

DOI:10.19651/j.cnki.emt.1802175

# 基于灰狼优化算法的 SVM 的图像噪声识别

田东雨 何玉珠 宋平

(北京航空航天大学 仪器科学与光电工程学院 北京 100191)

**摘要:** 对噪声图像进行噪声类型识别,是对噪声图像进行有针对性去噪的关键技术之一。支持向量机(SVM)是一种基于统计学习理论适用于有限样本情况的分类方法,而且它的分类能力很大程度上取决于其相关参数。提出一种基于灰狼优化算法(GWO)的 SVM 分类方法,将 GWO 应用在 SVM 的参数寻优中,从而获得最优的分类模型;同时将该方法应用于噪声图像的噪声类型识别实验,针对高斯、椒盐、斑点这 3 类噪声在目标图像上形成的噪声干扰图像,分别用 90 个和 60 个干扰图像数据作为训练集和测试集,提取 Zernike 矩、小波高频不显著系数子带能量比这两类特征值,利用 GWA-SVM 分类器对干扰图像特征进行分类。实验结果表明,与传统的 SVM 分类器相比,GWA-SVM 方法具有更好的分类准确率。

**关键词:** 噪声干扰图像; 噪声识别; 支持向量机; 灰狼优化算法; 参数优化

中图分类号: TP206.1 文献标识码: A 国家标准学科分类代码: 510.40

## Approach for image noise recognition by optimizing SVM using grey wolf optimization algorithm

Tian Dongyu He Yuzhu Song Ping

(School of Instrumentation Science and Opto-electronics, Beihang University, Beijing 100191, China)

**Abstract:** Noise type recognition for noise images is one of the key techniques for targeted denoising of noise images. Support vector machine (SVM) is a classification method based on statistical learning theory applicable to finite sample cases, and its classification ability depends largely on its related parameters. In this paper a new method is proposed to optimize the parameters of SVM. Grey wolf optimization (GWO) algorithm is used to optimize the parameter of SVM for obtain the optimal classification model, meanwhile the proposed method is applied to the noise type recognition experiment of noise images. The images with noise interference are formed by three types of noises such as Gauss noise, Salt-and-Pepper noise and speckle noise. 90 sample data are taken as training samples and the remaining 60 sample data are taken as the testing samples. The Zernike moments and wavelet high-frequency non-significant coefficient subband energy ratio are selected as the eigenvalue. The GWO-SVM classifier is used to classify noise images. The experimental results show that the GWO-SVM method has better classification accuracy than the traditional SVM classifier.

**Keywords:** image with noise interference; noise recognition; support vector machine; grey wolf optimization algorithm; parameter optimization

## 0 引言

噪声识别是对噪声图像进行有针对性去噪的第一步,同时也是图像去噪的关键步骤<sup>[1]</sup>。相对于人为地处理图像,利用计算机来进行图像的视觉判读能够更加准确地识别图像,进而进行分类。这是一项很有价值的关键技术。

支持向量机(support vector machine, SVM)是一种适用于有限样本情况的分类方法,它的理论基础就是统计学习理论;由于其优越的分类能力,在各个方面都有广泛应

用。如模式识别<sup>[2]</sup>、文本识别<sup>[3]</sup>、图像分类识别<sup>[4-5]</sup>、故障诊断<sup>[6]</sup>等领域。在利用 SVM 进行分类的过程中,参数的选择极其重要,会直接影响到分类器的性能。尤其是惩罚因子 C、核函数的参数等。目前关于 SVM 研究比较广阔的一个点就是 SVM 参数的选取问题。梯度下降法<sup>[7]</sup>、遗传算法<sup>[8]</sup>、粒子群算法<sup>[9]</sup>、蚁群算法<sup>[10]</sup>、蜂群算法<sup>[11]</sup>等智能算法已经和 SVM 结合在一起,应用到 SVM 的参数选取上。

不同的算法会对分类器产生不同影响,以上智能算法在参数寻优的过程中都会不同程度地陷入局部最优解,根

本无法达到全局最优,进而实现最优分类。2014 年 Mirjalili 提出了灰狼优化算法(grey wolf optimization algorithm, GWO),跟其他的优化算法相比,灰狼优化算法的结构更加简单、收敛速度更快、更容易达到最优分类。基于此,本文提出了一种基于 GWO 的 SVM 参数寻优方法,并将优化的分类器应用于噪声分类中。

## 1 SVM 原理及参数选择

### 1.1 SVM 原理

SVM 是由 Vapnik 等提出的一种基于结构风险最小化的机器学习方法,该方法能够无限逼近复杂系统(包括线性系统和非线性系统),而且它能够在样本数量较小的情况下很好的地平衡模型的复杂性和学习能力,进而获得最优的泛化能力。对于一个线性可分的二分类问题,SVM 实质上就是寻找一个使两类样本分布在两侧的且距离超平面最远的一个分类超平面。

设两类训练样本集为:

$$\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$$

其中,  $n$  表示样本数,  $x_i$  是第  $i$  个样本  $v$  维特征空间输入值,  $y_i \in \{-1, 1\}$ 。

在线性可分的情况下,SVM 求解的最优超平面就可以转化为以下的约束优化问题:

$$\min \varphi(\omega) = \frac{1}{2} \|\omega\|^2$$

$$\text{s.t. } y_i(\omega \cdot x_i + b) \geq 1, i = 1, 2, \dots, l \quad (1)$$

式中:  $\omega$  代表的是所求解的最优超平面的法向量;  $b$  为偏移量,  $\omega \cdot x + b = 0$  就是本文需要寻找的最优超平面。

如果样本为线性不可分的,SVM 则会采用非线性映射  $\Phi$ , 将样本从现有空间映射到更高维的空间  $\Omega$  上, 在  $\Omega$  内就转化成了线性可分的问题,因此在  $\Omega$  空间内就能求出最优分类平面。但是,核函数  $k(x_i, x_j)$  必须满足 Mercer 条件,即:

$$k(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (2)$$

综上所述,通过选择适当的核函数  $k(x_i, x_j)$ ,便可以实现对非线性样本的线性分类。在引入松弛变量  $\xi_i$  后,原分类面方程可表示为:

$$y_i(\omega \cdot \Phi(x_i) + b) \geq 1 - \xi_i, i = 1, \dots, n \quad (3)$$

式中:  $\omega$  是分类平面的权系数向量;  $b$  为分类的域值。最优分类面的问题就可以被转化为:

$$\begin{cases} \min \varphi(\omega) = \frac{1}{2} \|\omega\|^2 + C \left( \sum_{i=1}^n \xi_i \right) \\ y_i(\omega \cdot \Phi(x_i) + b) \geq 1 - \xi_i, i = 1, 2, \dots, n \end{cases} \quad (4)$$

式中:  $C$  表示惩罚因子,它控制着模型的复杂度以及逼近误差。

在引入 Lagrange 乘法算子之后,最优超平面的问题就可以转化为对偶二次规划问题,同时将核函数的内积转换代入,式(3)就可以被转换为如下:

$$\begin{aligned} \max L(\alpha) = & \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_i \sum_j \alpha_i \alpha_j y_i y_j (k(x_i, x_j)) \\ \text{s.t. } 0 \leq \alpha_i \leq C, \sum_{i=1}^l \alpha_i y_i = 0, \alpha_i \geq 0 \end{aligned} \quad (5)$$

最终的最优分类面函数就表示为:

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^n \alpha_i^* y_i k(x_i \cdot x) + b^* \right\} \quad (6)$$

### 1.2 支持向量机参数

支撑向量机的参数直接影响着其学习能力和泛化能力,因此在解决支撑向量机问题时比较重要的一点就是如何选择最优的支持向量机参数。对于核函数是 RBF 的 SVM 来说,它的参数调整包括参数  $C$  和核宽度  $\sigma$  的调整<sup>[12]</sup>。

## 2 基于 GWO 算法的 SVM 参数优化方法

### 2.1 GWO 算法原理

2014 年 Mirjalili<sup>[13]</sup> 提出了一种新的启发式算法,即 GWO 算法。GWO 是一种模拟了灰狼家族的社会等级制度和家族群体狩猎行为的新的群体智能优化算法<sup>[14]</sup>。跟其他的优化算法相比,GWO 的结构更加简单、收敛速度更快、更容易达到最优分类。

在 GWO 算法中,为了模拟灰狼家族的社会等级制度,按社会地位从高到低依次定义了 4 种类型的灰狼分别是  $\alpha$ 、 $\beta$ 、 $\sigma$  和  $\omega$ ,其中,狩猎过程是由  $\alpha$  狼、 $\beta$  狼和  $\sigma$  狼负责引导,  $\omega$  狼进行对猎物的跟踪围捕。它们的数学模型如下:

$$\begin{cases} \mathbf{D} = |\mathbf{C} \cdot \mathbf{X}_\alpha(t) - \mathbf{X}(t)| \\ \mathbf{X}(t+1) = \mathbf{X}_\alpha(t) - \mathbf{A} \cdot \mathbf{D} \end{cases} \quad (7)$$

式中:  $t$  代表当前的迭代次数;  $\mathbf{X}_\alpha$  是猎物位置向量;  $\mathbf{X}$  表示灰狼位置向量;  $\mathbf{A}$  和  $\mathbf{C}$  是参数向量。其中  $\mathbf{A}$  和  $\mathbf{C}$  可表示如下:

$$\begin{cases} \mathbf{A} = 2\mathbf{a} \cdot \mathbf{r}_1 - \mathbf{a} \\ \mathbf{C} = 2\mathbf{r}_2 \end{cases} \quad (8)$$

式中:  $\mathbf{a}$  是线性减小的并且有  $\mathbf{a} \in [0, 2]$ ;  $\mathbf{r}_1$  和  $\mathbf{r}_2$  是  $[0, 1]$  中的随机向量。

在模仿狩猎过程的时候,假设  $\alpha$  (最优解), $\beta$  和  $\delta$  对猎物(目标)的位置有较高的认识,那么可以利用他们来更新自己的位置,其公式如下:

$$\begin{cases} \mathbf{D}_\alpha = |\mathbf{C}_1 \cdot \mathbf{X}_\alpha - \mathbf{X}| \\ \mathbf{D}_\beta = |\mathbf{C}_2 \cdot \mathbf{X}_\beta - \mathbf{X}| \\ \mathbf{D}_\delta = |\mathbf{C}_3 \cdot \mathbf{X}_\delta - \mathbf{X}| \end{cases} \quad (9)$$

$$\begin{cases} \mathbf{X}_1 = \mathbf{X}_\alpha - \mathbf{A}_1 \cdot \mathbf{D}_\alpha \\ \mathbf{X}_2 = \mathbf{X}_\beta - \mathbf{A}_2 \cdot \mathbf{D}_\beta \\ \mathbf{X}_3 = \mathbf{X}_\delta - \mathbf{A}_3 \cdot \mathbf{D}_\delta \end{cases} \quad (10)$$

$$\mathbf{X}(t+1) = \frac{\mathbf{X}_1 + \mathbf{X}_2 + \mathbf{X}_3}{3} \quad (11)$$

### 2.2 GWO 算法的 SVM 参数选择

GWO-SVM 分类器是一种以支撑向量机为基础框架

结构,采用了 GWO 智能优化算法粒子更新策略的一种高效的分类器。在这种分类器中, SVM 的一种参数组合用粒子的位置信息来表示,通过 GWO 的最优寻找,进而获得最优粒子的信息,然后可以根据最优粒子来建立最优的分类器进而找到最优的分类超平面。其中,具体模型的建立过程如下。

1) 把包含不同噪声的图像分成两部分,一部分为 90 个训练样本,另一部分为 60 个测试样本。

2) 随机产生  $n$  个粒子,其中每一个粒子位置代表一组参数( $C, g$ )。

3) 根据  $C$  和  $g$  的特征来确定粒子位置的迭代范围以及更新步长。

4) 把粒子的位置代入到 SVM 模型中,得出当前粒子的适应度值。

5) 以适应度值为依据,将最优粒子存入  $V$ ,并更新  $U$ 。其中  $V$  代表每个粒子目前为止的最优位置, $U$  代表全局粒子的最优位置。

6) 根据 GWO 算法更新粒子的位置,若满足要求,则停止搜索;否则,返回步骤 3)。

7) 用获得的最优参数来建立分类模型。

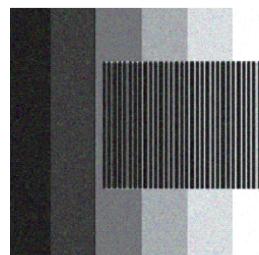
具体流程如图 1 所示。

### 3 GWO 算法的 SVM 在图像噪声识别的应用

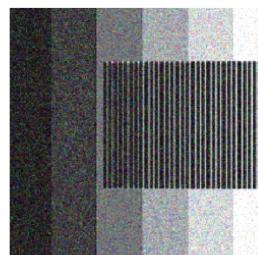
#### 3.1 干扰噪声的选择

本文选择了 3 种典型的噪声作为图像的干扰信号:高斯噪声、椒盐噪声、斑点噪声<sup>[15]</sup>。分别将它们添加到原目标图像中。目标图像如图 2 所示。

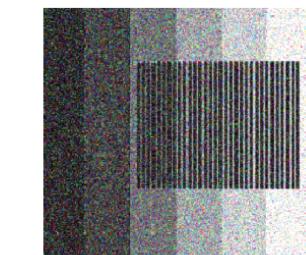
噪声的类别代表不同的干扰信号,噪声的强度代表干扰信号的强度。因为这 3 种噪声具有干扰信号源的典型特征。图 3~5 所示分别代表 3 类噪声在不同的参数下的噪声干扰图像。



$k1=0.002$



$k1=0.01$



$k1=0.03$

图 3 在不同参数下的高斯噪声干扰图像

#### 3.2 图像数据特征的提取

本文选择对典型的干扰噪声信号较为敏感的 2 个特征值。

1) 小波高频系数直方图的不显著系数能量比

根据小波变换原理可知,图像的噪声信息主要体现在

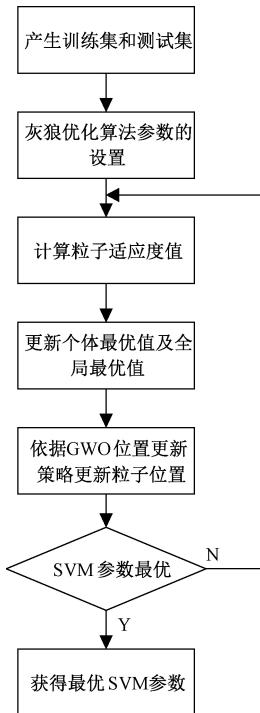


图 1 灰狼优化算法优化支持向量机参数流程

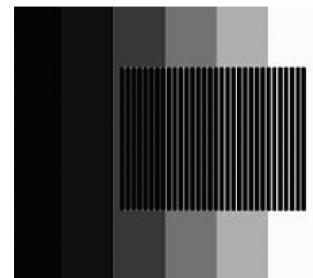


图 2 原目标图像

各个尺度信息的高频部分,因此,利用图像在小波变换后的曲线拟合图以及高频系数直方图就可以识别出不同噪声对图像造成的干扰。而噪声主要在图像的高频 HH 带中,因此,如果需要准确地识别出噪声的类型,则需要分析高频 HH 子带。

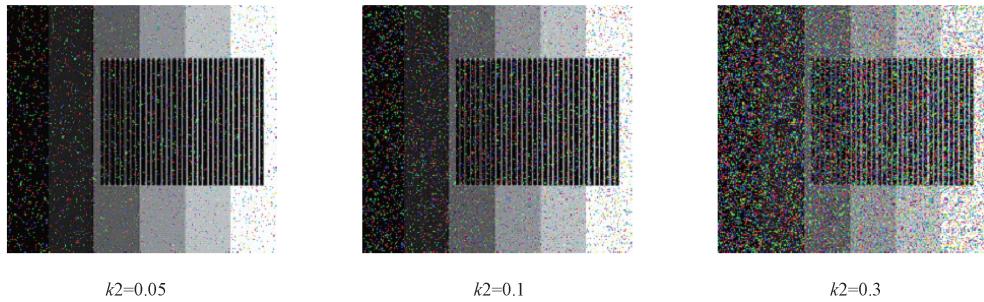


图 4 在不同参数下的椒盐噪声干扰图像

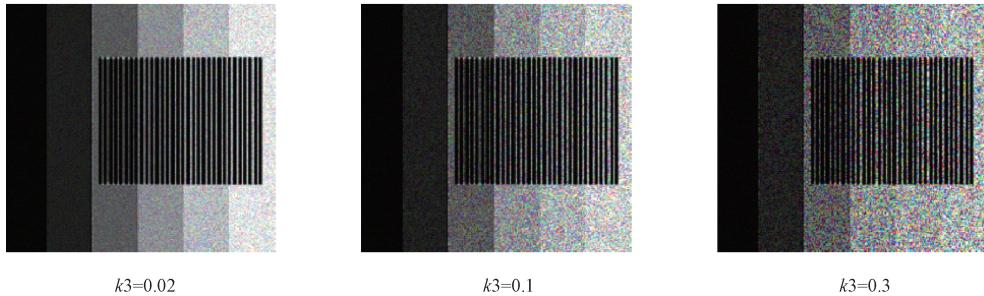


图 5 在不同参数下的斑点噪声干扰图像

假设 HH 子带的系数矩阵为  $D(i, j)$ , 按照系数幅值绝对值的大小找出较小的系数:

$$D_T(i, j) = \{ |D(i, j)|, |D(i, j)| < T \} \quad (12)$$

其中,  $T$  用来判别较小系数的阈值。而较小系数能量与子带总能量比为:

$$C_1 = ER_T = \frac{\frac{1}{mun} \sum_{i,j} (D_T(i, j)^2)}{\frac{1}{mun} \sum_{i,j} (|D(i, j)|)^2} \quad (13)$$

其中,  $mun$  为 HH 子带的总数;  $mun_r$  为满足较小系数条件的子带个数。

2) 噪声能量熵分布的梯度特征平面以及 Zernike 矩阵

在噪声图像亮度能量理论中, 图像的亮度反映了信号的强弱, 而图像的信息量则可以用信息熵来表示, 因此, 若想分析噪声图像的能量紊乱度就可以分析噪声图像的频域能量熵。Zernike 矩阵是一组具有旋转不变性的正交矩阵, 也即旋转目标的条件下不会改变其模值, 而且由于该矩阵可以构造出任意的高阶矩阵, 因此, Zernike 矩阵的识别效果是最优的。如下:

$$C_2 = Z_{mn} = \frac{n+1}{\pi} \int_0^1 \int_0^{2\pi} [V_{mn}(\gamma, \theta)] f(\gamma, \theta) \gamma d\gamma d\theta = \frac{n+1}{\pi} \int_0^1 \int_0^{2\pi} R_{mn}(\gamma) e^{im\theta} f(\gamma, \theta) \gamma d\gamma d\theta \quad (14)$$

式中:  $m, n$  为正整数,  $n - |m| =$  偶数,  $|m| < n$ ;  $\gamma$  是零点到  $(x, y)$  的矢量长度,  $\gamma = \sqrt{x^2 + y^2}$ ,  $x > -1, y < 1$ ,  $R_{mn}(\gamma)$  表示点  $(x, y)$  的径向多项式。

$$R_{mn}(\gamma) = \sum_{s=0}^{(n-|m|)/2} \frac{(-1)^s [(n-s)!] \gamma^{n-2s}}{s! \left( \frac{n+|m|}{2} - s \right)! \left( \frac{n-|m|}{2} - s \right)!} \quad (15)$$

### 3.3 基于 GWO-SVM 图像噪声识别阶段

在图像的噪声识别的过程中, 本文提出一种结合 GWO 和 SVM 的分类器, 即 GWO-SVM 分类器。该分类器通过 GWO 算法来优化 SVM 的参数, 以此来提高样本分类的精确度。SVM 的输入是噪声干扰图像的特征向量和 GWO 初始化参数, 而输出是最佳 SVM 参数和噪声干扰图像的噪声类别。使用不同的核函数(线性, 多层感知器(MLP), 径向基函数(RBF)和多项式)训练和测试 SVM 并进行 3 次交叉验证, 进而得到最佳参数设置和样本分类。

### 3.4 实验结果

实验数据: 把 3 种噪声分别添加到原始图像组成, 总共有 150 幅噪声干扰图像, 其中, 每类噪声干扰图像(根据不同的噪声强度添加到原始图像)有 50 幅图像。

分别把每类噪声干扰图像的 30 个和 20 个图像数据作为训练集和测试集, 因此, 总的训练集为 90 个, 总的测试集为 60 个。共进行了 3 次交叉验证。

本文提出的 GWO-SVM 方法已经被成功应用到实验中, 其中 150 幅噪声干扰图像被应用到训练和测试数据集, 实现了对 GWO-SVM 惩罚因子和核函数最佳的选择。而且不同的内核功能已经过测试。

如图 6 所示, 将所提出的 GWO-SVM 算法应用于

SVM 分类,而获得的分类准确度,使用一对一多类方法和 3 倍交叉验证。

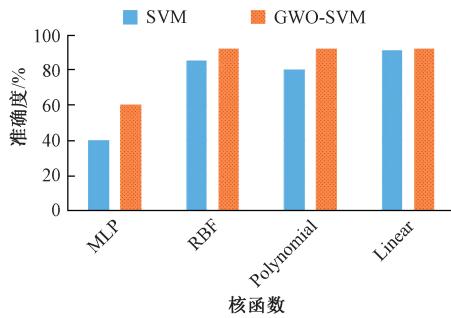


图 6 GWO-SVM 和 SVM 核函数的结果

从图 6 可以看出,没有进行 GWO 优化 SVMs-MLP 核函数的精度非常低,为 39.43%,而使用 GWO-SVM 的精度达到了 60%,这意味着精度提高了 20.57%。对于线性核函数,使用传统的 SVM 实现的准确度是 90.86%,而使用 GWO-SVM 提出的方法,其准确度已经提高到 92%,这意味着使用线性核函数的情况下,其准确度仅增加 1.14%。同样,对于 RBF 核函数,使用传统 SVM 实现的准确度等于 85.14%,而使用 GWO-SVM 提出的方法,它的准确度已经提高到了 92%,这意味着准确度提高了大约 6.86%。对于多项式核函数,使用传统 SVM 的准确度达到 80%,而使用 GWO-SVM 时,准确度提高到 92%,这意味着精度提高了约 12%。SVM 的最佳参数及其核函数如表 1 所示,传统 SVM 及其内核函数的参数如表 2 所示。

表 1 GWO-SVM 的最佳参数

核函数	SVM 的最佳参数	
Linear	$C=2.9$	—
RBF	$C=2.7$	$\sigma=12.7$
Polynomial	$C=3.4$	$d=1.4$
MLP	$\alpha=6.1$	$c_1=-50$

表 2 SVM 的最佳参数

核函数	SVM 的最佳参数	
Linear	$C=10$	—
RBF	$C=1.6$	$\sigma=2$
Polynomial	$C=1.8$	$d=2$
MLP	$\alpha=0.5$	$c_1=0.5$

## 4 结 论

本文提出了一种 GWO-SVM 模型,该模型采用 SVM 分类和 GWO 算法相结合的组合方法,通过选择最优 SVM 参数设置来提高分类精度。拟议的方法包括 3 个主要阶段:预处理,特征提取和 GWO-SVMs 分类。本文所提出

的分类方法已通过使用三重交叉验证应用一对多类 SVM 系统来实现。实验结果表明,所提出的 GWO-SVM 方法分类准确度达到了 92%,明显优于典型的支撑向量机分类算法。

## 参 考 文 献

- [1] 彭浩,刘明生. 自适应 SAR 图像噪声识别和去噪算法研究[J]. 河北省科学院学报,2013,30(2):66-74.
- [2] HUANG H P, LIU Y H. Fuzzy support vector machines for pattern recognition and data mining[J]. International Journal of Fuzzy Systems, 2002, 4(3), 826-835.
- [3] 刘晓亮,丁世飞. SVM 用于文本分类的适用性[J]. 计算机工程与科学,2010,32(6):106-108.
- [4] 谢塞琴,沈福明,邱雪娜. 基于支持向量机的人脸识别方法[J]. 计算机工程,2009,35(16):186-188.
- [5] 朱志宾,丁世飞. 基于 TWSVM 的图像分类[J]. 南京师大学报(自然科学版),2014, 38(3):8-14.
- [6] 李海涛,何玉珠,宋平. 基于量子万有引力搜索的 SVM 自驾故障诊断 [J]. 北京航空航天大学学报,2016, 42(6):1093-1098.
- [7] 张周锁,李凌均,何正嘉. 基于支持向量机故障分类器的参数优化研究[J]. 西安交通大学学报 2003,37(11): 1101-1104,1109.
- [8] 刘东平,单甘霖,张岐龙,等. 基于改进遗传算法的支持向量机参数优化[J]. 网络新媒体技术,2010,31(5): 11-15.
- [9] 路志英,李艳英,陆洁,等. 粒子群算法优化 RBFSVM 沙尘暴预报模型参数[J]. 天津大学学报,2008, 41(4): 413-41.
- [10] 吴震宇,袁惠群. 蚁群支持向量机在内燃机故障诊断中的应用研究[J]. 振动与冲击,2009,28(3):83-86.
- [11] 刘路,王太勇. 基于人工蜂群算法的支持向量机优化[J]. 天津大学学报,2011,44(9):803-809.
- [12] DONG S J, LUO T H. Bearing degradation process prediction based on the PCA and optimized LS-SVM model[J]. Measurement,2013,46(9):3143-3152.
- [13] MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software,2014,69(3):46-61.
- [14] 朱凤明,樊明龙. 混沌粒子群算法对支持向量机模型参数的优化[J]. 计算机仿真,2010,11(27):183-186.
- [15] LONG W, LIANG X M, CAI S H, et al. A modified augmented lagrangian with improved grey wolf optimization to constrained optimization problems[J]. Neural computing and applications, 2017, 28 (1): 421-438.

## 作者简介

田东雨,硕士,主要研究方向为嵌入式技术。

E-mail:tiandyuestc@hotmail.com