Circuits and Systems for Video Technology*, **29**, 390-403. <https://doi.org/10.1109/TCSVT.2018.2799214>
- [19] Mairal, J., Bach, F., Ponce, J. and Sapiro, G. (2009) Online Learning for Matrix Factorization and Sparse Coding. *Journal of Machine Learning Research*, **11**, 19-60.
- [20] Tropp, J.A. and Gilbert, A.C. (2007) Signal Recovery from Random Measurements via Orthogonal Matching Pursuit. *IEEE Transactions on Information Theory*, **53**, 4655-4666. <https://doi.org/10.1109/TIT.2007.909108>
- [21] Wright, J., Yang, A.Y., Ganesh, A., Sastry, S.S. and Ma, Y. (2009) Robust Face Recognition via Sparse Representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **31**, 210-227. <https://doi.org/10.1109/TPAMI.2008.79>