

基于双变异粒子群优化算法优化的支持向量机及其在民航发动机损伤类型识别中的应用

郑波¹ 马昕²

1 中国民航飞行学院教务处 四川 广汉 618307

2 中国民航飞行学院空中交通管理学院 四川 广汉 618307

(b_zheng1@126.com)

摘要 为提高民航发动机损伤类型识别的自动化水平和可靠度,增强民航发动机的维修保障能力,本文利用颜色矩和灰度共生矩阵(Gray Level Co-occurrence Matrix,GLCM)来构造基于发动机无损检测图像的特征数据库,同时将支持向量机(Support Vector Machine,SVM)作为智能识别算法。为保障 SVM 可靠稳定的识别性能,提出利用双变异的粒子群优化(Dual Mutation Particles Swarm Optimization,DMPSO)算法对核参数和惩罚因子进行优化,双变异策略提升了 PSO 的全局寻优能力,一些复杂的测试函数验证了 DMPSO 的全局寻优能力。最后根据某型发动机的 4 种损伤类型图像,按照不同的特征提取方法构造特征数据库,分别利用本文所提的 DMPSO 优化的 SVM、BP(back propagation)网络、ELM(Extreme Learning Machines)网络以及 k-NN(k-nearest neighborhood)算法进行损伤类型识别,识别结果证明了文中所提的特征提取方法更适合发动机损伤识别,有利于提高损伤识别精度。同时比较了 4 种识别算法的性能,基于 DMPSO 优化的 SVM 具有更优、更稳定的识别输出。对比实验证明了所提方法有利于提升民航发动机损伤类型的识别效率。

关键词: 颜色矩; 灰度共生矩阵; 粒子群优化算法; 支持向量机; 损伤类型识别

中图法分类号 V263.6;TP277

Application on Damage Types Recognition in Civil Aeroengine Based on SVM Optimized by DMPSO

ZHENG Bo¹ and MA Xin²

1 Academic Affairs Office, Civil Aviation Flight University of China, Guanghan, Sichuan 618307, China

2 College of Air Traffic Control, Civil Aviation Flight University of China, Guanghan, Sichuan 618307, China

Abstract In order to recognize the damage types of aeroengine automatically and reliably, enhance the capability of aeroengine maintenance support, the feature extraction method based on color moments and gray level co-occurrence matrix (GLCM) is proposed to construct the feature database of the aeroengine's non-destructive detection images, and the support vector machine (SVM) is utilized as intelligent classifier for damages recognition. A dual mutation particles swarm optimization (DMPSO) algorithm is designed to optimize the kernel parameter and penalty factor for guaranteeing the recognition performance of SVM, dual mutation strategy improves the global optimization capability, and some complex test functions have been used to prove DMPSO's performance. Finally, the feature databases are constructed by different feature methods according to four damage types of certain aeroengine, and then the proposed SVM optimized by DMPSO is used for damage types recognition compared with back propagation (BP) network, extreme learning machine (ELM) network, and k-nearest neighborhood (k-NN). The recognition results have proven the proposed feature extraction method is more suitable for aeroengine damage recognition and is helpful to improve the accuracy of damage recognition. Meanwhile, the recognition performances of the four algorithms are compared, and the comparison results have demonstrated the optimized SVM always has better and stable recognition output. The comparison experiment has proven that the methods proposed in this paper are helpful to improve the recognition efficiency of aeroengine damage types.

Keywords Color moments, GLCM, PSO, SVM, Damage types recognition

1 引言

保障民航飞机安全飞行是民航业的生命线。发动机作为高度集成化、精密化的复杂工业产品,向飞机运行提供充足的动力,是保障飞行安全的关键系统。根据全球民航业数据统计,

基金项目:四川省科技计划项目(2019YJ0720);中国民用航空局发展基金教育人才类项目(14002600100018J034);中国民航飞行学院面上项目(2019-53);中国民航飞行学院青年基金项目(Q2018-139)

This work was supported by the Project of Sichuan Province Science and Technology Program (2019YJ0720), China Civil Aviation Administration Development Foundation Educational Talents Program (14002600100018J034), General Foundation of Civil Aviation Flight University of China(2019-053) and Youth Foundation of Civil Aviation Flight University of China(Q2018-139).

通信作者:马昕(ttccll123321@126.com)

由发动机引起的飞行事故占比约为 50%，而发动机的维修支出约占到所有支出成本的 40%^[1]。因此，开展高效、精准的民航发动机维修决策研究，对保障飞行安全、降低维护成本、提高运行效率具有重要意义。

民航发动机长期在高温、高压、高载荷的严苛环境下运行，各级轮盘、叶片、涡轮、燃油喷嘴等关键部件容易受到各类冲击载荷作用，产生裂纹、腐蚀、撕裂、烧伤、掉块等各类损伤。这不仅会使发动机产生性能衰退，还容易导致发动机工作失效，严重时甚至威胁到飞行安全，造成严重后果。借助无损检测技术，能准确探测到发动机内部产生的结构损伤并形成图像信息。确定发动机损伤类型是发动机图像分析技术的关键环节，对进一步判断损伤机理、确定损伤部件、评估受损程度具有指导作用。基于数字图像处理技术的损伤识别依然依赖专家经验，但发动机结构复杂，损伤种类多样、特征繁多，传统的依赖专家经验的方法越来越难以胜任对损伤类型的精确识别。随着现代智能识别技术的快速发展，人工神经网络、深度学习和统计模式识别等方法被广泛应用于模式识别^[2-4]，使发动机的损伤类型检测与识别摆脱了对专家经验的过度依赖，提高了识别准确率，从而为发动机的维修保障提供了可靠的技术支持。

研究表明：由于人工神经网络一直存在收敛性和泛化能力差的缺点，且网络参数和拓扑结构设定方面存在不确定性，增加了其应用难度^[5]。深度学习对样本数量要求较高，且算法运行效率较低，降低了实时性要求^[6]。而统计模式识别对样本的概率分布比较敏感^[7]。SVM 作为经典的机器学习算法是建立在统计学习理论的 VC (Vapnik-Chervonenkis) 维理论和结构风险最小原理基础上的，具有完备的理论基础和可解释性，在模式识别、回归估计中被广泛使用，特别是核函数的引入，拓展了 SVM 的应用范围，使 SVM 成为最受欢迎的机器学习算法^[8-9]。因此，本文将采用 SVM 作为发动机损伤类型识别的方法。

同其他机器学习算法一样，参数调节是影响算法性能的主要因素。本文提出了一种改进的粒子群优化 (Particles Swarm Optimization, PSO) 算法，通过增强种群的多样性、平衡探索和开发能力，使 PSO 算法具有良好的全局寻优能力，从而实现对 SVM 参数的优化，以提高 SVM 在发动机损伤类型识别中的准确率和稳定性。

2 基于颜色特征和纹理特征的损伤数据库

图 1 显示了对发动机损伤类型的识别过程。利用无损检测获得不同的损伤图像后，关键是要形成数字化的图像特征表示，以构建发动机损伤数据库，为训练 SVM 提供原始样本。

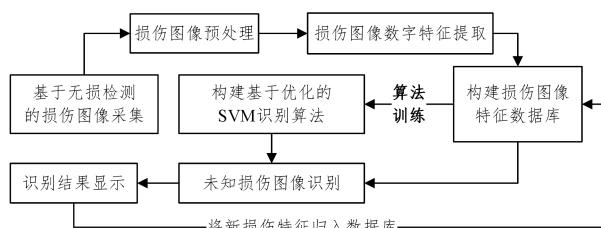


图 1 发动机损伤图像识别过程

Fig. 1 Process of aeroengine damage images recognition

2.1 基于颜色矩和 GLCM 的特征提取

对图像的颜色、纹理、形状等底层特征的分析提取，已成

为当今工业界和学术界广泛应用的方法，国内外也已取得了较为丰富的研究成果，文献[10]提出了基于 HSV 空间的颜色特征提取方法，文献[11]利用 GLCM 的统计量来描述图像的纹理特征，文献[12]通过融合 GLCM 特征和 Tamura 特征，得到新的图形数字特征。通常，图像的颜色特征具有较强的鲁棒性，是反映发动机损伤部位最直观、最明显的特征；而纹理特征反映的是物体表面的结构特点以及周围的环境信息，是图像灰度化的属性。根据损伤图像特点，本文提出了一种基于颜色矩特征和 GLCM 纹理特征(CM-GLCM)的图像特征提取方法。

设 $\mathbf{R}, \mathbf{G}, \mathbf{B}$ 为发动机损伤图像的红色、绿色、蓝色分量矩阵，按照人眼对不同色系的敏感程度，对 $\mathbf{R}, \mathbf{G}, \mathbf{B}$ 三分量进行加权平均获得图像的灰度化，其计算公式如下：

$$f(i,j) = 0.30 \cdot \mathbf{R}(i,j) + 0.59 \cdot \mathbf{G}(i,j) + 0.11 \cdot \mathbf{B}(i,j) \quad (1)$$

其中， f 表示图像的灰度矩阵。获得灰度化的损伤图像后，通过计算的矩来描述颜色的统计特征。通常，颜色分布信息主要集中在低阶矩，因此采用前三阶矩来表明图像的颜色分布，其计算公式如下：

$$\mu = \frac{1}{N} \sum_{i,j} p_{ij} \quad (2)$$

$$\sigma = \left[\frac{1}{N} \sum_{i,j} (p_{ij} - \mu)^2 \right]^{\frac{1}{2}} \quad (3)$$

$$\zeta = \left[\frac{1}{N} \sum_{i,j} (p_{ij} - \mu)^3 \right]^{\frac{1}{3}} \quad (4)$$

其中， N 为矩阵的像素数量； p_{ij} 为第 i 行 j 列的像素点； μ 为一阶矩，也叫矩阵的均值，表示灰度图像的平均强度； σ 为二阶矩，也叫矩阵的方差，反映了灰度图像的不均匀性；而 ζ 为三阶矩，也叫矩阵的偏度，定义了灰度图像的不对称性。

灰度共生矩阵(GLCM)是指一种通过研究灰度的空间相关特性来描述纹理的常用方法，是 Haralick 等^[13]于 20 世纪 70 年代初提出的。GLCM 是对灰度图像上保持距离为 d ，方向为 θ 的两个像素分别具有某灰度的状况进行统计获得的，反映了灰度图像关于方向、间隔和幅度变化的综合信息，是分析图像局部模式的基础。关于 GLCM 的定义、计算过程，可参见文献[12-13]。为了能够以 GLCM 来更直观地描述图像纹理特征，本文采用角二阶矩(Angular Second Moment, ASM)、对比度(contrast)、相关性(correlation)、熵(entropy)和逆差矩 (Inverse Different Moment, IDM) 来表征 GLCM 反映的纹理特征，具体计算公式如下：

$$ASM = \sum_{i,j} p_{ij}^2 \quad (5)$$

$$CON = \sum_{i,j} (i-j)^2 p_{ij} \quad (6)$$

$$COR = \frac{\sum_{i,j} (i-\mu_i)(j-\mu_j) p_{ij}}{\sigma_i \sigma_j} \quad (7)$$

$$ENT = - \sum_{i,j} p_{ij} \lg p_{ij} \quad (8)$$

$$IDM = \sum_{i,j} \frac{p_{ij}}{1 + (i-j)^2} \quad (9)$$

$$\text{其中, } \mu_i = \sum_j p_{ij} \quad (10)$$

$$\mu_j = \sum_i p_{ij} \quad (11)$$

$$\sigma_i = \sum_j (i-\mu_i)^2 p_{ij} \quad (12)$$

$$\sigma_j = \sum_i (j-\mu_j)^2 p_{ij} \quad (13)$$

角二阶矩反映了图像灰度分布的均匀程度和纹理粗细程度，当 GLCM 中元素集中分布时，ASM 有相对较大的值，表

明灰度图像是一种较为均匀的纹理模式。对比度反映了灰度图像的清晰度,一般图像沟纹越深,CON 越大,视觉效果就越清晰。相关性度量了 GLCM 中行元素或列元素的相似度,当元素均匀相等时,COR 较大,反映了图像中局部灰度相关。熵是图像所携带的随机信息的度量,当 GLCM 中元素分散分布时,ENT 通常较大,表示此时图像具有较大的非均匀程度和复杂程度。而逆差矩反映图像纹理的粗糙度,粗纹理的IDM 较大,反之较小。

至此,提取了灰度图像的颜色矩特征和 GLCM 纹理特征 8 个,用于描述发动机损伤图像,进而构建发动机损伤图像数据库,为自动识别提供样本支撑。图 2 所示为图像特征提取的流程图。

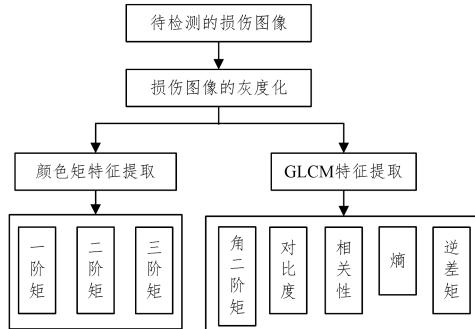


图 2 图像特征提取流程图

Fig. 2 Flowchart of image feature extraction

2.2 构建发动机损伤图像特征数据库

收集某型民航发动机在无损检测过程中的 4 类损伤图像,图 3 显示了每类当中的其中一张损伤图像。

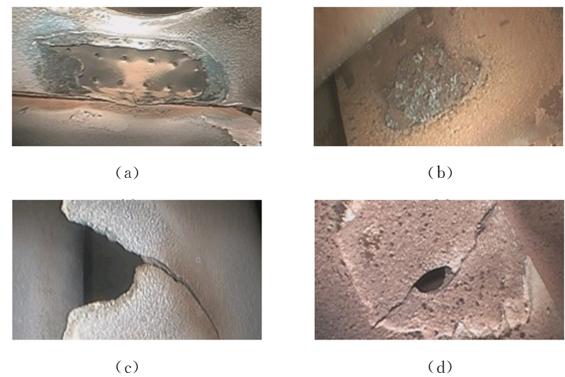


图 3 某型发动机损伤图像

Fig. 3 Damage images of a certain aeroengine

图 3(a)所示为发动机燃油喷嘴隔板(fuel nozzle baffle)烧穿损伤,图 3(b)所示为高压涡轮动叶(high pressure turbine blade, HPT blade)烧蚀损伤,图 3(c)所示为高压压气机叶片后缘(high pressure compressor blade trailing edge, HPC blade TE)掉块并有裂纹,图 3(d)所示为燃烧室(combustion chamber)穿孔。按照前述的特征提取方法,构造一个民航发动机损伤图像的特征数据库,部分数据样本如表 1 所列。

表 1 发动机损失图像特征数据的部分样本

Table 1 Partial samples of damage image features database

颜色矩特征				GLCM 特征				损失类型
一阶矩	二阶矩	三阶矩	角二阶矩	对比度	相关性	熵	逆差矩	
93.7363	11.6403	61.5801	0.0486	0.9658	0.9731	5.2483	0.8258	烧穿
96.4422	9.2361	67.4654	0.0068	8.4195	0.8006	7.5101	0.3426	烧穿
94.1228	10.6837	63.5223	0.0467	3.2251	0.9142	5.4002	0.8105	烧穿
93.7347	10.3823	52.2879	0.0607	0.7241	0.97063	4.8397	0.8692	烧蚀
94.1052	9.0594	55.04069	0.05837	2.8275	0.8925	4.9956	0.8529	烧蚀
98.9348	7.7736	59.4908	0.00777	8.4832	0.7341	7.3995	0.3397	烧蚀
96.6967	7.6054	65.1879	0.0488	7.5639	0.8126	5.2735	0.8344	掉块
95.6412	12.0436	64.0749	0.0173	5.0355	0.8722	6.6855	0.4971	掉块
97.0433	6.7279	66.9045	0.0469	9.7213	0.7677	5.3636	0.8191	掉块
106.4187	6.9893	61.5982	0.0068	8.7235	0.7506	7.5113	0.3386	穿孔
98.4885	8.5429	59.4548	0.0138	5.3788	0.8317	6.7651	0.4707	穿孔
108.8065	6.9618	61.6739	0.0068	8.7999	0.7493	7.5277	0.3368	穿孔

表 2 列出了数据库的基本特征。其中,随机选择 339 个样本作为训练样本,其余的 86 个样本作为测试样本,以便检验本文所提的识别算法的性能。

表 2 民航发动机损伤图像特征数据库

Table 2 Basic characteristics of damage images database

部位	损伤类型	训练样本数	测试样本数
fuel nozzle baffle	烧穿	78	20
HPT blade	烧蚀	90	23
HPC blade TE	掉块	78	20
combustion chamber	穿孔	93	23

3 改进的 PSO 算法

PSO 算法是一种启发式群体随机搜索算法,自 1995 年提出后,因其简洁的数学表达、明确的数学解释、较少的参数调节,在工程优化问题中得到广泛应用,成为当前最流行的智

能优化方法之一^[14]。PSO 算法同其他群体优化算法一样存在一种固有缺陷,即在迭代过程中容易陷入局部最优区域无法跳出而导致早熟收敛^[15]。为了弥补 PSO 算法的这一固有缺陷,本文提出了一种基于双变异(Dual Mutation, DM)策略的 PSO(DMPSO) 算法,以增强种群的多样性,平衡迭代过程中的开发能力和探索能力,增强种群的全局寻优能力,为 SVM 提供最优参数。

3.1 DMPSO 算法

关于传统 PSO 算法的理论可参见文献^[14]。本文所提的 DM 策略主要体现在两个方面:1)迭代变异策略(iteration mutation strategy);2)自调节变异策略(self-regulation mutation strategy)。

3.1.1 迭代变异策略

迭代变异策略通过引入变异向量 α 对粒子更新公式进行改进,式(14)为重新设计的粒子更新公式:

$$\begin{cases} \mathbf{v}_i^{k+1} = \omega \cdot \mathbf{v}_i^k + c_1 \cdot r_1 \cdot \boldsymbol{\alpha} \cdot (\mathbf{p}_{ge}^k - \mathbf{p}_i^k) + c_2 \cdot r_2 \cdot (\mathbf{p}_{ge}^k - \mathbf{p}_i^k) \\ \mathbf{p}_i^{k+1} = \mathbf{p}_i^k + \mathbf{v}_i^{k+1} \end{cases} \quad (14)$$

其中, k 为当前迭代次数; \mathbf{p}_i 为第 i 个粒子; \mathbf{p}_{ge} 为单个粒子所经历的历史最优位置; \mathbf{p}_{ge} 为群体最优位置; \mathbf{v}_i 为粒子的速度向量; ω 是递减型惯性权重; c_1 和 c_2 为正常数, 称为学习因子, 一般在 0~2 之间取值; 而 r_1 和 r_2 为 [0,1] 之间两个相互独立的随机数。 $\boldsymbol{\alpha}$ 定义为变异向量。一般而言, 传统的粒子位置更新公式不含 $\boldsymbol{\alpha}$ 。 $\boldsymbol{\alpha}$ 是一个与 \mathbf{p}_i 同维度的、随机产生的、只含有 0 和 1 元素的二进制向量, 其作用是降低粒子对自身极值的依赖度, 增加种群的多样性, 有利于增强粒子在迭代初期的开发能力, 从而增加粒子跳出局部最优区域的概率。

3.1.2 自调节变异策略

自调节变异策略对不能改进全局极值的粒子实施一次变异。如果 \mathbf{p}_i 不能更新全局极值 \mathbf{p}_{ge} , 则它将在无需人工干预的情况下进行一次自变异。反之, 如果 \mathbf{p}_i 能够更新 \mathbf{p}_{ge} , 则将按照式(14)继续迭代。

式(15)为自调节变异公式, 表达式如下:

$$\mathbf{p}_i^{k+1} = (1 - \boldsymbol{\alpha}) \cdot \mathbf{p}_i^k + r \cdot \boldsymbol{\alpha} \cdot (\mathbf{p}_{ge}^k - \mathbf{p}_i^k) \quad (15)$$

其中, r 也为 [0,1] 之间的随机数, $\boldsymbol{\alpha}$ 同样为随机产生的变异向量。自调节变异策略的作用是用 \mathbf{p}_{ge} 中的部分元素来替代 \mathbf{p}_i

表 3 8 种测试函数的特征
Table 3 Characteristics of 8 test functions

测试函数	搜索范围	维度	最优解	全局极值
Sphere: $f_{Sphere} = \sum_{i=1}^n x_i^2$	[-100, 100]	50	(0, 0, ..., 0) ₅₀	0
Schaffer: $f_{Sch} = 0.5 + \frac{(\sin \sqrt{\sum_{i=1}^n x_i^2})^2 - 0.5}{[1 + 0.001(\sum_{i=1}^n x_i^2)]^2}$	[-100, 100]	50	(0, 0, ..., 0) ₅₀	0
Griewank: $f_{Gri} = \sum_{i=1}^n \frac{x_i^2}{4000} - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	[-100, 100]	50	(0, 0, ..., 0) ₅₀	0
Ackley: $f_{Ack} = -20 \cdot e^{-0.2 \sqrt{\sum_{i=1}^n x_i^2}} - e^{\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)} + 20 + e$	[-100, 100]	50	(0, 0, ..., 0) ₅₀	0
Rastrigin: $f_{Ras} = \sum_{i=1}^n [x_i^2 - 10 \cdot \cos(2\pi x_i) + 10]$	[-100, 100]	50	(0, 0, ..., 0) ₅₀	0
Rosenbrock: $f_{Ros} = \sum_{i=1}^{n-1} [100(x_i^2 - x_{i+1})^2 + (x_i - 1)^2]$	[-100, 100]	50	(1, 1, ..., 1) ₅₀	0
SDPF: $f_{SDPF} = \sum_{i=1}^n x_i ^{i+1}$	[-100, 100]	50	(0, 0, ..., 0) ₅₀	0
RHEF: $f_{RHEF} = \sum_{i=1}^n \left(\sum_{j=1}^i x_j\right)^2$	[-100, 100]	50	(0, 0, ..., 0) ₅₀	0

表 4 各 PSO 算法寻优结果比较表
Table 4 Optimization results of PSO variants

function	SRPSO	ALCPSO	SLPSO	IWPSO	SFPSO	DNPSO	SAPSO	MAPSO	DMPSO
f_{Sphere}	1.7591×10^{-4}	8.4543	4202.32	469.3132	1843.34	0.1174	141.2324	0.0041	2.6565×10^{-92}
f_{Sch}	0.4473	0.4645	0.4954	0.4532	0.4864	0.4855	0.4543	0.3435	0
f_{Gri}	0.0053	0.3654	2.1038	1.1102	1.5452	0.0231	0.9563	0.0041	0
f_{Ack}	21.1654	19.4546	18.6332	19.5434	20.8652	20.1004	19.5646	18.7543	0
f_{Ras}	192.8652	951.2340	4558.7600	1126.4300	2626.3200	473.2345	1178.3400	205.422003	0
f_{Ros}	154.9428	5232.1300	8823.4500	5892.7400	2061.1200	168.4534	2635.4600	147.6532	43.8797
f_{SDPF}	3.14×10^8	1.21×10^{24}	6.12×10^{52}	1.49×10^{38}	1.42×10^{39}	0.1564	9.65×10^{35}	7.85×10^7	1.3532×10^{-111}
f_{RHEF}	917.6472	1032.7600	9613.3400	10434.5300	6846.5300	677.4532	2510.4200	1245.6400	2.7938×10^{-81}

将一些基于不同改进策略的 PSO 算法与 DMPSO 算法进行比较, 有基于模仿人类行为的算法, 如 Self Regulating PSO (SRPSO)^[16], Aging Leader and Challengers PSO (ALCPSO), Social Learning PSO (SLPSO)^[17]; 有基于参数调节的方法, 如 Inertia Weights PSO (IWPSO), Shrinkage Factor

中相应位置的元素, 这样不仅增加了种群的多样性, 同时有利于提高迭代后期粒子的开发能力, 从而增加获得更优解的概率。

图 4 所示为自调节变异过程的流程图。

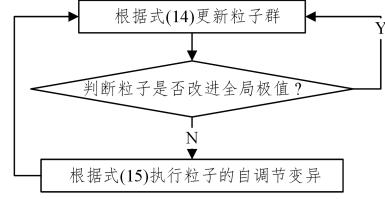


图 4 粒子自调节变异流程图

Fig. 4 Flowchart of self-regulation mutation strategy

本文所提的 DMPSO 算法, 所需设置的参数数与传统 PSO 算法是一致的, 变异过程也无需人工干预, 但因增加了种群多样性, 兼顾了开发和探索能力, 丰富了粒子更新方式, 使得算法的全局寻优性能得到显著提高。

3.2 PSO 算法性能验证

为了验证 DMPSO 算法的性能, 一些复杂的经典测试函数将用来验证不同 PSO 改进算法的寻优性能, 这些测试函数的相关信息如表 3 所列。表 4 所列为各 PSO 改进算法的寻优结果。

PSO (SFPSO)^[18]; 有基于邻域拓扑结构的方法, 如 Dynamic Neighborhood PSO (DNPSO)^[19]; 有基于算法集成的方法, 如 Simulated Annealing PSO (SAPSO)^[20], Multiple Agents PSO (MAPSO)^[21]。所有算法的种群数均设置为 60, 最大迭代数设置为 400, 粒子在 [-100, 100] 的范围内随机初始化, 而速

度在 $[-2, 2]$ 的范围内随机初始化,所有算法都在相同的计算环境下运行。以各 PSO 算法连续运行 100 次所得的适应度值的平均值来衡量算法的寻优性能。显然,表 4 显示了本文所提的 DMPSO 算法具有优良的全局寻优性能,能在工程优化中提供可靠的寻优结果。

4 基于 DMPSO 优化的 SVM

SVM 是在统计学习理论基础上产生的具有坚实理论基础的模式识别方法,通过使超平面间的分类间隔(margin)最大化,利用 Lagrange 函数把最优分类面问题转为对偶问题来求解次凸二次规划(convex quadratic programming)问题,从而构造出相应的判别函数。对于线性不可分问题,通过核函数映射,将在低维空间的原始样本转换为高维特征空间的线性可分样本,从而实现对线性不可分样本的正确识别。SVM 最大分类间隔的优化问题可以转换为:

$$\begin{cases} \min_{w, b, \xi} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \\ \text{s. t. } \begin{cases} y_i((w \cdot \Phi(x_i)) + b) \geq 1 - \xi_i \\ \xi_i \geq 0 \end{cases} \end{cases} \quad (16)$$

其中, w 为超平面的法向量; ξ 为松弛变量; C 为惩罚因子; x_i 为样本向量; y_i 为样本向量的标签, $y_i \in \{-1, +1\}$; $\Phi(\cdot)$ 为将样本由低维空间映射到高维特征空间的映射函数。通过 Lagrange 函数构造并求解凸二次规划问题,最终可得到如下的决策函数:

$$f(x) = \operatorname{sgn}\left(\sum_{i=1}^n y_i \alpha_i^* (\Phi(x_i) \cdot \Phi(x)) + b^*\right) \quad (17)$$

其中, α^* 为支持向量的系数;因非支持向量对应的 α^* 为 0,所以 n 为支持向量的个数; x_i 为所确定的支持向量; b^* 为分类阈值。

根据 Mercer 条件,可选定一函数 K 来对应某变换空间的内积 $\Phi(x_i) \cdot \Phi(x)$,令 $K(x_i \cdot x) = \Phi(x_i) \cdot \Phi(x)$,而函数 K 被称为核函数(kernel function)。通过核函数的方式可以有效避免确定 $\Phi(\cdot)$ 的理论困难,则式(17)可以改写为:

$$f(x) = \operatorname{sgn}\left(\sum_{i=1}^n y_i \alpha_i^* K(x_i \cdot x) + b^*\right) \quad (18)$$

径向基函数(Radial Basis Function, RBF)属于全局核函数,研究表明,全局核函数能使分类超平面最大程度逼近训练样本,有利于提升样本分类精度^[22]。因此本文采用 RBF 核函数,则式(18)可改写为:

$$f(x) = \operatorname{sgn}\left(\sum_{i=1}^n y_i \alpha_i^* \exp(-\gamma \|x_i - x\|^2) + b^*\right) \quad (19)$$

由于 C 控制对错分样本的惩罚程度,能调节支持向量置信范围和经验风险的比例;而 γ 主要影响样本在高维特征空间中的线性可分情况,(C, γ)不同的数值组合可导致 SVM 的分类精度产生较大的差异。因此,需要利用 DMPSO 算法对(C, γ)进行寻优,以确保获得全局最优解,进而使 SVM 获得最佳分类效果。

当 DMPSO 算法优化(C, γ)时,利用交叉验证(Cross-Validation,CV)来确定适应度函数,通常将训练样本分割为 k 组,依次以 $k-1$ 组样本为训练算法,余下的一组为测试样本,则可获得 k 个识别精度,并将 k 个识别精度的平均值作为 DMPSO 的适应度值。交叉验证由于遍历了所有样本,因此能最大限度地提高 SVM 的分类精度,保证算法的稳定性。

5 对损伤图像识别性能的验证

为了验证本文所提的基于颜色矩和 GLCM 的特征提取效果,同时验证基于 DMPSO 优化的 SVM(DMPSO-SVM)的损伤识别性能,本文将做如下对比验证。

5.1 不同特征提取方法对识别精度的影响

图像的特征提取方法有多种,根据发动机损伤图像的特点,将本文所提的特征提取方法与文献[10-12, 23, 24]的方法进行比较。其中,文献[10]提出了 HSV 空间颜色特征提取方法,文献[11]提出了基于 GLCM 统计量的纹理特征提取方法,文献[23]提出了基于 Tamura 的特征提取方法,文献[12]提出了基于 Tamura 和 GLCM 融合的特征提取方法(Tamura-GLCM),而文献[24]提出了基于 Tamura 和局部灰度颜色(gray color, GC)融合的特征提取方法(Tamura-GC)。

利用 DMPSO-SVM 作为识别算法,PSO 的种群设置为 40,最大迭代数设置为 100,粒子搜索范围为 $[0, 100]$,而速度在 $[-1, 1]$ 之间随机初始化,交叉验证的 k 取 5。利用 3.2 节中的民航发动机损伤图像,根据不同的方法提取图像特征,并进行算法训练和测试。

同时,引入常用的基于知识学习的智能算法,如 BP(Back Propagation)网络^[25]、ELM(Extreme Learning Machines)网络^[26]、k-NN(k-Nearest Neighborhood)算法^[27]来测试各种特征提取方法对识别精度的影响。BP 网络的误差目标设置为 0.005,迭代次数设置为 300 次。ELM 网络由文献[26]所提的方法优化。K-NN 取 k 为 1 时的识别精度。各算法的具体计算过程请参见相关参考文献。因受权值随机初始化的影响,BP 网络、ELM 网络的输出精度呈现出不确定性,因此这 2 种方法在相同计算环境下连续运行 50 次,取平均精度作为最终输出。

图 5 比较了基于不同特征提取方法的各识别算法的识别效果。如图 5 所示,对于不同的识别算法,本文所提的特征提取方法都有较其他特征提取方法更优的识别效果。分析各种特征提取算法可知:文献[10]、文献[11]和文献[23]中的方法属于单一特征提取方法,对损伤图像的描述不够全面,导致识别精度相对较差;文献[12]和文献[24]的方法属于融合特征提取方法,从多维度来刻画损伤图像特征,因此相比单一特征提取方法更有利损伤图像识别,且文献[24]也考虑到了颜色特征,其对损伤图像的识别也具有相对较高的精度。图 5 表明了本文所提基于颜色矩和 GLCM 特征提取的方法综合考虑了颜色特征和纹理统计特征,对发动机损伤图像特征提取更加客观、全面,实验结果证明本文所提特征提取方式更加合理有效。

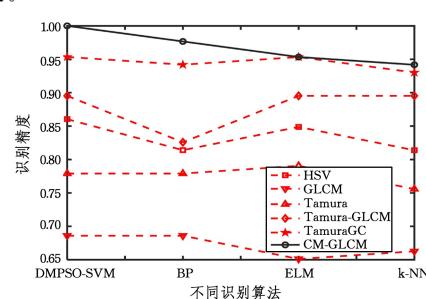


图 5 基于不同特征提取方法的识别性能比较

Fig. 5 Recognition effect comparison based on different feature extraction methods

识别精度

5.2 不同识别算法的识别性能比较

本文提出了基于 DMPSO 优化的 SVM,通过交叉验证以获得最优的 (C, γ) ,从而保证 SVM 稳定可靠的输出。为了验证本文所提算法在损伤图像识别中的优势,将上述的 4 种识别算法与 DMPSO-SVM 进行识别性能比较。图 6 显示了 4 中算法的识别性能差异。如图 6 所示,所提 DMPSO-SVM 的识别性能基本上都优于其他 3 种算法。

表 5 列出了 DMPSO 和 4 种识别算法的计算结果,其中 $(C, \gamma)_{best}$ 表示利用 DMPSO 寻优后的输出解,而 CV 的平均精度即是适应度值。

表 5 识别算法的特征提取方法的识别性能比较

Table 5 Recognition performance comparison of feature extraction methods of algorithms

特征提取方法	DMPSO-SVM		BP	ELM	k-NN
	$(C, \gamma)_{best}$	CV 平均精/%度			
HSV	(2.47, 11.96)	87.10	86.04	81.40	84.88
GLCM	(9.19, 13.24)	74.42	68.60	68.60	65.12
Tamura	(56.46, 1.98)	84.56	77.90	77.90	79.06
Tamura-GLCM	(10.01, 4.47)	94.01	89.53	82.58	89.53
Tamura-GC	(5.27, 5.33)	96.31	95.35	94.19	95.34
CM-GLCM	(4.67, 7.54)	96.77	100	97.67	95.34
					94.18%

由于各种识别算法的识别原理各不相同,因此很难保证一种方法对所有数据分布类型都有效,例如利用文献[23]中提取的数据,DMPSO-SVM 的识别精度就不如 ELM 网络。但 DMPSO-SVM 有效克服了随机性的影响,不存在 BP 网络和 ELM 网络输出不确定性的缺陷,同时,也不会像 k-NN 一样对 k 值敏感。因此,DMPSO-SVM 不仅具有良好的识别性能,还能提供稳定、准确的输出,能够为民航发动机的损伤类型识别提供可靠的技术支撑。

结束语 通过对某些发动机损伤图像的特征提取,以及对损伤类型的识别,可以得出如下结论:1)本文提出的基于颜色矩和 GLCM 纹理特征的特征提取方法更有利于描述发动机的损伤图像,表达发动机的损伤特征,为训练识别算法提供合理有效的损伤图像特征数据库;2)由于双变异策略的作用,DMPSO 算法能较好地维持总群多样性,平衡迭代过程中的开发和探索,提升了全局寻优能力,为 SVM 参数优化提供符合要求的全局输出;3)SVM 经过 DMPSO 优化以后,能确保 SVM 获得最优的识别性能,同时保障了 SVM 输出结果的稳定性。因此,本文所提特征提取方法和损伤类型识别算法能够为实际的发动机维修保障提供自动化的、可靠的损伤类型输出,从而提升安全保障效率。

参 考 文 献

- [1] ZHANG L. Research on electrical system fault diagnosis method of civil aviation engine[D]. Tianjin: Tianjin University, 2016.
- [2] YANG X Y, PANG S, SHEN W, et al. Aero engine fault diagnosis using an optimized extreme learning machine[J]. International Journal of Aerospace Engineering, 2016, 2016:1-10.
- [3] ITJENS G, KOOI T, BEJNORDI B E, et al. A survey on deep learning in medical image analysis[J]. Medical Image Analysis, 2017, 42:60-88.
- [4] MARTINEZ-LUENGO M, KOLIOS A, WANG L. Structural health monitoring of offshore wind turbines: A review through the Statistical Pattern Recognition Paradigm[J]. Renewable and Sustainable Energy Reviews, 2016, 64:91-105.
- [5] ZHENG B, HUANG H Z, GUO W, et al. Fault diagnosis method based on supervised particle swarm optimization classification algorithm[J]. Intelligent Data Analysis, 2018, 22(1):191-210.
- [6] ZHANG J Y, WANG H L, GUO Y, et al. Review of deep learning [J]. Application Research of Computers, 2018, 35(721):7-14, 22.
- [7] JAIN A K, DUIN R P W, MAO J C. Statistical pattern recognition:a review[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22:4-37.
- [8] LI J M, ZHANG B, LIN F Z. Training algorithms for support vector machine[J]. Journal of TsingHua University(Science and Technology), 2003, 43(1):120-124.
- [9] HUANG H Z, WANG H K, LI Y F, et al. Support vector machine based estimation of remaining useful life: current research status and future trends[J]. Journal of Mechanical Science and Technology, 2015, 29(1):151-163.
- [10] YANG A B, SHENG J C, LI Y Z, et al. Color feature extraction based on HSV space [J]. Computer Knowledge and Technology, 2017(18):193-195.
- [11] GAO C C, HUI X W. GLCM-based feature extraction [J]. Computer systems & Application, 2010, 19(6):195-198.
- [12] GEN Y P, GAO H B, REN Z Y. Image retrieval algorithm combining color feature and text feature [J]. Wireless Internet Technology, 2017(24):113-116.
- [13] HARALICK R M, SHANMUGAM K, DINSTEIN I. Texture features for image classification[J]. IEEE Transactions on Systems, Man and Cybernetics, 1973, SMC-3(6):610-621.
- [14] KENNEDY J, EBERHART R C. Particle swarm optimization [C]// Proceedings of IEEE International Conference on Neural Network. Perth, 1995:1942-1948.
- [15] LI A G, QIN Z, BAO F M. Particle swarm optimization algorithms [J]. Computer Engineering and Applications, 2017, 186(3):454-458.
- [16] TANWEER M R, SURESH S, SUNDARARAJAN N. Self regulating particle swarm optimization algorithm[J]. Information Sciences, 2015, 294(10):182-202.

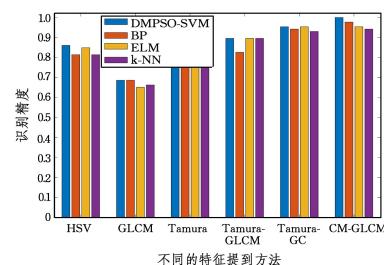


图 6 4 种识别算法的识别性能差异

Fig. 6 Recognition performance differences of 4 algorithms

- [17] SINGH R P, MUKHERJEE V, GHOSHAL S P. Particle swarm optimization with an aging leader and challengers algorithm for optimal power flow problem with FACTS devices[J]. Electrical Power and Energy Systems, 2015, 64: 1185-1196.
- [18] BERGH V D. An analysis of particle swarm optimizers[D]. Pretoria: university of Pretoria, 2002.
- [19] ZHENG B, GAO F. Fault diagnosis method based on S-PSO classification algorithm [J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(11): 3640-3651.
- [20] LIU W, SUN R B, WANG H R. Escape from the immune particle swarm algorithm embedded mechanism of simulated annealing [J]. Journal of Jilin normal university (Natural Science Edition), 2018, 39(1): 85-90.
- [21] YANG B, WANG C, HUANG H, et al. A multi-agent and PSO based simulation for human behavior in emergency evacuation [C]// Proceedings of International Conference on Computational Intelligence and Security. Harbin, 2007: 296-300.
- [22] DAMOULAS T, GIROLOAMI M A. Probabilistic multi-class multi-kernel learning: on protein fold recognition and remote homology detection[J]. Bioinformatics, 2008, 24(10): 1264-1270.
- [23] LIU Y, LI Z, GAO Z M. An Improved Texture Feature Extraction Method for Tyre Tread Patterns[C]// International Conference on Intelligent Science and Big Data Engineering. Berlin: Springer, 2013: 705-713.
- [24] LI N, XIONG Z Y, XIE J, et al. Brain tumor segmentation on multi-modality magnetic resonance images based on Tamura Texture feature and SVM model[J]. Journal of South-Central

University for Nationalities (Natural Science Edition), 2018, 37(3): 148-153.

- [25] ALI J B, FNAIECH N, SAIDI L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration[J]. Applied Acoustics, 2015, 89(3): 16-27.
- [26] HONGJUN S U, TIAN S, CAI Y, et al. Optimized extreme learning machine for urban land cover classification using hyperspectral imagery[J]. Frontiers of Earth Science, 2017, 11(4): 765-773.
- [27] LI J. Research on the k-NN classification[J]. Natural Sciences Journal of Harbin Normal University, 2013, 29(4): 8-11.



ZHENG Bo, born in 1984, Ph.D, associate professor. His main research interests include fault diagnosis, pattern recognition and optimization design.



MA Xin, born in 1984, B. S., lecturer. His main research interests include optimization design of civil aviation traffic safety and flight reliability diagnosis.

(上接第 110 页)

- [11] ENGLAND M, FLORESCU D. Comparing Machine Learning Models to Choose the Variable Ordering for Cylindrical Algebraic Decomposition[C]// Conference on Intelligent Computer Mathematics. 2019: 93-108.
- [12] ZHU Z P, CHEN C B. Variable Order Selection for Cylindrical Algebraic Decomposition Based on Machine Learning [EB/OL]. (2019-04-10) [2019-12-23]. https://www.researchgate.net/publication/332749898_Variable_Order_Selection_for_Cylindrical_Algebraic_Decomposition_Based_on_Machine_Learning.
- [13] COLLINS G E. Quantifier elimination for real closed fields by cylindrical algebraic decomposition [J]. Springer Lecture Notes in Computer Science, 1975, 33: 515-532.
- [14] ARNON D S, COLLINS G E, MCCALLUM S. Cylindrical algebraic decomposition I: The basic algorithm[C]// SIAM Journal of Computing, 1984, 13(4): 865-877.
- [15] MCCALLUM S. An improved projection operation for cylindrical algebraic decomposition[C]// European Conference on Computer Algebra, 1985, 2: 277-278.
- [16] COLLINS G E, HU H. Partial cylindrical algebraic decomposition for quantifier elimination [J]. Journal of Symbolic Computation, 1991, 12: 299-328.
- [17] BROWN C W. Improved projection for cylindrical algebraic decomposition [J]. Journal of Symbolic Computation, 2001, 32(5): 447-465.
- [18] STRZEBONSKI A W. Cylindrical Algebraic Decomposition using validated numerics[J]. Journal of Symbolic Computation, 2006, 41(9): 1021-1038.

- [19] IWANE H, YANAMI H, ANAI H, et al. An effective implementation of a symbolic-numeric cylindrical algebraic decomposition for quantifier elimination[C]// Symbolic Numeric Computation. 2009: 55-64.
- [20] DOLZMANN A, SEIDL A, STURM T. Efficient projection orders for CAD[C]// International Symposium on Symbolic and Algebraic Computation. 2004: 111-118.
- [21] CHEN C B, MORENO MAZA M. Quantifier elimination by cylindrical algebraic decomposition based on regular chains [J]. Journal of Symbolic Computation, 2016, 75: 74-93.
- [22] WANG R B, XU H Y, LI B, et al. Research on Method of Determining Hidden Layer Nodes in BP Neural Network [J]. Computer Technology and Development, 2018, 28(4): 31-35.



ZHU Zhang-peng, born in 1993, master, is a member of China Computer Federation. His main research interests include machine learning and so on.



CHEN Chang-bo, born in 1981, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include symbolic-numeric computation, automatic parallelization and optimization of computer programs and machine learning.