

记

$$\begin{aligned}\bar{\mathbf{X}} &= m^{-1} \sum_{i=1}^N \mathbf{X}_i \in \mathbf{R}^{m \times p}, \bar{\mathbf{Y}} = m^{-1} \sum_{i=1}^N \mathbf{Y}_i \in \mathbf{R}^{m \times q}, \\ \mathbf{C}_{xx} &= \sum_{i=1}^N (\mathbf{X}_i - \bar{\mathbf{X}})^T (\mathbf{X}_i - \bar{\mathbf{X}}) \in \mathbf{R}^{p \times p}, \\ \mathbf{C}_{xy} &= \sum_{i=1}^N (\mathbf{X}_i - \bar{\mathbf{X}})^T (\mathbf{Y}_i - \bar{\mathbf{Y}}) \in \mathbf{R}^{p \times q}, \\ \mathbf{C}_{yy} &= \sum_{i=1}^N (\mathbf{Y}_i - \bar{\mathbf{Y}})^T (\mathbf{Y}_i - \bar{\mathbf{Y}}) \in \mathbf{R}^{q \times q}, \mathbf{C}_{yx} = \mathbf{C}_{xy}^T \in \mathbf{R}^{q \times p}.\end{aligned}$$

显然  $\mathbf{C}_{xx}, \mathbf{C}_{yy}$  是对称非负定阵且

$$\begin{aligned}\text{cov}(\mathbf{X}\mathbf{w}_x, \mathbf{Y}\mathbf{w}_y) &= E(\mathbf{X}\mathbf{w}_x - \bar{\mathbf{X}}\mathbf{w}_x)^T (\mathbf{Y}\mathbf{w}_y - \bar{\mathbf{Y}}\mathbf{w}_y) \\ &= N^{-1} \sum_{i=1}^N (\mathbf{X}_i \mathbf{w}_x - \bar{\mathbf{X}}\mathbf{w}_x)^T (\mathbf{Y}_i \mathbf{w}_y - \bar{\mathbf{Y}}\mathbf{w}_y) \\ &= N^{-1} \mathbf{w}_x^T \left( \sum_{i=1}^N (\mathbf{X}_i - \bar{\mathbf{X}})^T (\mathbf{Y}_i - \bar{\mathbf{Y}}) \right) \mathbf{w}_y = N^{-1} \mathbf{w}_x^T \mathbf{C}_{xy} \mathbf{w}_y, \\ \text{var}(\mathbf{X}\mathbf{w}_x) &= E(\mathbf{X}\mathbf{w}_x - \bar{\mathbf{X}}\mathbf{w}_x)^T (\mathbf{X}\mathbf{w}_x - \bar{\mathbf{X}}\mathbf{w}_x) = N^{-1} \mathbf{w}_x^T \mathbf{C}_{xx} \mathbf{w}_x, \\ \text{var}(\mathbf{Y}\mathbf{w}_y) &= E(\mathbf{Y}\mathbf{w}_y - \bar{\mathbf{Y}}\mathbf{w}_y)^T (\mathbf{Y}\mathbf{w}_y - \bar{\mathbf{Y}}\mathbf{w}_y) = N^{-1} \mathbf{w}_y^T \mathbf{C}_{yy} \mathbf{w}_y,\end{aligned}$$

于是,模型(1)可转化为

$$\max_{\mathbf{w}_x, \mathbf{w}_y} = \frac{\mathbf{w}_x^T \mathbf{C}_{xy} \mathbf{w}_y}{\sqrt{\mathbf{w}_x^T \mathbf{C}_{xx} \mathbf{w}_x \mathbf{w}_y^T \mathbf{C}_{yy} \mathbf{w}_y}}. \quad (2)$$

由于模型(2)不受范数  $\|\mathbf{w}_x\|$ ,  $\|\mathbf{w}_y\|$  的影响,所以可等价表示为

$$\begin{aligned}\max_{\mathbf{w}_x, \mathbf{w}_y} & \mathbf{w}_x^T \mathbf{C}_{xy} \mathbf{w}_y \\ \text{s.t.} & \mathbf{w}_x^T \mathbf{C}_{xx} \mathbf{w}_x = 1, \mathbf{w}_y^T \mathbf{C}_{yy} \mathbf{w}_y = 1.\end{aligned} \quad (3)$$

考虑模型(3)的 Lagrange 函数,并令  $\partial L / \partial \mathbf{w}_x = \partial L / \partial \mathbf{w}_y = 0$ ,又由于  $\mathbf{w}_x^T \mathbf{C}_{xy} \mathbf{w}_y = \mathbf{w}_y^T \mathbf{C}_{yx} \mathbf{w}_x$  于是

$$\begin{cases} \mathbf{C}_{xy} \mathbf{w}_y = \lambda \mathbf{C}_{xx} \mathbf{w}_x, \\ \mathbf{C}_{yx} \mathbf{w}_x = \lambda \mathbf{C}_{yy} \mathbf{w}_y. \end{cases} \quad (4)$$

为了避免矩阵  $\mathbf{C}_{xx}$  和  $\mathbf{C}_{yy}$  的奇异性,将其正则化,即用  $\mathbf{C}_{xx} + t\mathbf{I}_{p \times p}$  替代  $\mathbf{C}_{xx}$ ,用  $\mathbf{C}_{yy} + t\mathbf{I}_{q \times q}$  替代  $\mathbf{C}_{yy}$ ,其中  $t \geq 0$  是正则化参数。若  $\mathbf{C}_{xx}$  或  $\mathbf{C}_{yy}$  是非奇异阵,则对应的  $t=0$ 。于是由(4)式可得广义特征方程

$$\mathbf{C}_{xy} (\mathbf{C}_{yy} + t\mathbf{I}_{q \times q})^{-1} \mathbf{C}_{yx} \mathbf{w}_x = \lambda^2 (\mathbf{C}_{xx} + t\mathbf{I}_{p \times p}) \mathbf{w}_x. \quad (5)$$

为了求解方程(5),对矩阵  $\mathbf{C}_{xx} + t\mathbf{I}_{p \times p}$  进行特征值分解(Eigen Value Decomposition, EVD):  $\mathbf{C}_{xx} + t\mathbf{I}_{p \times p} = \mathbf{U} \Sigma_x \mathbf{U}^T$ ,其中  $\mathbf{U} \in \mathbf{R}^{p \times p}$  是正交阵,  $\Sigma_x = \text{diag}(\sigma_1, \dots, \sigma_p)$  且  $\sigma_1 \geq \dots \geq \sigma_p > 0$  是  $\mathbf{C}_{xx} + t\mathbf{I}_{p \times p}$  的全部非零特征值。

记

$$\begin{cases} \mathbf{B}_{xy} = \sum_x^{-1} \mathbf{U}^T \mathbf{C}_{xy} (\mathbf{C}_{yy} + t\mathbf{I}_{q \times q})^{-1} \mathbf{C}_{yx} \mathbf{U} \in \mathbf{R}^{p \times p}, \\ \mathbf{B} = \sum_x^{-1/2} \mathbf{U}^T \mathbf{C}_{xy} (\mathbf{C}_{yy} + t\mathbf{I}_{q \times q})^{-1/2} \in \mathbf{R}^{p \times q}, \\ \bar{\mathbf{w}}_x = \mathbf{U}^T \mathbf{w}_x,\end{cases}$$

可得

$$\mathbf{B}_{xy} \bar{\mathbf{w}}_x = \lambda^2 \bar{\mathbf{w}}_x, \quad (6)$$

设  $\text{rank}(\mathbf{B}) = r \leq \min\{p, q\}$ 。并对  $\mathbf{B}$  进行奇异值分解(Singular Value Decomposition, SVD)

$$\mathbf{B} = \mathbf{P} \begin{bmatrix} \Sigma_B & 0 \\ 0 & 0 \end{bmatrix} \mathbf{Q}^T = [\mathbf{P}_1, \mathbf{P}_2] \begin{bmatrix} \Sigma_B & 0 \\ 0 & 0 \end{bmatrix} \mathbf{Q}^T = [\mathbf{P}_1 \Sigma_B, 0] \mathbf{Q}^T,$$

其中  $\mathbf{P} = [\mathbf{P}_1, \mathbf{P}_2] \in \mathbf{R}^{p \times p}$ ,  $\mathbf{Q} \in \mathbf{R}^{q \times q}$  是正交阵,  $\Sigma_B = \text{diag}(\xi_1, \dots, \xi_r)$ ,  $\xi_1 \geq \dots \geq \xi_r > 0$  是  $\mathbf{B}$  的所有非零奇异值且  $\mathbf{P}_1 = [p_1, \dots, p_r] \in \mathbf{R}^{p \times r}$ , 于是

$$\mathbf{B}_{xy} \sum_x^{-1/2} p_i = \xi_i^2 \sum_x^{-1/2} p_i, i=1, \dots, r. \quad (7)$$

对比(6)和(7)两式,可知  $\{(\xi_i^2, \bar{\mathbf{w}}_{xi})\}_{i=1}^r = \{(\xi_i^2, \sum_x^{-1/2} \mathbf{P}_i)\}_{i=1}^r$  是特征方程(6)的全部非零解。单向 2D-

CCA 寻找累积贡献率不小于  $\mu$  的  $d$  ( $d \leq r$ ) 对典型投影方向

$$\begin{aligned} \mathbf{w}_{xi} &= \mathbf{U} \bar{\mathbf{w}}_x = \mathbf{U} \sum_x^{-1/2} p_i, \\ \mathbf{w}_{yi} &= \xi_i^{-1} (\mathbf{C}_{yy} + t \mathbf{I}_{q \times q})^{-1} \mathbf{C}_{yx} \mathbf{w}_{xi} = \xi_i^{-1} (\mathbf{C}_{yy} + t \mathbf{I}_{q \times q})^{-1} \mathbf{C}_{yx} \mathbf{U} \sum_x^{-1/2} p_i, i=1, 2, \dots, d. \end{aligned}$$

下面给出具体算法。

#### 算法 1 (2D-CCA)

步 1 给定图像集  $\{\mathbf{X}_i \in \mathbf{R}^{m \times p}\}_{i=1}^N$  和  $\{\mathbf{Y}_i \in \mathbf{R}^{m \times q}\}_{i=1}^N$ , 选择适当的正则化参数  $t \geq 0$  和累积贡献率  $\mu$  (一般  $0.8 \leq \mu \leq 1$ )。计算矩阵  $\mathbf{C}_{xy}, \mathbf{C}_{xx} + t \mathbf{I}_{p \times p}, \mathbf{C}_{yy} + t \mathbf{I}_{q \times q}$ , 若  $\mathbf{C}_{xx}$  或  $\mathbf{C}_{yy}$  是非奇异阵, 则对应的  $t=0$ 。

步 2 对矩阵  $\mathbf{C}_{xx} + t \mathbf{I}_{p \times p}$  进行 EVD:  $\mathbf{C}_{xx} + t \mathbf{I}_{p \times p} = \mathbf{U} \sum_x \mathbf{U}^T$ , 其中  $\mathbf{U}, \sum_x, \sigma_1 \geq \dots \geq \sigma_p > 0$  如上所述。

步 3 令  $\mathbf{B} = \sum_x^{-1/2} \mathbf{U}^T \mathbf{C}_{xy} (\mathbf{C}_{yy} + t \mathbf{I}_{q \times q})^{-1/2} \in \mathbf{R}^{p \times q}$  且  $\text{rank}(\mathbf{B}) = r \leq \min\{p, q\}$ 。

步 4 对矩阵  $\mathbf{B}$  进行 SVD:  $\mathbf{B} = [\mathbf{P}_1 \sum_B, 0] \mathbf{Q}^T$ , 其中  $\mathbf{P}_1, \sum_B, \xi_1 \geq \dots \geq \xi_r > 0$  如上所述。

步 5 若前  $d \leq r$  个特征值对应的  $\text{CCR}(\xi_1^2 + \dots + \xi_d^2) / (\xi_1^2 + \dots + \xi_r^2) \geq \mu$ , 则取典型投影方向为

$$\begin{aligned} \mathbf{W}_x &= [\mathbf{w}_{x1}, \dots, \mathbf{w}_{xd}] = \mathbf{U} \sum_x^{-1/2} [p_1, \dots, p_d] \in \mathbf{R}^{p \times d}, \\ \mathbf{W}_y &= [\mathbf{w}_{y1}, \dots, \mathbf{w}_{yd}] = (\mathbf{C}_{yy} + t \mathbf{I}_{q \times q})^{-1} \mathbf{C}_{yx} \mathbf{U} \sum_x^{-1/2} [\xi_1 p_1, \dots, \xi_d p_d] \in \mathbf{R}^{q \times d}. \end{aligned}$$

步 6 利用典型方向计算降维特征集  $\{\mathbf{X}_i \mathbf{W}_x \in \mathbf{R}^{m \times d}\}_{i=1}^N$  和  $\{\mathbf{Y}_i \mathbf{W}_y \in \mathbf{R}^{m \times d}\}_{i=1}^N$ 。

从算法 1 中可以看出, CCR 影响着降维特征集的维度, CCR 越大, 降维特征集的维度也越高, 反之亦然。降维特征集的维度又影响着算法的计算成本和图像的识别精度。因此, 如何选择合理的 CCR 是一个急需解决的问题。

## 2 SVM 与 OVR-MSVM

本节简要回顾作为二类数据分类器的线性 SVM 和作为多类数据分类器的线性 OVR-MSVM, 详细内容见文献[15, 16]。

给定二分类数据集  $\mathbf{T} = \{(\mathbf{x}_i, y_i)\}_{i=1}^m \in \mathbf{R}^d \times \{\pm 1\}$ , 其中  $y_i \in \{\pm 1\}$  是第  $i$  个样本  $\mathbf{x}_i \in \mathbf{R}^d$  的类标签。用  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_m] \in \mathbf{R}^{d \times m}$ ,  $\mathbf{D} = \text{diag}(y_1, \dots, y_m) \in \mathbf{R}^{m \times m}$  和  $\mathbf{y} = (y_1, \dots, y_m)^T \in \mathbf{R}^m$  分别表示样本矩阵、类标签矩阵和类标签向量。线性 SVM 通过下面的二次规划模型

$$\begin{aligned} \min_{\mathbf{w}, b, \xi_i} & \frac{1}{2} \|\mathbf{w}\|^2 + \mathbf{C} \sum_{i=1}^m \xi_i \\ \text{s.t.} & y_i (\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 - \xi_i, \xi_i \geq 0, i=1, \dots, m, \end{aligned} \quad (8)$$

寻找分类决策函数  $f(x) = \mathbf{w}^T \mathbf{x} + b$ , 其中  $\mathbf{w} \in \mathbf{R}^d$  和  $b \in \mathbf{R}$  分别表示  $f(x)$  的法向量和阈值,  $\mathbf{C} > 0$  是模型参数,  $\{\xi_i\}_{i=1}^m$  是松弛变量,  $\|\cdot\|$  表示  $l_2$ -范数,  $\langle \cdot, \cdot \rangle$  表示内积。模型(8)的 Wolfe 对偶形式为

$$\begin{aligned} \min_{\boldsymbol{\alpha}} & \frac{1}{2} \boldsymbol{\alpha}^T \mathbf{G} \boldsymbol{\alpha} - \mathbf{e}_m^T \boldsymbol{\alpha} \\ \text{s.t.} & \mathbf{y}^T \boldsymbol{\alpha} = 0, 0 \leq \boldsymbol{\alpha} \leq \mathbf{C} \mathbf{e}_m, \end{aligned} \quad (9)$$

其中  $\boldsymbol{\alpha} \in \mathbf{R}_+^m$  是 Lagrange 乘子向量,  $\mathbf{G} = \mathbf{D} \mathbf{X}^T \mathbf{X} \mathbf{D} \in \mathbf{R}^{m \times m}$  是对称非负定阵,  $\mathbf{e}_m = (1, \dots, 1)^T \in \mathbf{R}^m$ 。通过求解模型(9)得到分类决策函数的方法称为线性 SVM, 下面给出具体算法。

#### 算法 2 (线性 SVM)

步 1 给定数据集  $\mathbf{T} = \{(\mathbf{x}_i, y_i)\}_{i=1}^m \in \mathbf{R}^d \times \{\pm 1\}$ , 选取适当的模型参数  $\mathbf{C} > 0$ 。

步 2 求解模型(9), 得最优解  $\boldsymbol{\alpha}^* \in \mathbf{R}_+^m$ 。

步 3 计算  $\mathbf{w}^* = \mathbf{X} \mathbf{D} \boldsymbol{\alpha}^* = \sum_{i=1}^m \boldsymbol{\alpha}_i^* y_i \mathbf{x}_i \in \mathbf{R}^d$ 。

步 4 寻找  $\boldsymbol{\alpha}^*$  的一个正分量  $0 < \boldsymbol{\alpha}_j^* < \mathbf{C}$ , 计算  $b^* = y_j - \langle \mathbf{w}^*, \mathbf{x}_j \rangle$ 。

步 5 构造分类决策函数  $f(x) = \langle \mathbf{w}^*, \mathbf{x} \rangle + b^*$ 。

步 6 对任一输入  $\tilde{\mathbf{x}} \in \mathbf{R}^d$ , 其类标签可判断为  $y_{\tilde{\mathbf{x}}} = \text{sign}(f(\tilde{\mathbf{x}})) = \text{sign}(\langle \mathbf{w}^*, \tilde{\mathbf{x}} \rangle + b^*)$ 。

给定  $K (K \geq 3)$  类数据集  $T = \{(x_i, y_i)\}_{i=1}^m \in \mathbf{R}^d \times \{1, \dots, K\}$ , 第  $i$  类有  $m_i$  个样本且  $\sum_{i=1}^K m_i = m$ 。用

$$\begin{aligned} \mathbf{X} &= [x_1, \dots, x_m] \in \mathbf{R}^{d \times m}, \mathbf{X}_i [x_1^{(i)}, \dots, x_{m_i}^{(i)}] \in \mathbf{R}^{d \times m_i}, \\ \mathbf{X}_{-i} &= \mathbf{X} \setminus \mathbf{X}_i = [\mathbf{X}_1, \dots, \mathbf{X}_{i-1}, \mathbf{X}_{i+1}, \dots, \mathbf{X}_K] \in \mathbf{R}^{d \times (m - m_i)} \end{aligned}$$

分别表示总体样本矩阵、第  $i$  类样本矩阵和去掉第  $i$  类的剩余样本矩阵, 显然  $\mathbf{X}$  可表示为  $\mathbf{X} = [\mathbf{X}_1, \dots, \mathbf{X}_K]$ 。

以  $\mathbf{X}_i$  为正类,  $\mathbf{X}_{-i}$  为负类, 利用算法 2 学习  $K$  个分类决策函数的方法称为线性 OVR-MSVM。第  $i$  个分类决策函数  $f_i(\mathbf{x}) = (\mathbf{w}_i^*)^T \mathbf{x} + b_i^*$  对应的原始模型和 Wolfe 对偶形式分别为

$$\begin{aligned} \min_{\mathbf{w}_i, b_i, \xi_k} & \frac{1}{2} \|\mathbf{w}_i\|^2 + \mathbf{C}_i \sum_{k=1}^m \xi_k^i \\ \text{s.t.} & y_k^i (\langle \mathbf{w}_i, x_k^i \rangle + b_i) \geq 1 - \xi_k^i, \xi_k^i \geq 0, k = 1, \dots, m \end{aligned}$$

和

$$\begin{aligned} \min_{\alpha^i} & \frac{1}{2} \alpha^{iT} \mathbf{G}_i \alpha^i - e_m^T \alpha^i \\ \text{s.t.} & y^{iT} \alpha^i = 0, \mathbf{0} \leq \alpha^i \leq \mathbf{C}_i \mathbf{e}_m, \end{aligned} \quad (10)$$

其中  $\mathbf{w}_i \in \mathbf{R}^d$  和  $b_i \in \mathbf{R}$  分别是决策函数  $f_i(x)$  的法向量和阈值,  $\mathbf{C}_i > 0$  为模型参数,  $\{\xi_k^i\}_{k=1}^m$  是松弛变量,  $\mathbf{G}_i = \mathbf{D}_i \mathbf{X}^T \mathbf{X} \mathbf{D}_i \in \mathbf{R}^{m \times m}$ ,  $\mathbf{D}_i = \text{diag}(y_1^i, \dots, y_m^i) \in \mathbf{R}^{m \times m}$ 。下面给出具体算法。

**算法 3** (线性 OVR-MSVM)

步 1 给定  $K (K \geq 3)$  类数据集  $T = \{(x_i, y_i)\}_{i=1}^m \in \mathbf{R}^d \times \{1, \dots, K\}$ , 选取适当的模型参数  $\mathbf{C}_1, \dots, \mathbf{C}_K > 0$ 。

步 2 任取  $i \in \{1, \dots, K\}$ , 以  $\mathbf{X}_i$  为正类,  $\mathbf{X}_{-i}$  为负类, 求解模型(10), 得最优解  $\alpha^i \in \mathbf{R}_+^m$ 。

步 3 计算  $\mathbf{w}^i = \mathbf{X} \mathbf{D}_i \alpha^i = \sum_{k=1}^m \alpha_k^i y_k^i \mathbf{x}_k \in \mathbf{R}^d$ 。

步 4 寻找  $\alpha^i$  的一个正分量  $0 < \alpha_j^i < \mathbf{C}_i$  计算  $b_i = y_j^i - \langle \mathbf{w}_i, \mathbf{x}_j \rangle$ 。

步 5 构造  $K$  个分类决策函数  $f_i(\mathbf{x}) = (\mathbf{w}_i^*)^T \mathbf{x} + b_i^*, i = 1, \dots, K$ 。

步 6 对任一输入  $\tilde{\mathbf{x}} \in \mathbf{R}^d$ , 其类标签可判断为  $y_{\tilde{\mathbf{x}}} = \arg \max_{1 \leq i \leq K} (f_i(\tilde{\mathbf{x}}) / \|\mathbf{w}_i^*\|)$ 。

### 3 PDEs 对 2D-CCA 的影响

本节首先简要回顾如何利用 PDEs 进行图像特征提取(详细内容见文献[10]), 然后讨论 PDEs 的进化对 2D-CCA 中 CCR 的影响。

#### 3.1 基于 PDEs 的图像特征提取方法

给定  $K$  类噪声(光暗、有遮挡)图像集  $\{(\mathbf{I}_m, \mathbf{h}_m)\}_{m=1}^M \in \mathbf{R}^{d_1 \times d_2} \times \mathbf{R}^K$ , 其中  $\mathbf{I}_m$  是原始图像,  $\mathbf{h}_m$  是其对应的标签向量, 若  $\mathbf{I}_m$  属于第  $i$  类, 则  $\mathbf{h}_m$  的第  $i$  个分量  $h_{mi} = 1$ , 反之  $h_{mi} = 0$ 。令  $\mathbf{H} = [\mathbf{h}_1, \dots, \mathbf{h}_M] \in \mathbf{R}^{K \times M}$  (称为标签矩阵)。基于 PDEs 的图像特征提取模型为

$$\begin{aligned} \min_{\mathbf{W}, (\alpha_i(t))} & \mathbf{E} = \mathbf{M}^{-1} \|\mathbf{H} - \mathbf{W} \cdot \mathbf{U}\|_{t=T}^2 + \lambda \|\mathbf{W}\|_F^2 \\ \text{s.t.} & \mathbf{u}_m^{n+1} = \mathbf{u}_m^n + \Delta t \sum_{i=0}^5 \alpha_i^n g(\text{inv}_i(\mathbf{u}_m^n)) \in \mathbf{R}^{d_1 \times d_2}, \\ & \mathbf{u}_m^0 = \mathbf{I}_m, n = 0, 1, \dots, N-1, M = 1, \dots, M, \end{aligned} \quad (11)$$

其中  $\mathbf{A} = [\alpha_i^n]_{N \times 6}$  是控制系数矩阵,  $\mathbf{W} \in \mathbf{R}^{K \times d_1 d_2}$  是权矩阵,  $\mathbf{u}|_{t=T}$  为  $t = T$  时的特征矩阵,  $\text{vec}(u)$  是矩阵  $u$  的向量化,  $\lambda > 0$  是调节参数,  $\mathbf{U}|_{t=T} = [\text{vec}(u_1|_{t=T}), \dots, \text{vec}(u_M|_{t=T})] \in \mathbf{R}^{d_1 d_2 \times M}$ ,  $g(x) = x / (1 + |x|)$  是压缩函数,  $N$  为进化次数,  $N$  次进化后的图像特征矩阵为  $u_1^N, \dots, u_M^N$ 。图像识别的准确性严重依赖于图像特征提取的效果, 而这些特征矩阵又依赖于参数矩阵  $\mathbf{A}$ 。利用梯度下降法, 可得参数矩阵  $\mathbf{A}$  的进化迭代公式

$$(\alpha_i^n)^{k+1} = (\alpha_i^n)^k - \eta (\partial \mathbf{E} / \partial \alpha_i^n)^k, i = 0, \dots, 5, n = 0, \dots, N-1,$$

其中  $\eta > 0$  为迭代步长,  $\partial \mathbf{E} / \partial \alpha_i^n = \Delta t \cdot \text{Tr}[(\partial \mathbf{E} / \partial \mathbf{U}^{n+1})^T \mathbf{B}_i^n]$  且

$$\begin{aligned} \mathbf{B}_i^n &= [\text{vec}(g(\text{inv}(u_1^N))), \dots, \text{vec}(g(\text{inv}(u_M^N)))] \in \mathbf{R}^{d_1 d_2 \times M}, \\ \mathbf{C}_i^n &= [\text{vec}(z(i, 1, n)), \dots, \text{vec}(Z(i, M, n))] \in \mathbf{R}^{d_1 d_2 \times M}, \end{aligned}$$

$$\begin{aligned} \partial E / \partial \mathbf{U}^N &= 2\mathbf{M}^{-1}\mathbf{W}^T(\mathbf{W}\mathbf{U}^N - \mathbf{H}), \\ \partial E / \partial \mathbf{U}^n &= \partial E / \partial \mathbf{U}^{N+1} + \Delta t \sum_{i=0}^5 a_i^n \mathbf{C}_i^n, \\ Z(i, m, n) &= [Z(i, m, n)(p, q)] \in \mathbf{R}^{d_1 \times d_2}, n=0, \dots, N-1, i=0, \dots, 5, m=0, \dots, M, \\ Z(i, m, n)(p, q) &= \frac{\partial E}{\partial u_m^{n+1}}(p+1, q) \cdot \frac{\partial g(\text{inv}_i(u_m^n)(p+1, q))}{\partial u_m^n(p+1, q)} + \frac{\partial E}{\partial u_m^{n+1}}(p-1, q) \\ &\cdot \frac{\partial g(\text{inv}_i(u_m^n)(p-1, q))}{\partial u_m^n(p-1, q)} + \frac{\partial E}{\partial u_m^{n+1}}(p, q+1) \cdot \frac{\partial g(\text{inv}_i(u_m^n)(p, q+1))}{\partial u_m^n(p, q+1)} + \frac{\partial E}{\partial u_m^{n+1}}(p, q-1) \\ &\cdot \frac{\partial g(\text{inv}_i(u_m^n)(p, q-1))}{\partial u_m^n(p, q-1)} + \frac{\partial E}{\partial u_m^{n+1}}(p, q) \cdot \frac{\partial g(\text{inv}_i(u_m^n)(p, q))}{\partial u_m^n(p, q)}. \end{aligned}$$

### 3.2 PDEs 对 2D-CCA 的影响

目前大多数的降噪技术和降维技术大都是独立进行学习的,很少进行一体化学习。雷等人提出的基于 PDEs 的 CCA 方法虽然可以对图像进行降噪降维处理,但需将图像拉长为向量,这种拉长不仅会破坏图像的几何结构,而且可能导致“维度灾难”,增加算法的计算复杂度。本节以 PDEs 为降噪工具,以单向 2D-CCA 为降维工具,以 SVM 或 OVR-MSVM 为识别器,以识别精度为标准,对 2D-CCA 和 PDEs 进行一体化学习,并研究 PDEs 的进化对单向 2D-CCA 中 CCR 的影响。具体思路见图 1 所示。




图 1 2D-CCA 和 PDEs 的一体化学习路径

下面给出具体算法。

**算法 4** (2D-CCA 和 PDEs 的一体化学习)

**步 1** 给定  $K$  类噪声(光暗、有遮挡)图像集  $\{(\mathbf{I}_m, \mathbf{h}_m)\}_{m=1}^M \in \mathbf{R}^{d_1 \times d_2} \times \mathbf{R}^K$ , 选择适当的识别器和模型参数。置 PDEs 进化次数  $N=1$ 。

**步 2** 利用 PDEs 对图像集进行降噪,得特征矩阵集  $\{\mathbf{u}_j \in \mathbf{R}^{d_1 \times d_2}\}_{j=1}^M$ 。

**步 3** 将每个  $\mathbf{u}_j$  按列分块,得到两个矩阵集  $\{\mathbf{X}_j \in \mathbf{R}^{d_1 \times d_3}\}_{j=1}^M$  和  $\{\mathbf{Y}_j \in \mathbf{R}^{d_1 \times (d_2-d_3)}\}_{j=1}^M$ , 其中  $d_3 < d_2$ 。

**步 4** 任取 CCR  $\mu$  (一般  $0.8 \leq \mu \leq 1$ ), 利用算法 1 对矩阵集  $\{\mathbf{X}_j \in \mathbf{R}^{d_1 \times d_3}\}_{j=1}^M$  和  $\{\mathbf{Y}_j \in \mathbf{R}^{d_1 \times (d_2-d_3)}\}_{j=1}^M$  进行联合降维,得降维矩阵集  $\{\mathbf{X}_j^* \in \mathbf{R}^{d_1 \times d_4}\}_{j=1}^M$  和  $\{\mathbf{Y}_j^* \in \mathbf{R}^{d_1 \times d_4}\}_{j=1}^M$ , 其中  $1 \leq d_4 \leq \min\{d_3, d_2-d_3\}$ 。

**步 5** 将降维矩阵集进行融合,得  $\left\{ \begin{bmatrix} \mathbf{X}_j^* \\ \mathbf{Y}_j^* \end{bmatrix} \in \mathbf{R}^{2d_1 \times d_4} \right\}_{j=1}^M$ 。

**步 6** 利用识别器进行识别,得识别精度。若识别精度不理想,置  $N \leftarrow N+1$ , 转步 2; 否则,输出结果。

## 4 实验与结果分析

本节通过实验验证了算法 4 的有效性。采用六折交叉验证法,即将全部样本随机分为六份,取五份作为训练集,剩余一份作为测试集,循环六次,取平均精度。CCR 分别取为不小于 0.8, 0.85, 0.9, 0.95 和 1 五种情况(具体计算结果见表 1-6 中括号部分)。PDEs 的进化次数  $N \leq 8$  且不考虑压缩函数的影响,即取  $g(x) = x$ 。所有实验都在 AR 人脸数据集<sup>[17]</sup>和 FRGCv 数据集<sup>[18]</sup>上完成。

### 4.1 AR 人脸数据集上的实验与结果分析

**4.1.1 数据集的构成。** AR 人脸数据集包括 100 个人(男 50 人,女 50 人)的 2600 张面部图像,每人 26 张,每张图像的尺寸为  $50 \times 40$ 。每人的图像包括正面视图、具有不同的面部表情的图像和不同照明和遮挡(太阳眼镜和围巾)条件下的图像。随机选取 8 人(见图 2)构成 4 个二类图像集,随机选取 9 人(见图 3)构成 3 个三类图像集。



图 2 基于 AR 人脸数据集的 4 个二类图像集



图3 基于AR人脸数据集的3个三类图像集

4.1.2 实验与结果分析。下面的表1和表2分别是二类图像集和三类图像集的实验结果,其中  $N=0$  表示没有经过 PDEs 的进化,只是利用单向 2D-CCA 进行了降维。

表1 二类图像集的实验结果(线性 SVM 作为识别器,  $C=0.5$ )

	N	0	1	2	3	4	5	6	7	8	
第1组	$\geq 0.8$	0.5000 (0.8334)	0.5000 (0.8349)	<b>0.8611</b> (0.8359)	0.8333 (0.8375)	0.8611 (0.8401)	0.8333 (0.8458)	0.8611 (0.8649)	0.8056 (0.8745)	0.8611 (0.8512)	
	$\geq 0.85$	0.5833 (0.9181)	<b>1.0000</b> (0.9188)	0.8333 (0.9193)	0.8333 (0.9201)	0.8333 (0.9214)	0.8056 (0.9242)	0.8611 (0.8649)	0.8611 (0.8745)	0.8611 (0.8512)	
	$\geq 0.9$	0.5833 (0.9181)	<b>1.0000</b> (0.9188)	0.8333 (0.9193)	0.8333 (0.9201)	0.8333 (0.9214)	0.8333 (0.9242)	0.8611 (0.9334)	0.8611 (0.9259)	0.8611 (0.9120)	
	$\geq 0.95$	0.5843 (1.0000)	<b>1.0000</b> (1.0000)	0.8889 (1.0000)	0.8333 (1.0000)	0.8333 (1.0000)	0.7778 (1.0000)	0.8333 (1.0000)	0.8611 (1.0000)	0.8333 (96.53%)	0.8333 (95.20%)
	1	0.5843	<b>1.0000</b>	0.8889	0.8333	0.8333	0.7778	0.8333	0.8611	0.8333	
	第2组	$\geq 0.8$	0.5833 (0.8370)	<b>1.0000</b> (0.8406)	0.8333 (0.8421)	1.0000 (0.8447)	0.9000 (0.8499)	0.8194 (0.8635)	0.9167 (0.8157)	0.9479 (0.8649)	0.8519 (0.8287)
$\geq 0.85$		0.5000 (0.9204)	<b>1.0000</b> (0.9224)	0.8333 (0.9231)	0.8333 (0.9242)	0.9000 (0.9266)	0.8194 (0.8635)	0.9048 (0.8943)	0.9000 (0.8649)	0.9259 (0.8898)	
$\geq 0.9$		0.5000 (0.9204)	<b>1.0000</b> (0.9224)	0.8333 (0.9231)	0.8333 (0.9242)	0.9000 (0.9266)	0.8194 (0.9333)	0.9048 (0.9503)	0.9479 (0.9267)	0.8519 (0.9396)	
$\geq 0.95$		0.5000 (1.0000)	0.9583 (0.9678)	0.6944 (0.9507)	<b>1.0000</b> (1.0000)	0.9583 (1.0000)	0.8889 (1.0000)	0.9048 (0.9503)	1.0000 (0.9699)	1.0000 (0.9803)	
1		0.5000	<b>1.0000</b>	0.8333	1.0000	0.9583	0.8889	0.7778	0.8750	0.9167	
第3组		$\geq 0.8$	0.6667 (0.8275)	<b>1.0000</b> (0.8301)	0.7500 (0.8325)	1.0000 (0.8375)	0.9000 (0.8517)	0.8194 (0.8091)	0.8929 (0.8662)	0.8438 (0.8425)	0.8981 (0.8609)
	$\geq 0.85$	0.5833 (0.9179)	<b>1.0000</b> (0.9195)	0.8333 (0.9206)	1.0000 (0.9228)	0.9000 (0.8517)	1.0000 (0.8908)	0.8929 (0.8662)	0.9479 (0.8915)	0.8981 (0.8609)	
	$\geq 0.9$	0.5833 (0.9179)	<b>1.0000</b> (0.9195)	0.8333 (0.9206)	1.0000 (0.9228)	0.9000 (0.9287)	0.8750 (0.9503)	0.9167 (0.9299)	0.9063 (0.9017)	0.9352 (0.9169)	
	$\geq 0.95$	0.5833 (1.0000)	0.9167 (1.0000)	0.8889 (1.0000)	<b>1.0000</b> (1.0000)	0.9333 (1.0000)	0.8750 (0.9503)	0.8810 (0.9715)	0.8646 (0.9515)	0.8611 (0.9592)	
	1	0.5833	0.9167	0.8889	<b>1.0000</b>	0.9333	0.7222	0.8810	0.9375	0.8241	
	第4组	$\geq 0.8$	0.5000 (0.8493)	<b>1.0000</b> (0.8504)	0.8333 (0.8519)	0.9792 (0.8545)	0.8972 (0.8269)	0.9421 (0.8752)	0.9246 (0.8292)	0.8247 (0.8535)	0.9136 (0.8720)
$\geq 0.85$		0.5833 (0.9285)	<b>1.0000</b> (0.8504)	0.8333 (0.8519)	0.9792 (0.8545)	0.9028 (0.8596)	0.9421 (0.8752)	0.9107 (0.8629)	0.8924 (0.9109)	0.9136 (0.8720)	
$\geq 0.9$		0.5833 (0.9285)	<b>1.0000</b> (0.9296)	0.8611 (0.9303)	1.0000 (0.9316)	0.9000 (0.9342)	0.9398 (0.9419)	0.9127 (0.9257)	0.8924 (0.9109)	0.9120 (0.9305)	
$\geq 0.95$		0.7500 (1.0000)	0.9792 (1.0000)	0.8241 (1.0000)	<b>1.0000</b> (1.0000)	0.8972 (0.9704)	0.9375 (0.9840)	0.8948 (0.9679)	0.8750 (0.9503)	0.8781 (0.9676)	
1		0.7500	0.9792	0.8241	<b>1.0000</b>	0.9056	0.9005	0.8433	0.8550	0.8395	

表 2 三类图像集的实验结果(线性 OVR-MSVM 作为识别器,  $C=0.5$ )

	N	0	1	2	3	4	5	6	7	
第 1 组	$\geq 0.8$	0.7222 (0.8269)	<b>1.0000</b> (0.8301)	0.8333 (0.8358)	0.9931 (0.8585)	0.8889 (0.8464)	0.8704 (0.8297)	0.9127 (0.8367)	0.8247 (0.8314)	
	$\geq 0.85$	0.7222 (0.9187)	<b>1.0000</b> (0.9206)	0.8380 (0.9240)	0.9931 (0.8585)	0.8833 (0.8710)	0.9444 (0.8958)	0.9067 (0.8529)	0.9253 (0.8933)	
	$\geq 0.9$	0.7222 (0.9187)	<b>1.0000</b> (0.9206)	0.8380 (0.9240)	0.9965 (0.9371)	0.9083 (0.9116)	0.9769 (0.9436)	0.9147 (0.9123)	0.9618 (0.9373)	
	$\geq 0.95$	0.6667 (1.0000)	0.9514 (1.0000)	0.8426 (1.0000)	<b>1.0000</b> (1.0000)	0.9028 (0.9642)	0.9352 (0.9775)	0.9246 (0.9542)	0.9306 (0.9775)	
	1	0.6667	0.9514	0.8426	<b>1.0000</b>	0.8972	0.8218	0.9246	0.6910	
	第 2 组	$\geq 0.8$	0.7222 (0.8297)	<b>1.0000</b> (0.8525)	0.6065 (0.8346)	0.9931 (0.8309)	0.8333 (0.8178)	0.9537 (0.8243)	0.8611 (0.8148)	0.8976 (0.8309)
		$\geq 0.85$	0.7778 (0.9192)	<b>1.0000</b> (0.8525)	0.8750 (0.9219)	1.0000 (0.9247)	0.8889 (0.8542)	0.9514 (0.9017)	0.8750 (0.8792)	0.9201 (0.8536)
		$\geq 0.9$	0.7778 (0.9192)	0.9167 (0.9210)	0.8750 (0.9219)	<b>1.0000</b> (0.9247)	0.8917 (0.9301)	0.9514 (0.9017)	0.8909 (0.9350)	0.9340 (0.9082)
		$\geq 0.95$	0.7222 (1.0000)	0.8542 (1.0000)	0.8426 (1.0000)	<b>1.0000</b> (1.0000)	0.8972 (1.0000)	0.9931 (0.9565)	0.8948 (0.9745)	0.8611 (0.9514)
		1	0.7222	0.8542	0.8426	<b>1.0000</b>	0.8972	0.9583	0.8909	0.8021
第 3 组		$\geq 0.8$	0.6667 (0.8396)	<b>1.0000</b> (0.8416)	0.5926 (0.8453)	1.0000 (0.8543)	0.8806 (0.8060)	0.9560 (0.8598)	0.8690 (0.8426)	0.8993 (0.8004)
	$\geq 0.85$	0.7222 (0.9205)	<b>1.0000</b> (0.9210)	0.7315 (0.9234)	1.0000 (0.8543)	0.8750 (0.8817)	0.9560 (0.8598)	0.8988 (0.8979)	0.9271 (0.8706)	
	$\geq 0.9$	0.7222 (0.9205)	<b>1.0000</b> (0.9210)	0.7315 (0.9234)	0.9815 (0.9301)	0.8944 (0.9493)	0.9410 (0.9220)	0.9028 (0.9475)	0.9757 (0.9184)	
	$\geq 0.95$	0.6667 (1.0000)	<b>1.0000</b> (1.0000)	0.7731 (1.0000)	0.9514 (0.9765)	0.8889 (1.0000)	0.8657 (0.9716)	0.9028 (0.9825)	0.8628 (0.9598)	
	1	0.6667	<b>1.0000</b>	0.7731	0.9931	0.8889	0.5671	0.9107	0.6684	

从表 1 和表 2 中可以看出,无论 CCR 的取值如何,最多经过 3 次 PDEs 进化,识别精度就能达到最优,甚至达到 1,最低也能提高 20% 以上。

### 4.2 FRGCv 数据集上的实验与结果分析

4.2.1 数据集的构成。FRGCv 数据集包括 466 个人的 4007 张面部图像,每张图像的尺寸为  $64 \times 64$ 。随机抽取 8 人的面部图像构成 4 组二类图像集(见图 4),随机抽取 9 人的面部图像构成 3 组三类图像集(见图 5)。为了便于比较,识别器的模型参数均取为  $10^2$ 。



图 4 FRGCv 数据集集中的 4 组二类图像集



图 5 FRGCv 数据集集中的 3 组三类图像集

4.2.2 实验与结果分析。下面的表 3 和表 4 分别是二类图像集和三类图像集的实验结果,其中  $N=0$  表示没有经过 PDEs 的进化,只是利用单向 2D-CCA 进行了降维。

表 3 二类图像集的实验结果(线性 SVM 作为识别器,  $C=10^2$ )

	N	0	1	2	3	4	5	6	7
第 1 组	$\geq 0.8$	0.5556 (0.8821)	0.6597 (0.8822)	0.7500 (0.8824)	0.7917 (0.8826)	<b>0.7972</b> (0.8830)	0.7847 (0.8836)	0.7857 (0.8849)	0.7795 (0.8865)
	$\geq 0.85$	0.5556 (0.8821)	0.6597 (0.8822)	0.7500 (0.8824)	0.7361 (0.8825)	<b>0.8036</b> (0.8830)	0.7847 (0.8836)	0.7972 (0.8830)	0.7795 (0.8865)
	$\geq 0.9$	0.5833 (1.0000)	0.7014 (1.0000)	0.7407 (1.0000)	0.6910 (1.0000)	<b>0.8167</b> (1.0000)	0.8009 (1.0000)	0.8016 (1.0000)	0.7847 (1.0000)
	$\geq 0.95$	0.5833 (1.0000)	0.7014 (1.0000)	0.7407 (1.0000)	<b>0.8160</b> (1.0000)	0.7694 (1.0000)	0.8009 (1.0000)	0.8016 (1.0000)	0.7847 (1.0000)
	1	0.5833	0.5972	0.7407	0.8160	<b>0.8167</b>	0.8009	0.8016	0.7847
第 2 组	$\geq 0.8$	0.5833 (0.8803)	0.7569 (0.8808)	0.6808 (0.8815)	0.7674 (0.8823)	0.7583 (0.8834)	<b>0.7708</b> (0.8847)	0.7599 (0.8863)	0.7326 (0.8841)
	$\geq 0.85$	0.5833 (0.8803)	0.6806 (0.8808)	0.5972 (0.8810)	0.6840 (0.8814)	0.6806 (0.8819)	<b>0.7879</b> (0.8826)	0.7540 (0.8833)	0.7656 (0.8819)
	$\geq 0.9$	0.5417 (1.0000)	0.6875 (1.0000)	0.6157 (1.0000)	0.6458 (1.0000)	0.6361 (1.0000)	<b>0.7830</b> (1.0000)	0.6766 (1.0000)	0.7430 (1.0000)
	$\geq 0.95$	0.5417 (1.0000)	0.6875 (1.0000)	0.7083 (1.0000)	<b>0.7831</b> (1.0000)	0.5667 (1.0000)	0.6134 (1.0000)	0.6210 (1.0000)	0.7430 (1.0000)
	1	0.5417	0.6875	0.7361	<b>0.7843</b>	0.5667	0.5810	0.5714	0.7430
第 3 组	$\geq 0.8$	0.5347 (0.8843)	0.6806 (0.8852)	0.7222 (0.8863)	0.7917 (0.8874)	0.7500 (0.8887)	<b>0.8426</b> (0.8901)	0.7857 (0.8916)	0.7882 (0.8932)
	$\geq 0.85$	0.5347 (0.8843)	0.6806 (0.8852)	0.7222 (0.8863)	0.7431 (0.8862)	0.7278 (0.8870)	<b>0.7824</b> (0.8878)	0.7813 (0.8886)	0.7674 (0.8896)
	$\geq 0.9$	0.5833 (1.0000)	0.6042 (1.0000)	0.6157 (1.0000)	0.6910 (1.0000)	0.6917 (1.0000)	<b>0.7926</b> (1.0000)	0.6825 (1.0000)	0.7066 (1.0000)
	$\geq 0.95$	0.5833 (1.0000)	0.5486 (1.0000)	0.6157 (0.8863)	0.6354 (1.0000)	0.6917 (1.0000)	<b>0.7269</b> (1.0000)	0.6468 (1.0000)	0.6580 (1.0000)
	1	0.5833	0.5347	0.7407	0.6354	<b>0.7599</b>	0.6227	0.6270	0.6146
第 4 组	$\geq 0.8$	0.5278 (0.8871)	0.7708 (0.8868)	0.7361 (0.8870)	<b>0.8646</b> (0.8876)	0.7917 (0.8885)	0.8148 (0.8897)	0.8241 (0.8911)	0.8299 (0.8926)
	$\geq 0.85$	0.5278 (0.8871)	0.6875 (0.8870)	0.7083 (0.8870)	0.7951 (0.8872)	0.7806 (0.8876)	<b>0.8495</b> (0.8882)	0.8075 (0.8889)	0.8194 (0.8898)
	$\geq 0.9$	0.5417 (1.0000)	0.6181 (1.0000)	0.6343 (1.0000)	<b>0.8264</b> (1.0000)	0.7361 (1.0000)	0.7824 (1.0000)	0.8016 (1.0000)	0.7726 (1.0000)
	$\geq 0.95$	0.5417 (1.0000)	0.5625 (1.0000)	0.6056 (1.0000)	<b>0.8125</b> (1.0000)	0.6528 (1.0000)	0.7130 (1.0000)	0.7271 (1.0000)	0.8090 (1.0000)
	1	0.5417	0.5625	0.5741	<b>0.8264</b>	0.7722	0.6273	0.6429	0.7917

从表 3 和表 4 中可以看出,无论 CCR 的取值如何,最多经过 5 次 PDEs 进化,识别精度就能达到最优。对二类图像集来说,精度最低提高了 24.6%,最高提高了 63.81%。对三类图像集来说,精度最低提高了 56.4%,最高提高了 64.58%。

从上述一系列实验可以看出,PDEs 的进化不仅可以提高图像的识别精度,而且可以弱化 CCR 的选择对识别精度的影响,甚至不用考虑 CCR 的选择问题,通过不超过 5 次的 PDEs 进化即可达到最优识别精度。

表 4 三类图像集的实验结果(线性 OVR-MSVM 作为识别器,  $C=10^2$ )

	N	0	1	2	3	4	5	6	7
第 1 组	$\geq 0.8$	0.5278 (0.8814)	0.7847 (0.8820)	0.7546 (0.8830)	<b>0.8264</b> (0.8844)	0.8229 (1.0000)	0.8079 (0.8891)	0.7976 (0.8865)	0.7587 (0.8963)
	$\geq 0.85$	0.5278 (0.8814)	0.7847 (0.8820)	0.7546 (0.8830)	<b>0.8264</b> (0.8844)	0.8229 (1.0000)	0.8079 (0.8891)	0.7976 (0.8865)	0.7587 (0.8963)
	$\geq 0.9$	0.5000 (1.0000)	0.7639 (1.0000)	0.7407 (1.0000)	<b>0.8229</b> (1.0000)	0.7944 (1.0000)	0.7801 (1.0000)	0.7817 (1.0000)	0.7049 (1.0000)
	$\geq 0.95$	0.5000 (1.0000)	0.7639 (1.0000)	0.7407 (1.0000)	<b>0.8229</b> (1.0000)	0.7944 (1.0000)	0.7801 (1.0000)	0.7817 (1.0000)	0.7049 (1.0000)
	1	0.5000	0.7639	0.7407	<b>0.8229</b>	0.7944	0.7801	0.7817	0.7049
	$\geq 0.8$	0.5185 (0.8800)	0.7917 (0.8809)	0.7731 (0.8820)	0.8021 (0.8840)	<b>0.8111</b> (0.8863)	0.7801 (0.8894)	0.7798 (0.8983)	0.7708 (0.9023)
	$\geq 0.85$	0.5185 (0.8800)	0.7917 (0.8809)	0.7731 (0.8820)	0.8021 (0.8840)	<b>0.8111</b> (0.8863)	0.7801 (0.8894)	0.7798 (0.8983)	0.7708 (0.9023)
	$\geq 0.9$	0.5185 (1.0000)	0.7917 (1.0000)	0.7130 (1.0000)	0.7951 (1.0000)	<b>0.8139</b> (1.0000)	0.7454 (1.0000)	0.7183 (1.0000)	0.7708 (0.9023)
	$\geq 0.95$	0.5185 (1.0000)	0.7917 (1.0000)	0.7130 (1.0000)	0.7569 (1.0000)	<b>0.8139</b> (1.0000)	0.7500 (1.0000)	0.7460 (1.0000)	0.7361 (1.0000)
	1	0.5185	0.7917	0.7130	0.7639	<b>0.8139</b>	0.7176	0.7460	0.7361
第 3 组	$\geq 0.8$	0.5278 (0.8805)	0.5833 (0.8806)	0.7407 (0.8810)	0.6111 (0.8806)	<b>0.8657</b> (0.8820)	0.7972 (0.8816)	0.8194 (0.8824)	0.6875 (0.8809)
	$\geq 0.85$	0.5278 (0.8805)	0.6250 (0.8806)	0.7407 (0.8810)	0.6632 (0.8808)	<b>0.8657</b> (0.8820)	0.7972 (0.8816)	0.8194 (0.8824)	0.7517 (0.8812)
	$\geq 0.9$	0.5139 (1.0000)	0.6875 (1.0000)	0.6528 (1.0000)	0.7257 (1.0000)	<b>0.8214</b> (1.0000)	0.7917 (1.0000)	0.8171 (1.0000)	0.7986 (1.0000)
	$\geq 0.95$	0.5139 (1.0000)	0.6875 (1.0000)	0.6528 (1.0000)	0.7917 (1.0000)	<b>0.8171</b> (1.0000)	0.7917 (1.0000)	0.7976 (1.0000)	0.8171 (1.0000)
	1	0.5139	0.6875	0.6528	0.7917	<b>0.8247</b>	0.7917	0.7143	0.8171

### 4.3 对比实验与分析

为进一步证实该算法的优越性,本节将本文提出的算法与 CCA 算法、2D-CCA 算法和雷等人提出的基于 PDEs 的 CCA 算法进行对比实验.结合前两节与文献[10]中的结论,本实验仅进行 5 次的 PEDs 进化。

4.3.1 数据集的构成。本实验仍在 AR 数据集上进行,随机选取 8 人(见图 6)构成 4 个二类图像集,随机选取 9 人(见图 7)构成 3 个三类图像集。



图 6 基于 AR 人脸数据集的 4 个二类图像集



图 7 基于 AR 人脸数据集的 3 个三类图像集



4.3.2 实验与结果分析。下面的表 5 和表 6 分别是二类图像集和三类图像集的实验结果,其中  $N=0$  表示没有经过 PDEs 的进化,只是利用一维 CCA 或单向 2D-CCA 进行了降维。

表 5 二类图像集的实验结果(线性 SVM 作为识别器,  $C=0.5$ )

N	基于 PDEs 的 CCA						基于 PDEs 的单向 2D-CCA						
	0	1	2	3	4	5	0	1	2	3	4	5	
第 1 组	$\geq 0.8$	0.5250 (0.8004)	0.5625 (0.8004)	0.5750 (0.8004)	0.6500 (0.8004)	0.6700 (0.8004)	<b>0.7179</b> (0.8004)	0.5500 (0.8370)	<b>1.0000</b> (0.8406)	0.8333 (0.8421)	1.0000 (0.8447)	0.9000 (0.8499)	0.9583 (0.8635)
	$\geq 0.85$	0.5500 (0.8609)	0.5750 (0.8609)	0.5833 (0.8609)	0.6000 (0.8609)	0.6833 (0.8609)	<b>0.6964</b> (0.8609)	0.5600 (0.9204)	<b>1.0000</b> (0.9224)	0.8333 (0.9231)	1.0000 (0.9242)	0.9000 (0.9266)	0.9583 (0.8635)
	$\geq 0.9$	0.5500 (0.9305)	0.5625 (0.9305)	0.5917 (0.9306)	0.6250 (0.9305)	0.6875 (0.9103)	<b>0.7000</b> (0.9305)	0.5600 (0.9204)	<b>1.0000</b> (0.9224)	0.8333 (0.9231)	1.0000 (0.9242)	0.9000 (0.9266)	0.9306 (0.9333)
	$\geq 0.95$	0.5750 (0.9513)	0.5917 (0.9513)	0.6125 (0.9513)	0.6200 (0.9513)	0.6750 (0.9513)	<b>0.6964</b> (0.9513)	0.6333 (1.0000)	<b>1.0000</b> (1.0000)	0.8333 (1.0000)	1.0000 (1.0000)	0.8833 (1.0000)	0.9167 (1.0000)
	1	0.6625	0.6917	0.6625	0.7050	<b>0.7134</b>	0.7042	0.6333	<b>1.0000</b>	0.8333	1.0000	0.8833	0.9167
第 2 组	$\geq 0.8$	0.5000 (0.8168)	0.5063 (0.8168)	0.5300 (0.8168)	0.5708 (0.8168)	0.6500 (0.8168)	<b>0.6875</b> (0.8168)	0.5000 (0.8378)	<b>1.0000</b> (0.8395)	0.8333 (0.8413)	1.0000 (0.8447)	0.9000 (0.8534)	0.9444 (0.8073)
	$\geq 0.85$	0.5000 (0.8759)	0.5063 (0.8759)	0.5400 (0.8759)	0.5833 (0.8759)	0.6679 (0.8759)	<b>0.6781</b> (0.8759)	0.5000 (0.9284)	<b>1.0000</b> (0.9294)	0.8334 (0.9304)	1.0000 (0.9322)	0.9000 (0.8534)	1.0000 (0.8826)
	$\geq 0.9$	0.5000 (0.9162)	0.5125 (0.9162)	0.5500 (0.9162)	0.6083 (0.9162)	0.6607 (0.9162)	<b>0.7031</b> (0.9162)	0.5000 (0.9284)	<b>1.0000</b> (0.9294)	0.8334 (0.9304)	1.0000 (0.9322)	0.9000 (0.9363)	0.9306 (0.9503)
	$\geq 0.95$	0.5333 (0.9550)	0.5563 (0.9550)	0.6000 (0.9550)	0.6500 (0.9550)	0.6786 (0.9550)	<b>0.7125</b> (0.9550)	0.7000 (1.0000)	<b>1.0000</b> (1.0000)	0.8333 (1.0000)	1.0000 (1.0000)	0.9000 (1.0000)	0.9306 (0.9503)
	1	0.7200	0.7625	0.8250	<b>0.8313</b>	0.7750	0.7500	0.7000	<b>1.0000</b>	0.8333	1.0000	0.9021	0.9167
第 3 组	$\geq 0.8$	0.5750 (0.8385)	0.5875 (0.8385)	0.6083 (0.8385)	0.6188 (0.8385)	0.6375 (0.8385)	<b>0.6562</b> (0.8385)	0.8333 (0.8378)	<b>1.0000</b> (0.8395)	0.8333 (0.8413)	1.0000 (0.8447)	0.8167 (0.8534)	0.9583 (0.8073)
	$\geq 0.85$	0.5500 (0.8857)	0.5938 (0.8857)	0.6050 (0.8857)	0.6167 (0.8857)	0.6214 (0.8857)	<b>0.6344</b> (0.8857)	0.8333 (0.9284)	<b>1.0000</b> (0.9294)	0.7778 (0.9304)	1.0000 (0.9322)	0.8167 (0.8534)	1.0000 (0.8826)
	$\geq 0.9$	0.5750 (0.9209)	0.5917 (0.9209)	0.6000 (0.9209)	0.6100 (0.9209)	0.6083 (0.9209)	<b>0.6179</b> (0.9209)	0.8333 (0.9284)	<b>1.0000</b> (0.9294)	0.7778 (0.9304)	1.0000 (0.9322)	0.8500 (0.9363)	0.9583 (0.9503)
	$\geq 0.95$	0.5500 (0.9645)	0.5625 (0.9645)	0.5667 (0.9645)	0.5750 (0.9645)	0.5900 (0.9645)	<b>0.6042</b> (0.9645)	0.8333 (1.0000)	<b>1.0000</b> (1.0000)	0.8333 (1.0000)	1.0000 (1.0000)	0.8667 (1.0000)	0.9583 (0.9503)
	1	0.6750	<b>0.7000</b>	0.6625	0.6350	0.6125	0.6321	0.8333	<b>1.0000</b>	0.8333	1.0000	0.8667	0.9583
第 4 组	$\geq 0.8$	0.6500 (0.8293)	0.6625 (0.8293)	0.6750 (0.8293)	0.6938 (0.8293)	0.7150 (0.8293)	<b>0.7417</b> (0.8293)	0.5000 (0.8363)	<b>1.0000</b> (0.8373)	0.8333 (0.8403)	1.0000 (0.8466)	0.9000 (0.8658)	0.9861 (0.8422)
	$\geq 0.85$	0.6500 (0.8812)	0.6750 (0.8812)	0.6875 (0.8812)	0.6950 (0.8812)	<b>0.7125</b> (0.8812)	0.6929 (0.8812)	0.5000 (0.9205)	<b>1.0000</b> (0.9220)	0.8611 (0.9234)	1.0000 (0.9265)	0.9000 (0.8658)	1.0000 (0.9163)
	$\geq 0.9$	0.6250 (0.9218)	0.6500 (0.9218)	0.6667 (0.9218)	0.7042 (0.9218)	0.7250 (0.9218)	<b>0.7594</b> (0.9218)	0.5833 (0.9205)	<b>1.0000</b> (0.9220)	0.8611 (0.9234)	1.0000 (0.9265)	0.9333 (0.9364)	1.0000 (0.9163)
	$\geq 0.95$	0.6500 (0.9530)	0.6625 (0.9530)	0.6667 (0.9530)	0.6875 (0.9530)	0.7393 (0.9530)	<b>0.7688</b> (0.9530)	0.7500 (1.0000)	<b>1.0000</b> (1.0000)	0.8889 (1.0000)	1.0000 (1.0000)	0.9167 (1.0000)	1.0000 (0.9639)
	1	0.5750	0.6500	0.6167	0.6563	0.7071	<b>0.7125</b>	0.7500	<b>1.0000</b>	0.8889	1.0000	0.9167	1.0000

从表 5 和表 6 中可以看出,基于 PDEs 的 CCA 算法和单向 2D-CCA 算法均可提高图像的识别精度,而且可以弱化 CCR 的选择对识别精度的影响,甚至不用考虑 CCR 的选择问题。但相比之下本文提出的算法可以在 PDEs 进化次数更少的情况下获得更好的识别精度,甚至可达 100% 的识别精度。

表 6 三类图像集的实验结果(线性 OVR-MSVM 作为识别器,  $C=0.5$ )

		基于 PDEs 的 CCA					基于 PDEs 的单向 2D-CCA						
N		0	1	2	3	4	5	0	1	2	3	4	5
第 1 组	$\geq 0.8$	0.7722 (0.8003)	0.8370 (0.8003)	0.8750 (0.8003)	0.8956 (0.8003)	0.9000 (0.8003)	<b>0.9302</b> (0.8003)	0.6667 (0.8303)	<b>1.0000</b> (0.8327)	0.8241 (0.8350)	1.0000 (0.8402)	0.8917 (0.8584)	0.9398 (0.8398)
	$\geq 0.85$	0.7722 (0.8530)	0.8259 (0.8530)	0.8667 (0.8530)	0.8933 (0.8530)	0.9167 (0.8530)	<b>0.9254</b> (0.8530)	0.6667 (0.8590)	<b>1.0000</b> (0.9196)	0.8333 (0.9203)	1.0000 (0.9218)	0.8917 (0.8584)	0.9398 (0.9081)
	$\geq 0.9$	0.8000 (0.9220)	0.8481 (0.9220)	0.8833 (0.9220)	0.9111 (0.9220)	0.9259 (0.9220)	<b>0.9365</b> (0.9220)	0.7222 (0.9185)	<b>1.0000</b> (0.9196)	0.8333 (0.9203)	1.0000 (0.9218)	0.9000 (0.9310)	0.9398 (0.9081)
	$\geq 0.95$	0.7778 (0.9544)	0.8370 (0.9544)	0.8694 (0.9544)	0.8978 (0.9544)	0.9074 (0.9544)	<b>0.9317</b> (0.9544)	0.7778 (1.0000)	<b>1.0000</b> (1.0000)	1.0000 (1.0000)	0.8917 (1.0000)	0.9398 (1.0000)	0.9699 (0.9591)
	1	0.7556	0.8074	0.8528	0.8867	0.9037	<b>0.9254</b>	0.7778	<b>1.0000</b>	1.0000	0.8917	0.9398	0.8512
第 2 组	$\geq 0.8$	0.9111 (0.8173)	0.9370 (0.8173)	0.9528 (0.8173)	0.9622 (0.8173)	<b>0.9667</b> (0.8173)	0.9603 (0.8173)	0.9000 (0.8208)	<b>1.0000</b> (0.8316)	0.8333 (0.8393)	0.9931 (0.8438)	0.8500 (0.8798)	0.9282 (0.8134)
	$\geq 0.85$	0.9444 (0.8626)	0.9630 (0.8626)	0.9722 (0.8626)	0.9756 (0.8626)	0.9630 (0.8626)	<b>0.9762</b> (0.8626)	0.9000 (0.9176)	<b>1.0000</b> (0.9198)	0.8333 (0.9213)	0.9931 (0.9252)	0.8500 (0.8798)	0.9699 (0.8811)
	$\geq 0.9$	0.9500 (0.9229)	0.9667 (0.9229)	0.9750 (0.9229)	0.9733 (0.9229)	<b>0.9796</b> (0.9229)	0.9698 (0.9229)	0.9000 (0.9176)	<b>1.0000</b> (0.9198)	0.8333 (0.9213)	0.9931 (0.9252)	0.8600 (0.9414)	0.9282 (0.9376)
	$\geq 0.95$	0.9500 (0.9508)	0.9500 (0.9508)	0.9667 (0.9508)	0.9583 (0.9508)	<b>0.9689</b> (0.9508)	0.9667 (0.9508)	0.9000 (1.0000)	<b>1.0000</b> (1.0000)	0.8400 (1.0000)	0.9862 (1.0000)	0.8917 (1.0000)	0.9282 (0.9713)
	1	0.9444	0.9519	0.9611	0.9622	0.9704	<b>0.9730</b>	0.9000	<b>1.0000</b>	0.8400	0.9862	0.8917	0.9500
第 3 组	$\geq 0.8$	0.7349 (0.8507)	0.6185 (0.8507)	0.7028 (0.8507)	0.7689 (0.8507)	0.8056 (0.8507)	<b>0.8381</b> (0.8507)	0.7556 (82.88%)	<b>1.0000</b> (0.8324)	0.8148 (0.8366)	0.9931 (0.8513)	0.9020 (0.8319)	0.8912 (0.8261)
	$\geq 0.85$	0.5278 (0.8507)	0.6259 (0.8507)	0.7222 (0.8507)	0.7778 (0.8507)	0.8259 (0.8507)	<b>0.8159</b> (0.8507)	0.6900 (91.66%)	<b>1.0000</b> (0.9108)	0.9028 (0.9200)	0.9931 (0.8513)	0.9028 (0.9049)	0.9514 (0.8904)
	$\geq 0.9$	0.5778 (0.9148)	0.6926 (0.9148)	0.7667 (0.9148)	0.8156 (0.9148)	0.8426 (0.9148)	<b>0.8683</b> (0.9148)	0.7333 (91.66%)	<b>1.0000</b> (0.9108)	0.9028 (0.9200)	0.9757 (0.9267)	0.9028 (0.9049)	0.8912 (0.9450)
	$\geq 0.95$	0.5722 (0.9513)	0.6852 (0.9513)	0.7444 (0.9513)	0.7933 (0.9513)	0.8352 (0.9513)	<b>0.8381</b> (0.9513)	0.7141 (1.0000)	<b>1.0000</b> (1.0000)	0.8148 (1.0000)	0.9930 (1.0000)	0.9083 (0.9595)	0.9514 (0.9835)
	1	0.5722	0.6704	0.7528	0.8000	0.8278	<b>0.8556</b>	0.6667	<b>1.0000</b>	0.8148	0.9930	0.9028	0.8912

## 5 结论

对于噪声图像的识别问题,降噪和降维是两个极其重要的环节。目前大多数的降噪技术和降维技术都是独立进行学习的,很少进行一体化学习。雷等人提出的基于 PDEs 的 CCA 方法虽然可以同时图像进行降噪降维处理,但需将图像拉长为向量,这种拉长不仅破坏了图像的几何结构,而且可能导致“维度灾难”,增加算法的计算复杂度。本文提出的 2D-CCA 和 PDEs 一体化学习算法是雷方法的改进和扩展,弥补了雷方法中的缺陷。同时研究了 PDEs 的进化对选择 2D-CCA 中 CCR 的影响。实验结果表明 PDEs 的进化可以弱化 CCR 的选择问题,甚至不用考虑这一问题,且识别精度明显优于雷等人提出的算法,同时所需的 PDEs 的进化次数也明显少于雷等人所提算法。在本文的基础上可以考虑 PDEs 对双向 2D-CCA 中 CCR 的影响,这将是我们的下一步工作。

(下转第 95 页)

# 增稠型煤矿高效泡沫降尘剂试验研究

曹桐,兰文龙,孟庆国,周振,张道鹏

(山东理工大学 化学化工学院,山东 淄博 255049)

**摘要** 煤炭资源开采挖掘过程中所产生的矿井粉尘,严重制约煤炭开采的安全生产.为了降低开采工作过程中所产生的煤尘浓度、提高泡沫降尘剂的降尘能力,采用对比试验法测定了增稠型煤矿泡沫降尘剂的发泡能力,并用改进的 Ross-Miles 法测定了其发泡性能及稳泡性能,使用水膜浮选法测定了其润湿性能,最终得出发泡效率高、稳定时间长且润湿性能好的最佳试验方案,其最大发泡率为 18.72 倍,并通过现场应用测得全尘平均降尘率为 96.21%。

**关键词** 泡沫降尘剂;发泡率;改进的 Ross-Miles 法;水膜浮选法

**中图分类号** TD714.4

**文献标识码** A

开放科学(资源服务)标识码(OSID)



## An Experimental Study of the Efficient Thickened Coal Mine Foam Dust-Reducing Agent

CAO Tong, LAN Wenlong, MENG Qingguo, ZHOU Zhen, ZHANG Daopeng

(School of Chemistry and Chemical Engineering, Shandong University of Technology, Zibo 255049, China)

**Abstract** Mine dust generated during the mining and excavation of coal resources has seriously affected the safety and health of miners. In order to reduce the dust density generated during coal mining and improve the dust-reducing efficiency of the foam dust-reducing agent, the foaming capacity of the thickened coal mine foam dust-reducing agent was studied by a comparative test method, and its development was studied using the improved Ross-Miles method. The foaming performance and foam stabilizing performance were determined by the water film flotation method, and finally the best test plan with high foaming efficiency, long stability time and good wetting performance was obtained. The maximum foaming rate was 18.72, and the average dust reduction rate of total dust measured by field application is 96.21%.

**Key words** foam dust-reducing agent; foaming rate; improved Ross-Miles method; water film flotation method

### 0 引言

在煤炭资源的开采挖掘过程中,除了会产生瓦斯等易燃易爆气体外,煤尘已经成为威胁煤矿安全生产的主要原因和最主要的自然灾害。矿井煤尘主要产生于机械开采挖掘的切割过程和传送运输的扬起过程,随着煤炭开采机械化程度的不断提高,日益增长的煤炭开采量导致生产过程中产生的煤尘浓度也越来越高。

收稿日期:2020-09-05

基金项目:国家自然科学基金项目(21671121)资助

通讯作者:张道鹏,男,汉族,博士,教授,研究方向:功能配合物、分子功能材料,E-mail:dpzhang73@126.com。

因此,如何有效降低矿井煤尘浓度,已经成为煤炭企业迫切需要解决的问题。一方面,矿井下的工作采掘面煤尘浓度过大,将会引发煤矿爆炸事故。据煤炭行业相关部门不完全统计,每年都有因煤尘浓度过高而引发的安全事故;与此同时,煤矿工人因吸入煤尘而患有尘肺病的案例也逐年攀升<sup>[1-4]</sup>。尘肺病给煤炭操作工人身体带来的损害以及由此产生的巨额医疗费用,也已经成为煤炭企业一项不能忽视的经济负担。目前,矿井煤尘给煤矿企业生产环境带来的重大安全隐患和给矿井工人带来重大健康隐患,已然成为制约煤炭企业持续、绿色、高效、安全发展的主要原因<sup>[5-7]</sup>。为了保障煤矿企业安全高效生产,必须从源头上采取有效降尘措施。

目前,国内外为了治理矿井煤尘,主要采用通风、喷雾、煤层注水和化学抑尘等措施。虽然这些降尘措施能够有效地降低煤尘的危害,提高降尘捕捉效果,但是对于呼吸性煤尘的效果却不够明显。针对这一实际问题,国内外研究人员将研究重点放到了耗水量少、覆盖面积广、润湿性好、黏附性强的泡沫降尘技术上<sup>[8-13]</sup>。然而,目前国内外大部分泡沫降尘剂一般含有硫、磷等元素。由于此类物质不容易降解,往往会对环境造成二次污染<sup>[14]</sup>,而且也会对人体产生一定危害。因此,针对目前煤矿企业降尘产品中存在的诸如此类的问题,本文利用环境友好型表面活性剂对增稠型泡沫降尘剂的发泡能力进行了对照试验,通过对比试验法对发泡剂的稳泡能力、润湿性能、降尘能力等进行了研究。使用改进的 Ross-Miles 方法测定了起泡性能和稳泡性能,并使用沉降法测定了其湿润性能,最终优选出了环保型泡沫降尘剂最佳配比方案。

## 1 设计思路

### 1.1 绿色安全

绿色化学的核心之一就是原料的安全性及产物对环境的友好性进行评价的。日常煤矿作业中常用的泡沫降尘剂在制备及使用过程中,往往会直接或间接与工作人员皮肤接触,因此制备绿色环保的降尘产品,对于降低对矿工工人危害 and 环境保护都有至关重要的意义。鉴于此现状,本文着重于开发不含硫、磷等对环境污染元素的新型泡沫降尘剂。研究过程中,在探究发泡条件时除使用传统发泡剂作为对比外,本文主要选用易于降解的环境友好型绿色表面活性剂,如椰子油二乙醇酰胺(CDEA)、羧甲基纤维素(CMC)、脂肪醇聚氧乙烯醚葡糖苷(AEG)、阳离子聚丙烯酰胺(PAM)等表面活性剂为原料进行复配。

### 1.2 溶解效应

为适应矿井中较为苛刻的施工环境,保障发泡器连续高效发泡,选用发泡剂时必须考虑在不同温度条件下的水溶性。选取的发泡剂(wt.% $<2\%$ )在不同温度条件下的水中都应具有良好的溶解度,通过搅拌可充分溶解,继而可以通过提高设备喷射压力,使泡沫能够均匀、高效地作用在扬尘严重的施工面,从根源出发隔离工作面,防止粉尘的扩散。

### 1.3 泡沫类型

根据泡沫存在的时间长短可以将泡沫分为:短时泡沫和持久泡沫;根据泡沫的相对稳定性,可以将其分为稳定泡沫和不稳定泡沫;根据其浓度可以分为:高浓度泡沫和低浓度泡沫。当泡沫遇到粉尘时,会与粉尘产生多种作用,而这些作用的强弱与粉尘的粒度、密度和浓度等有着直接的关系。当遇到密度较大、粒度较大的粉尘时,主要是重力及截留作用;而粒度较小粉尘遇到泡沫时,则以扩散和静电引力为主。发泡剂产生的泡沫不但需要高的发泡率,而且还必须具有一定的可持续性,这需要产生的泡沫应具有稠密、均匀、发泡率高、稳定不易破碎等特点,同时对呼吸性粉尘和全尘具有良好的吸附性,对目标颗粒的湿润性显著高于纯水以及其它发泡剂单体。

### 1.4 设计原理

阴离子及两性表面活性剂的主要功能表现在改变液体表面及液-液界面的性质,通过表面活性剂的性质对复配体系的表面活性进行调控,通过活性剂亲水基间的静电作用形成了致密的吸附膜,从而增强了泡沫降尘剂的作用效果。由于产生的泡沫相比水雾具有更大的比表面积,因此极大提高了降尘剂的吸附能力,最大限度的节约降尘所需的用水量,并通过表面活性剂的使用,来改良泡沫对粉尘的湿润性,从而提高了降尘效率。然而,使用单一组分发泡剂具有诸多限制,比如发泡率低、泡沫极易破碎、对粉尘的湿润性没有明显提高等。针对以上不足,本研究使用绿色表面活性剂,主要从泡沫的发泡率、稳定性和对粉尘的湿润性出发,通过

进行复配来克服上述不足。

## 2 实验部分

### 2.1 实验材料及仪器

试剂:本试验所用材料:椰子油二乙醇酰胺(CDEA)、羧甲基纤维素(CMC)、脂肪醇聚氧乙烯醚葡糖苷(AEG)、阳离子聚丙烯酰胺(PAM)等表面活性剂。为探究含有硫酸盐、磺酸盐的传统表面活性剂的发泡效果以及各组分试剂含量对发泡的影响,选用十二烷基苯磺酸钠等六种常见试剂作为对照试验<sup>[15]</sup>。

仪器:罗氏泡沫仪(2152)、水浴锅、磁力搅拌器、天平、烧杯、量筒、计时器、注射器。

### 2.2 性能测评

起泡性能代表发泡剂在外界条件作用下起泡的难易程度,表达式为 $R=V/M$ ,其中 $R$ 为起泡率, $V$ 为泡沫体积, $M$ 为泡沫质量。该式表明起泡性能 $R$ 是用单位质量发泡剂产生泡沫体积来衡量,单位质量发泡剂形成的泡沫体积越大说明起泡性能越优良。

发泡剂的稳泡性是衡量泡沫寿命长短的重要指标,通常用罗氏泡沫仪来进行测算,并用泡沫消散速率系数 $\alpha$ 来表示,其表达式为 $\alpha=\Delta V/\Delta t$ ,式中 $\Delta V$ 为测量时间内泡沫体积减少量, $\Delta t$ 为泡沫破损的时间区间,泡沫消散速率系数(负值)越大,表明泡沫在测试时间内破损越慢,即发泡剂的起泡稳定性越好。

发泡剂的润湿性能通常用粉尘颗粒在溶液泡沫中的沉降时长来表示,即沉降时间的长短与接触角呈现相关性,沉降时间越短表明固体颗粒与试剂接触角越大,润湿性能越好。表达式为 $\Delta T=T_2-T_1$ ,其中 $T_2$ 是煤尘接触到盛有发泡液的10 mL量筒底端的时间; $T_1$ 是煤尘接触到装在10 mL量筒里的发泡液液面的时间。

### 2.3 实验测量

起泡率 $R$ 测量:取一个洁净干燥的50 mL小烧杯,加入定量称取的待测降尘剂,然后加入20 mL自来水,再加入磁转子进行搅拌,如果溶解过程缓慢,可以加热使之加速溶解。当降尘剂完全溶解后,将溶液转移到500 mL烧杯里,并稀释到100 mL。然后向烧杯中加入磁转子,充分搅拌均匀,搅拌均匀10 min后关闭搅拌。待泡沫静置6 min后,使用洁净干燥的20 mL注射器和分析天平精准称量20 mL泡沫的质量。

消散速率系数 $\alpha$ 计算:利用罗氏泡沫仪(2152)测量时间区间内泡沫体积随时间的变化量,并将所得的散点数据代入一元线性回归方程 $y=ax+\beta$ 进行模拟,得到泡沫体积随时间的变化趋势图。 $y=ax+\beta$ 式中平均消散速率系数为 $\alpha$  mL/min;平均发泡力为 $\beta$  mL;发泡液完全加入泡沫仪后的时间为 $x$  min;随时间变化的泡沫体积为 $y$  mL;利用拟合得到平均消散速率系数 $\alpha$ ,当 $\beta=\beta_0/2$ , $x$ 的值即为泡沫破损的半衰期 $t_{1/2}$ 。

沉降时间 $\Delta t$ 测量:将配置的质量分数为0.50%的不同种类发泡液,各10 mL放入10 mL量筒中,然后立刻向其中加入研磨均匀的煤尘0.1000 g,分别记录平均沉降时间 $\Delta t$ 。

### 2.4 实验方案

通过改变5种试剂的不同比例来设计正交实验,依据对照实验结果分析<sup>[15]</sup>,综合考虑发泡剂的起泡率、稳泡性及消散速率系数等多方面因素,将发泡剂的复配方案设计如:发泡剂:椰子油脂肪酸二乙醇酰胺(CDEA);稳泡剂:羧甲基纤维素(CMC);湿润剂:脂肪醇聚氧乙烯醚葡糖苷(AEG);增稠剂:阳离子聚丙烯酰胺(PAM)。

根据不同质量分数的发泡剂,结合达到最大发泡率时稳泡剂、湿润剂、增稠剂的质量分数进行实验设计,并对正交试验过程中的最大发泡率进行测试记录。由于增稠剂PAM在复配溶液中主要起到絮凝作用,依据对照方案的实验经验,由PAM质量分数与发泡率的关系可知,随着PAM浓度的提高,在低浓度时发泡率达到最大,浓度提高以后发泡率迅速降低最后逐渐平稳,因此本研究引入PAM在发泡率最大时的质量分数:0.02%。

由图1可知,在CDEA含量低于20%时起泡率呈现先下降后上升的趋势,当浓度处于18%-35%区间范围内时发泡率趋于平衡,随着CDEA浓度的继续增加,起泡率也随之继续上升,并在CDEA质量分数为62.50%时达到峰值。由图2可知,稳泡剂和润湿剂也是影响起泡率的重要因素,当起泡率达最大值的时单体CMC、AEG的质量分数分别为1.23%、96.49%。




图 1 CDEA 质量浓度与发泡率的关系




图 2 CMC 质量浓度与发泡率的关系




图 3 AEG 质量浓度与发泡率的关系




图 4 复配方案泡沫消散速率

通过分析试验数据得出最大发泡率为 18.72 倍,最大发泡率时 CDEA、CMC、AEG、PAM 比例为 24:1:4:1。采用该比例的试剂配制成 1000 mL 质量分数为 0.25% 的待测体系,在 40 °C 时,利用罗氏泡沫仪 (2152) 进行稳泡性测试,试验结果如图 4 所示,消散速率系数  $\alpha$  平均值为 -30.905,消散速率方程为  $y = -30.905x + 456.77$ 。经测试平均沉降时间为 1.74 s。

取椰子油二乙二醇酰胺 8.00 g,羧甲基纤维素 0.30 g,脂肪醇聚氧乙烯醚葡萄糖苷 1.50 g 和聚丙烯酰胺(阳)2.00 g 加入 988.20 g 水中充分混合并稍作加热使其完全溶解,最终配置 1.00 kg 泡沫降尘剂。在该泡沫降尘剂中,椰子油二乙二醇酰胺所占比例为 0.80%,羧甲基纤维素所占比例为 0.03%,脂肪醇聚氧乙烯醚葡萄糖苷所占比例为 0.15%,聚丙烯酰胺(阳)所占比例为 0.20%。将制备好的泡沫降尘剂加入罗氏泡沫仪发生器中,产生泡沫量为 886.34 mL,将泡沫降尘剂质量扩大 100 倍后,加入矿用泡沫发生器中进行降尘效果测试,产生的泡沫喷射到尘源处降尘效果良好,该配方的全尘降尘率可达到 96.21%,呼尘降尘率可达到 96.63%。

### 2.5 除尘试验

根据泡沫降尘原理设计一种泡沫发生系统,其中主要部件有:泡沫喷射发生器、发泡液储箱、旋拧阀、水泵、储气罐、空气压缩机、压力泵等。具体结构见图 5 所示。现场除尘效果测试过程中,对各项技术参数进行了设定优化,降尘剂使用过程中要求水流量必须稳定在 1.1-1.4 m<sup>3</sup>/h 的区间范围内,压风流量稳定在 53 m<sup>3</sup>/h,风压、水压均大约为 0.5 MPa。

测试过程中技术参数为:(1)发泡倍数:45 倍;(2)水流量:1.4 m<sup>3</sup>/h;(3)泡沫生产量:53 m<sup>3</sup>/h;(4)发泡




图 5 除尘设备结构示意图.1-发泡液储箱;2-加压泵;3-水泵;4-比例混合器;5-空气压缩机;6-储气罐;7-旋拧阀;8-泡沫喷射发生器

液浓度:约1%。将按照复配方案和对照方案<sup>[15]</sup>质量比配置好泡沫降尘剂,然后分别加入到矿用泡沫发生器中进行发泡作业,将产生的泡沫输送到矿井工作面,并各自测量不同位置的呼尘、全尘浓度,结果见表2、表3。

通过表2、表3中的数据对比可以看出,在使用传统降尘措施时,呼吸性粉尘的降尘效率仅为54.30%,全尘的降尘效率仅为54.60%;而使用实验复配方案发泡剂以后,就整个矿井工作面的降尘效率

来看,呼尘降尘率为96.63%,全尘降尘率为96.21%,综合来看,相比于传统除尘措施,该实验泡沫除尘剂降尘效率更高,除尘效果更明显。

表2 发泡率测试试验数据

测试方案	最大发泡率	总质量分数/%
对照方案	18.34	0.50
复配方案	18.72	0.58

表3 稳泡性能和湿润性测试试验数据

测试方案	消散系数	起泡高度	湿润时间
对照方案	-6.20	425.87	2.32
复配方案	-32.43	484.33	1.73
复配方案	-29.43	449.67	1.74
复配方案	-30.86	436.33	1.75

### 3 结论

本文针对目前市场降尘剂存在稳定性差、效率低下的问题,通过实验研究了增稠型发泡剂复配方案的发泡率、稳定性、湿润性,得到了高发泡率、泡沫稳定性高、对粉尘湿润性良好的复配方案,CDEA、CMC、AEG、PAM四种试剂的质量比为24:1:4:1,发泡率达到18.72倍。试验和应用表明,该泡沫降尘剂方案相比其它降尘方案能够极大提高粉尘的吸附效率,能够显著改进井下掘进工作面粉尘问题,具有广阔的应用前景。

### 参 考 文 献

- [1] 白建民.煤矿井下泡沫除尘剂配方及除尘效率研究[J].内蒙古煤炭经济,2014(10):193-195.
- [2] 王志宝.综掘面高效泡沫降尘技术的应用研究[J].能源与环保,2017,39(6):63-66.
- [3] ARIF A A,PAUL R,DELMELLE E,et al.Estimating the prevalence and spatial clusters of coal workers' pneumoconiosis cases using medicare claims data,2011-2014[J].Am J Ind Med,2020,63(6):478-483.
- [4] HALL N B,HALLDIN C N,BLACKLEY D J,et al.Assessment of pneumoconiosis in surface coal miners after implementation of a national radiographic surveillance program,United States,2014-2019[J].Am J Ind Med,2020,63(12):1104-1108.
- [5] 任万兴,王德明,巫斌伟,等.矿用泡沫除尘技术[J].煤炭科学技术,2009,37(11):30-32.
- [6] 刘杰,杨胜强,王建波,等.泡沫降尘发泡剂的试验研究[J].煤矿安全,2012,43(10):18-20.
- [7] ZHU Y,WANG D,SHAO Z,et al.A statistical analysis of coalmine fires and explosions in China[J].Process Saf Environ Prot,2019,121:357-366.
- [8] 魏西莲,刘杰,尹宝霖.十二烷基羟基丙基三甲基氯化铵及复配体系泡沫性能的测定[J].聊城大学学报(自然科学版),2005,18(4):39-41.
- [9] 赫庆鹏,姚长滨,高天明,等.新型反应型表面活性剂的合成[J].聊城大学学报(自然科学版),2006,19(2):50-52.
- [10] 宋宝林,葛祥才.腰果酚/乙二醇双组份对酚醛泡沫塑料的改性研究[J].聊城大学学报(自然科学版),2013,26(1):43-45.
- [11] 石斌,杨胜强.矿用除尘发泡剂的试验研究[J].矿业研究与开发,2014,34(6):57-60.
- [12] WANG X,YUAN S,LI X,et al.Synergistic effect of surfactant compounding on improving dust suppression in a coal mine in Erdos,China[J].Powder Technol,2019,344:561-569.
- [13] ZHANG H,NIE W,YAN J,et al.Preparation and performance study of a novel polymeric spraying dust suppression agent with enhanced wetting and coagulation properties for coal mine[J].Powder Technol,2020,364:901-914.
- [14] 陶永铎,张辉,李秋小.椰子油乙氧基化物与阴离子表面活性剂协同效应[J].精细化工,2015,32(3):272-276.
- [15] 孟庆国,周茵,兰文龙,等.环境友好型泡沫除尘剂协同试验研究[J].矿业研究与开发,2019,39(4):105-110.