

基于 MSCPSO 混合核 SVM 参数优化的生菜品质检测*

孙俊¹ 王艳¹ 金夏明¹ 毛罕平²

(1. 江苏大学电气信息工程学院, 镇江 212013; 2. 江苏大学现代农业装备与技术省部共建重点实验室, 镇江 212013)

摘要: 核函数形式的选择与核函数参数值的大小是影响支持向量机的 2 个关键因素, 传统的支持向量机分类精度低、时效性差, 为了获得高精度、高时效性的支持向量机, 从影响支持向量机的核函数与核函数参数值 2 个关键因素着手, 提出了基于变尺度混沌粒子群优化 (MSCPSO) 混合核 SVM 参数的分类器。将此分类模型用于预测生菜叶片的生育期, 以及预测 3 个生育期的生菜叶片氮素水平, 预测精度分别达到 91.51%、85.38%、82.59% 和 81.26%。与传统的粒子群优化混合核 SVM 的分类器和变尺度混沌粒子群优化 RBF_SVM 分类器相比, 提出的分类器模型分类精度高、时效性好。

关键词: 生菜 品质检测 支持向量机 混合核函数 粒子群算法

中图分类号: TP391 **文献标识码:** A **文章编号:** 1000-1298(2013)09-0209-05

Detection of Lettuce Quality Based on Parameters Optimization of MSCPSO Mixed Kernel SVM

Sun Jun¹ Wang Yan¹ Jin Xiaming¹ Mao Hanping²

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

2. Key Laboratory of Modern Agricultural Equipment and Technology, Ministry of Education, Jiangsu University, Zhenjiang 212013, China)

Abstract: The traditional support vector machine has two faults: low classification accuracy and poor timeliness. In order to obtain support vector machine (SVM) with high accuracy and efficiency, the parameter optimization of SVM with mixed kernels based on mutative scale chaos particle swarm optimization (MSCPSO) was presented. This model was used to predict the growth stage of lettuce leave, which was consist of seedling stage, tillering stage and mature stage, and N content levels of three growth periods respectively. The prediction accuracy achieved to 91.51%, 85.38%, 82.59% and 81.26%. Compared with the traditional particle swarm optimization mixed nuclear SVM classifier and mutative scale chaos particle swarm optimization RBF_SVM classifier, the proposed classifier model showed higher classification accuracy and timeliness.

Key words: Lettuce Detection of quality Support vector machine Hybrid kernel function Particle swarm optimization

引言

目前, SVM 在解决非线性、小样本及高维模式识别问题中表现出计算简单、鲁棒性和有效性等优点^[1], 因而被推广到其他机器学习问题中。SVM 分类性能受惩罚因子 C 、核函数形式及核函数参数值

的影响。因此, 合理的核函数表达式和参数值可以提高 SVM 分类器的分类精度和泛化能力。目前常用的核函数有线性核函数、多项式核函数、径向基核函数以及两层感知器核函数^[2]。RBF 核函数具有学习能力强、泛化性能弱的特点; 而多项式核函数泛化能力强, 学习能力弱。因此目前有学者尝试把这

收稿日期: 2012-09-12 修回日期: 2012-11-26

* 国家自然科学基金资助项目(31101082)和江苏高校优势学科建设工程资助项目(苏政办发[2011]6号)

作者简介: 孙俊, 副教授, 主要从事图像信号处理及农作物无损检测研究, E-mail: sun2000jun@ujs.edu.cn

两类核函数混合起来组成一个新的核函数作为训练 SVM 分类器的核函数,弥补其单独使用时存在的不足。参数的优化是 SVM 需要解决的另一大难题,目前 SVM 参数选取方法主要有:经验选择法、实验试凑法、梯度下降法、交叉验证法^[3~6]等,同时随着智能优化方法的成功,陆续有学者采用遗传算法、粒子群算法^[7~8]等方法优化选择 SVM 参数。但这些方法各有其缺陷,遗传算法收敛速度慢且早熟;粒子群优化算法易陷入局部最优值,局部搜索能力差。鉴于混沌优化的随机性、遍历性、对初始条件的敏感性等特点,本文采用文献[9]的方法,将混沌优化理论引用到粒子群优化算法中,根据生菜叶片所呈现出的特征数据判断生菜叶片的品质。

1 基于混合核函数的支持向量机

1.1 支持向量机原理

支持向量机是借助最优化方法解决机器学习问题的新工具^[10],主要原理如下:

设样本集为 (x_i, y_i) ($i = 1, 2, \dots, N$), N 为训练集样本数量。其中, $x_i \in \mathbf{R}_n$ 为样本特征, $y_i \in \{+1, -1\}$ 为样本类别。若训练集为非线性时,需通过非线性函数将训练集数据映射到一个高维线性特征空间,并在这个特征空间中构造最优分类超平面,表达式为

$$f(x) = \omega \phi(x) + b = 0 \quad (1)$$

式中 $\phi(x)$ ——非线性函数

ω ——超平面的法向量

b ——超平面的偏移量

ω 和 b 共同决定了最优分类面的位置。

由于分类前不确定样本是否为线性,所以允许一部分样本被错分,可通过引入松弛变量 ξ_i , 并使 $\sum \xi_i$ 达到最小,即错分样本最少。分离面的优化问题变成求

$$\min \left\{ \frac{1}{2} \|\omega\|^2 \right\} + C \sum_{i=1}^l \xi_i$$

约束条件为

$$\begin{cases} y_i(\omega x_i + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \end{cases} \quad (i = 1, 2, \dots, l)$$

式中 C ——惩罚因子

训练样本 x_i 通过函数 Ψ 被映射到一个更高维数空间中,该超平面能使样本在此空间中具有最大分类间隔,引入 Lagrange 因子,得到超平面的决策函数

$$f(x) = \text{sign} \left(\sum a_i y_i (\Psi(x) \cdot \Psi(x_i)) + b \right) \quad (2)$$

其中 $0 \leq a_i \leq C$ 对应的点称为支持向量。

1.2 核函数的选择

通过引入松弛变量可以解决一些近似线性可分问题,但仍有一些问题无论如何修改松弛变量都不能当成近似线性的问题来解决^[11]。为了解决这类问题,根据泛函相关理论,可以找到一个满足 Mercer 条件核函数 $K(x, x_i)$ 来代替点积 $(\Psi(x) \cdot \Psi(x_i))$, 得到 SVM 的判决函数

$$f(x) = \text{sign} \left(\sum a_i y_i k(x \cdot x_i) + b \right) \quad (3)$$

核函数的引入避免了在高维特征空间进行复杂的运算,但是不同的核函数得到的分类模型不同,因此核函数的选择成为支持向量机研究核心问题之一。目前存在的核函数主要包括:线性核函数、多项式核函数、径向基核函数、S 形内核函数,把这几种核函数归集起来可分为两类:局部核函数和全局核函数。局部核函数在测试点附近的小领域内对数据点影响较大,因此具有较强的学习能力,但泛化能力弱,而全局核函数恰恰相反。RBF 核函数是典型的局部核函数,多项式核函数是典型的全局核函数。将二者线性组合成一个混合核函数,弥补各自的局限性,具体形式^[12]为

$$K_{\text{mix}} = \tau K_{\text{poly}} + (1 - \tau) K_{\text{rbf}} \quad (4)$$

其中 $\tau \in (0, 1)$ $K_{\text{poly}} = (x \cdot x_i + 1)^q$

$$K_{\text{rbf}} = \exp \left(- \frac{\|x - x_i\|^2}{2\sigma^2} \right)$$

此混合核函数满足 Mercer 条件,核函数的混合使需要优化的 SVM 参数比原来多了一个参数 τ 。 τ 可改变混合核函数中原核函数的权重,实验得到的 τ 的值一般在 0.50 ~ 0.99,当 τ 值较大时更能体现混合核函数的性能。多项式核函数 $K(x, x_i) = (x \cdot x_i + 1)^q$, q 值一般取 1 或 2。

2 支持向量机分类器模型的参数优化

2.1 支持向量机分类器模型参数的影响分析

影响支持向量机分类精度的参数是:惩罚因子 C 、核函数参数 σ 和权重因子 τ 。

(1) 惩罚因子 C 能够在结构风险和样本误差之间做出折中, C 越大对数据的拟合程度越高,但泛化能力会降低。因此在对参数组合进行寻优时,当有几组组合都可以取得相同的识别率时,一般取 C 值较小的那组。

(2) 本文所定的混合核函数, q 值一般取 1 或 2, σ 值对分类精度影响很大^[13], σ 太小,支持向量间的联系就会松弛; σ 太大,支持向量间的影响就会过强,模型精度难以满足要求。

(3) 权重因子 τ 可以改变混合核函数中原核函

数的权重, $\tau \in [0.5, 0.99]$ 。

由上可知, 如何寻找一个精确、快速、稳定的算法来实现对参数的优化具有重要的意义。进化算法是一种具有鲁棒性的方法, 能在大多数情况下得到比较满意的解。遗传算法和粒子群算法是具有代表性的两类进化算法, 由于遗传算法具有收敛速度慢、早熟的缺陷, 所以, 本文就针对改进的粒子群算法进行研究和实验。

2.2 粒子群优化算法的参数优化

PSO 算法采用速度-位置搜索模型^[14], 具体的数学描述如下: 设粒子群体规模为 N , 其中每个微粒在 D 维空间中的坐标位置可表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$; 微粒 i ($i = 1, 2, \dots, N$) 的速度用 $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ 表示; $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ 表示微粒 i ($i = 1, 2, \dots, N$) 的个体历史最优位置, $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ 表示目前群体历史最优位置。在第 n 次迭代中, 微粒 i ($i = 1, 2, \dots, N$) 的速度与位置调整公式为

$$v_{ij}(n) = \left[\lambda_{\min} + \frac{(T_{\max} - t)(\lambda_{\max} - \lambda_{\min})}{T_{\max}} \right] v_{ij}(n-1) + \Delta v_{ij}(n) \quad (6)$$

$$x_{ij}(n) = x_{ij}(n-1) + v_{ij}(n) \quad (7)$$

其中 $\Delta v_{ij}(n) = c_1 r_1 [p_{ij}(n-1) - x_{ij}(n-1)] + c_2 r_2 [p_{gj}(n-1) - x_{ij}(n-1)] \quad (8)$

式中 $v_{ij}(n)$ ——第 n 次迭代的速度
 λ_{\max} 、 λ_{\min} ——最大、最小权重因子, 通常 λ_{\max} 取 0.9, λ_{\min} 取 0.4
 c_1 、 c_2 ——学习因子, 通常 $c_1 = c_2 = 2.0$
 r_1 、 r_2 ——(0, 1) 之间的随机数
 t ——当前迭代次数
 T_{\max} ——总的迭代次数

2.3 变尺度的混沌粒子群优化算法

粒子群优化算法简单, 但是它具有局部搜索能力差, 易陷入局部最优点, 进化后期收敛速度慢等缺陷。由于混沌运动具有遍历性、随机性、对初始条件的敏感性等特点, 本文采用文献[9]的方法, 将变尺度混沌思想引入粒子群优化算法, 以每次寻优操作得到的本次操作最优值为中心动态地缩小区间, 然后重复寻优操作, 直至找到全局最优值。这样不仅提高了种群的多样性和粒子搜索的遍历性的能力, 而且提高了基本粒子群优化算法的收敛速度和精度。混沌序列为

$$x_{n+1} = \mu x_n (1 - x_n) \quad (9)$$

式中 μ ——控制参量

当 $\mu = 4$ 时, 该系统完全处于混沌状态。由任意初值 x_0 经过迭代运算, 可以确定一个的时间序列 x_0, x_1, \dots, x_n 。

设当前最优位置 x 的搜索区间为 $[x_1, x_2]$, 经过一次寻优操作后得到的本次操作最优值为 x^* , 变尺度操作计算式为

$$\begin{cases} x_1^{\gamma+1} = x^* - \kappa(\gamma)(x_2^\gamma - x_1^\gamma) \\ x_2^{\gamma+1} = x^* + \kappa(\gamma)(x_2^\gamma - x_1^\gamma) \end{cases} \quad (10)$$

其中, $\kappa \in (0, 0.5)$, κ 愈大, 搜索区间缩减程度愈小; γ 是变尺度操作次数。如果 $x_1^{\gamma+1} < x_1^\gamma$ 或 $x_2^{\gamma+1} < x_2^\gamma$, 则 $x_1^{\gamma+1} = x_1^\gamma$; 如果 $x_2^{\gamma+1} > x_2^\gamma$, 则 $x_2^{\gamma+1} = x_2^\gamma$ 。变尺度混沌搜索的目的是让算法在初期搜索范围较大, 避免过早陷入局部最优, 同时让算法在后期搜索范围缩小, 以提高搜索精度。因此获取 κ 值计算式为

$$\kappa(\gamma) = \frac{\frac{1}{2}}{1 + \exp\left(4 - \frac{1}{2}\gamma\right)} \quad (11)$$

式中 γ ——当前已经进行变尺度操作的次数

此方法帮助惰性粒子逃离局部极小点, 从而快速搜寻到最优解。

2.4 MSCPSO 的混合核 SVM 参数优化

具体流程如图 1 所示。

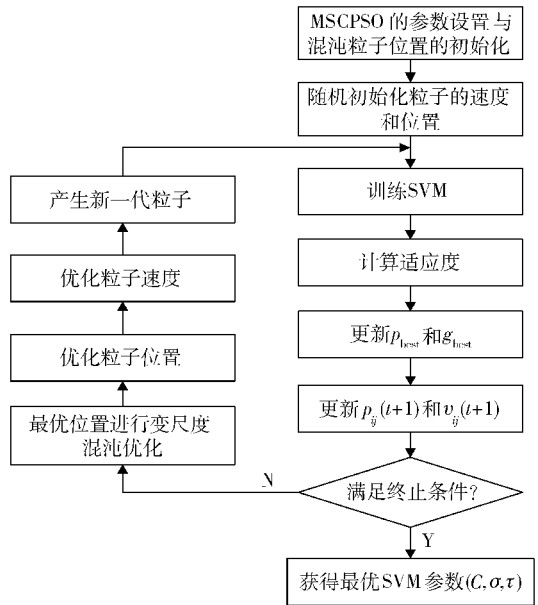


图 1 变尺度混沌粒子群的支持向量机参数优化过程
 Fig. 1 Parameter optimization process of SVM based on MSCPSO

3 实验与分析

3.1 数据源

本文的分类算法用于检验生菜叶片中的氮素含量情况, 由于不同的生育期对氮素含量的要求不同, 因此训练得到的支持向量机模型也不同。首先要判断出生菜叶片所处的生育期, 然后, 判断每个生育期的生菜叶片的氮素水平。因此, 在数据采集时, 将生

菜叶片按照生长周期分为3个生育期:幼苗期、发棵期和成熟期,在每个生育期内分别获得3个不同氮素水平(正常、缺氮和过氮)的生菜叶片。

3.1.1 图像的获取

实验所选的装置为:数码相机和相机三脚架,数码相机的型号为佳能60D,有效像素1800万。将数码相机固定在相机三脚架上,使相机与生菜叶片的距离大约保持20 cm,拍摄时间均在11:00至13:00之间,以确保充足的光照。为了解决生菜叶片表面凹凸不平导致光照不均的问题,采用LED灯对其光照进行补偿,并且在后续图像预处理中采用图像增强以及直方图均衡化等处理,在一定程度上提高分类精度。

3.1.2 特征提取及优化

将采集的生菜叶片经过图像增强、图像分割、膨胀和腐蚀等一系列预处理之后,提取能够反映生菜生长状况的特征值,例如:平滑度、熵、粗糙度、对比度、颜色矩等26个特征值,由于特征值的数量(维数)直接影响训练支持向量机的时间,所以,在不丢失有用特征信息的前提下,尽可能地降低特征值的数量,本文选择主成分分析法对原始数据降维,使累计贡献率不小于98%,最终获得12个主成分。

3.1.3 数据类别

生菜生育期包括:幼苗期、发棵期和成熟期。因为本实验的目的是定性分析生菜叶片中氮素水平(缺氮、正常和过氮),由于每个生育期对氮素水平的要求不同,所以要判断生菜叶片的氮素水平,首先要确定生菜叶片所属的生育期,然后对每个生育期的生菜叶片氮素水平进行判断。因此,实验数据所包含的信息不仅能够判断出生菜叶片所处的生育期,而且能够判断出生菜叶片是否缺氮、正常和过氮。

(1)生育期的判断。取360个样本数据,其中幼苗期、发棵期和成熟期各120个样本,取其270个为训练样本,其中幼苗期、发棵期和成熟期各90个,剩余的90个为测试样本,包括幼苗期、发棵期和成熟期各30个。

(2)氮素水平的判断。每个生育期取120个样本,其中正常、缺氮和过氮各40个样本,取90个训练样本,其中正常、缺氮和过氮各30个,剩余30个为测试数据,包括幼苗期、发棵期和成熟期各10个。

对以上数据分别用变尺度混沌粒子群优化支持向量机参数算法、粒子群优化混合核支持向量机参数算法和本文提出两者相结合的方法对这4组数据实验,比较分类效果。

3.2 参数设置

MSCPSO优化混合核SVM参数算法的参数设

置如下:粒子群的种群规模为20, $c_1 = c_2 = 2$,迭代最大次数为200。同时文中对 C 、 σ 和 τ 3个参数采用二进制编码,其中 C 的搜索范围设置为 $[0.01, 1000]$, σ 的搜索范围设置为 $[0.1, 100]$, τ 的取值范围为 $[0.5, 0.99]$, $r_1, r_2 \in [0, 1]$, $x_{\max} = v_{\max} = 50$ 。

算法的结束条件为:最大进化代数超过200代或连续10代最优解之差的绝对值小于0.001,则寻优过程停止,此时的参数为支持向量机要求的最优参数,如果同时有多组数据满足要求,则选取 C 值最小的那组参数为最优参数。

3.3 结果与分析

本文所涉及的算法都是在 faruto 编写的 Libsvm-mat 加强工具箱的辅助下实现的。其自带基于一对一算法的多分类模型,便于直接运用。实验是以分类误差为适应度函数,本文分别给出了适应度值即分类误差随迭代次数的变化曲线(实验采用的是幼苗期生菜叶片的特征数据),图2表示基于PSO的混合核SVM参数算法的最优个体适应度的变化曲线,其最优个体适应度为0.00097;图3表示基于MSCPSO的RBF_SVM参数算法的最优个体适应度的变化曲线,其最优个体适应度为0.00060;图4表示基于MSCPSO的混合核SVM参数算法的最优个体适应度的变化曲线,其最优个体适应度为0.00034。




图2 基于PSO的混合核SVM参数算法的优化过程曲线

Fig.2 Parameters optimization of PSO mixed kernel SVM




图3 基于MSCPSO的RBF_SVM参数算法的优化过程曲线

Fig.3 RBF_SVM parameters optimization based on MSCPSO




图4 基于 MSCPSO 的混合核 SVM 参数算法的优化过程曲线

Fig.4 Parameter optimization based on MSCPSO mixed kernel SVM

表1 为基于 PSO 的混合核 SVM 参数算法、基于 MSCPSO 的 RBF_SVM 参数算法和基于 MSCPSO 的混合核 SVM 参数算法分别训练 4 组数据得到最优参数所需要的时间。从表中可以得出:与基于 PSO 的混合核 SVM 参数算法和基于 MSCPSO 的 RBF_SVM 参数算法相比,基于 MSCPSO 的混合核 SVM 参数算法得到最优参数组合所需的时间较短,分类

表1 各种优化算法得到最优参数所需的时间

Tab.1 Time for obtaining the optimal parameters by different optimization algorithm

数据集	基于 PSO 的混合核 SVM 参数算法	基于 MSCPSO 的 RBF_SVM 参数算法	基于 MSCPSO 的混合核 SVM 参数算法
生育期的判断	109.37	108.69	93.16
幼苗期氮素水平判断	135.88	127.55	108.33
发棵期氮素水平判断	121.64	100.45	97.51
成熟期氮素水平判断	128.98	115.84	97.32

时效性有所提高。

表2 分别为 4 组数据通过基于 PSO 的混合核 SVM 参数算法、基于 MSCPSO 的 RBF_SVM 参数算法以及基于 MSCPSO 的混合核 SVM 参数算法得到的最优参数组合以及在最优参数组合下训练支持向量机所得到的分类精度。由表中数据可以得出,基于 MSCPSO 的混合核 SVM 参数算法训练得到的支持向量机模型分类精度最高,生育期与各生育期氮素水平分类精度分别为: 91.51%、85.38%、82.59%、81.26%。

表2 通过各种优化算法得出的分类精度

Tab.2 Classification accuracies obtained by different optimization algorithms

数据集	基于 PSO 的混合核 SVM 参数算法		基于 MSCPSO 的 RBF_SVM 参数算法		基于 MSCPSO 的混合核 SVM 参数算法	
	(C,σ,τ)	分类精度/%	(C,σ)	分类精度/%	(C,σ,τ)	分类精度/%
生育期判断	(7.49,0.67,0.59)	87.32	(7.78,0.56)	86.50	(6.51,0.63,0.79)	91.51
幼苗期氮素水平判断	(18.33,2.17,0.64)	83.47	(19.57,1.59)	80.32	(18.4,0.9,0.76)	85.38
发棵期氮素水平判断	(33.26,1.54,0.79)	73.54	(35.11,0.96)	76.83	(34.27,1.17,0.83)	82.59
成熟期氮素水平判断	(38.67,3.31,0.45)	78.57	(40.76,3.22)	72.91	(36.15,2.97,0.87)	81.26

4 结束语

从影响支持向量机性能的两个因素入手,提出 MSCPSO 优化混合核 SVM 参数的分类模型,该方法不但继承了 RBF 核函数的学习能力强,多项式核函数的泛化能力强的优点,而且保持了基本 PSO 算法的简单、

易实现等优点,弥补 PSO 算法收敛速度慢、后期振荡、容易陷入局部最小值点等缺陷,取得最佳的参数组合。分类结果表明, MSCPSO 的混合核 SVM 参数优化方法时效性最好,分类精度最高,生菜生育期与各生育期氮素水平分类精度分别为 91.51%、85.38%、82.59%、81.26%。

参 考 文 献

- 1 石峰,王小川,郁磊,等. MATLAB 神经网络 30 个案例分析[M]. 北京:北京航空航天大学出版社,2010.
- 2 奉国和. SVM 分类核函数及参数选择比较[J]. 计算机工程与应用,2011,47(3):123~124.
Feng Guohe. Parameter optimizing for support vector machines classification[J]. Computer Engineering and Applications,2011,47(3):123~124. (in Chinese)
- 3 刘伟,王建平,刘长虹,等. 基于粒子群寻优的支持向量机番茄红素含量预测[J]. 农业机械学报,2012,43(4):143~147,155.
Liu Wei, Wang Jianping, Liu Changhong, et al. Lycopene content prediction based on support vector machine with particle swarm optimization[J]. Transactions of the Chinese Society for Agricultural Machinery,2012,43(4):143~147,155. (in Chinese)
- 4 Bazi Y, Melgani F. Semisupervised PSO-SVM regression for biophysical parameter estimation [J] // IEEE Transactions on Geoscience and Remote Sensing, 2007,45(6): 1 887~1 895.
- 5 Bazi Y, Melgani F. A multiobjective PSO inflation methodology for SVM regression with limited training samples [C] // IEEE International Geoscience and Remote Sensing Symposium, 2007:4 360~4 363.

- winter wheat's biomass using digital photographs[J]. *Resource Development & Market*, 2011,27(3):193~196. (in Chinese)
- 7 Ehlert D, Hammen V, Adamek R. On-line sensor pendulum-meter for determination of plant mass[J]. *Precision Agriculture*, 2003,4(2):139~148.
- 8 Scrivner J H, Center D M, Jones M B. A rising plate meter for estimating production and utilization[J]. *Journal of Range Management*,1986,39(5):475~477.
- 9 Goldberg H. What is virtual instrumentation[J]. *IEEE Instrumentation & Measurement Magazine*,2000,3(4):10~13.
- 10 孟武胜,朱剑波,黄鸿,等. 基于 LabVIEW 数据采集系统的设计[J]. *电子测量技术*,2008,31(11):63~65.
Meng Wusheng, Zhu Jianbo, Huang Hong, et al. Data acquisition system based on LabVIEW[J]. *Electronic Measurement Technology*, 2008,31(11):63~65. (in Chinese)
- 11 郑珊珊,黄元庆. 测试系统的虚拟仪器设计[J]. *机电工程技术*,2005,34(3):44~46.
- 12 邓焱,王磊. LabVIEW7.1 测试技术与仪器应用[M]. 北京:机械工业出版社,2004.
- 13 杨乐平,李海涛,杨磊,等. LabVIEW 程序设计与应用[M]. 2版. 北京:电子工业出版社,2005.
- 14 何勇,林丽兰,俞海红. 基于虚拟仪器技术的土壤电导率测量仪器研究[J]. *农业工程学报*,2004,20(6):31~34.
He Yong, Lin Lilan, Yu Haihong. Measuring instrument for soil electric conductivity based on virtual instrument technology[J]. *Transactions of the CSAE*, 2004,20(6):31~34. (in Chinese)
- 15 介战,罗四倍,周学建. 基于 LabVIEW 的联合收割机水稻喂入量遥测试验[J]. *农业工程学报*,2009,25(13):87~91.
Jie Zhan, Luo Sibe, Zhou Xuejian. LabVIEW-based telemetering experiments of rice feed quantity for combined harvester[J]. *Transactions of the CSAE*, 2009,25(13):87~91. (in Chinese)
-

(上接第 213 页)

- 6 Mustafa M W, Sulaiman M H, Shareef H, et al. An application of genetic algorithm and least squares support vector machine for tracing the transmission loss in deregulated power system[C]//*IEEE Power Engineering and Optimization Conference (PEOCO)*, 2011:375~380.
- 7 李有梅,王梦云. 离散神经网络的优化能力研究[J]. *山西大学学报:自然科学版*,2002,25(3):208~213.
Li Youmei, Wang Mengyun. The performance of discrete neural network on combinatorial optimization problem[J]. *Journal of Shanxi University: Natural Science Edition*, 2002,25(3):208~213. (in Chinese)
- 8 Ozbeyaz A, Gursoy M I, Coban R. Regularization and kernel parameters optimization based on PSO algorithm in EEG signals classification with SVM[C]//*IEEE Signal Processing and Communications Applications (SIU)*, 2011:399~402.
- 9 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*,2010,27(11):183~186.
Zhu Fengming, Fan Minglong. Chaos particle swarm optimization algorithm for optimizing the parameter of SVM [J]. *Computer Simulation*, 2010,27(11):183~186. (in Chinese)
- 10 Hric M, Chmulik M, Jarina R. Model parameters selection for SVM classification using particle swarm optimization[C]//*IEEE Radioelektronika (RADIOELEKTRONIKA) 2011 21st International Conference*, 2011:1~4.
- 11 Guo X C, Liang Y C, Wu C G. Content determination by PSO-based LS-SVM regression [C]// *IEEE 2009 International Conference on Machine Learning and Cybernetics*, 2009:1043~1047.
- 12 王佳,徐蔚鸿. 基于动量粒子群的混合核 SVM 参数优化方法[J]. *计算机应用*,2011,31(2):501~503,516.
Wang Jia, Xu Weihong. Parameter optimization of mixed kernel SVM based on momentum particle swarm optimization [J]. *Journal of Computer Applications*, 2011,31(2):501~503,516. (in Chinese)
- 13 Samadzadegan F, Soleymani A, Abbaspour R A. Evaluation of genetic algorithms for tuning SVM parameters in multi-class problems[C]//*IEEE Computational Intelligence and Informatics (CINTI)*, 2010:323~328.
- 14 冯景新,钟伟民,钱锋. 变尺度混沌量子粒子群算法[J]. *华东理工大学学报:自然科学版*,2008,34(5):714~718.
Feng Jingxin, Zhong Weimin, Qian Feng. An scale chaos quantum particle swarm algorithm[J]. *Journal of East China University of Science and Technology: Natural Science Edition*, 2008,34(5):714~718. (in Chinese)