

狮群优化核极限学习机的分类算法

刘新建,孙中华

(武汉烽火信息集成技术有限公司,湖北 武汉 430074)

摘要: 在核极限学习机(Kernel Based Extreme Learning Machine, KELM)分类应用的基础上,结合狮群算法(Lion Swarm Optimization, LSO)强全局寻优能力与收敛快的特性,提出一种 LSO 优化 KELM 算法。将测试准确率作为 LSO 优化 KELM 的适应度函数,根据移动位置获取最优适应度值进行数据分类测试的评价标准。采用 UCI 数据集仿真测试,实验结果表明,较 KELM 分类,LSO 优化 KELM 可获得更优的分类准确率;较麻雀搜索算法(Sparrow Search Algorithm, SSA)优化 KELM,LSO 优化 KELM 收敛速度快,分类性能更优。

关键词: 核极限学习机;狮群算法;麻雀搜索算法

中图分类号: TP391.9

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.211532

中文引用格式: 刘新建,孙中华. 狮群优化核极限学习机的分类算法[J]. 电子技术应用, 2022, 48(2): 69–72.

英文引用格式: Liu Xinjian, Sun Zhonghua. Classification algorithm of loin swarm optimization kernel extreme learning machine[J]. Application of Electronic Technique, 2022, 48(2): 69–72.

Classification algorithm of loin swarm optimization kernel extreme learning machine

Liu Xinjian, Sun Zhonghua

(Wuhan Fiberhome Information Integration Technologies Co., Ltd., Wuhan 430074, China)

Abstract: Based on the classification and application of the kernel based extreme learning machine(KELM), combined with the strong global optimization ability and fast convergence characteristics of the lion swarm optimization(LSO) algorithm, an LSO optimization KELM algorithm is proposed. The test accuracy is taken as the fitness function of LSO to optimize KELM, and the evaluation standard for data classification test is obtained according to the mobile position to obtain the optimal fitness value. Using UCI data set simulation test, the experimental results show that compared with KELM classification, LSO optimization KELM can obtain better classification accuracy. Compared with sparrow search algorithm(SSA) optimization KELM, LSO optimization KELM has faster convergence speed and better classification performance.

Key words: kernel extreme learning machine(KELM); lion swarm optimization(LSO); sparrow search algorithm(SSA)

0 引言

图像分类是图像领域的研究热点之一,研究者对于不同场景的图像采用不同的算法进行研究。极限学习机(Extreme Learning Machine, ELM)有效避免了传统前馈神经网络训练的劣势,基于学习速度快、泛化性能好等优势应用于图像分类领域。文献[1]采用改进蝙蝠算法优化极限学习机进行图像分类,提高分类准确率的基础上加快了分类速度;文献[2]采用萤火虫算法(Firefly Algorithm, FA)优化极限学习机对遥感影响进行分类,FA 优化算法高于传统的遗传算法(Genetic Algorithm, GA)和粒子群算法(Particle Swarm Optimization, PSO)优化方法;文献[3]采用鱼群算法优化极限学习机,可获得更好的分类效果;文献[4]采用局部信息保持极限学习机,在分类性能上优于 KELM 算法;文献[5]、[6]采用多核多特征进行重构 ELM,提高了准确性和完整性。综上,较 ELM,采用群智能优化算法可获得更好的分类效果。KELM 采用核函数

来取代 ELM 的内积运算,增加了函数逼近能力,提高了非线性分类能力。文献[7]采用核极限学习机应用于脉象分类问题,较反向传播算法(Back Propagation, BP)和支持向量机算法(Support Vector Machine, SVM)提高了分类准确性。文献[8]采用核极限学习机可获得乳腺良恶性肿块样病变数据的分类准确率。

文献[9]指出 LSO 比 PSO 算法具有收敛速度快、精度高的特点,可获得全局最优解。文献[10]、[11]指出狮群算法优化传统算法,可获得更高精度。本文在 KELM 良好的分类性能基础上,结合 LSO 的寻优能力,提出 LSO 优化 KELM 算法(简称 LKELM),并采用 UCI 数据集进行仿真测试,以检验分类精度的提高程度。

1 KELM 算法

1.1 ELM

对于给定的训练样本集以及前馈网络的激活函数与隐含层节点数,采用 ELM 训练的步骤如下:

(1) 随机给定隐含层连接权值 $(a_i, \dots, b_i), i=1, \dots, L$, 并计算其输出矩阵 \mathbf{H} , 如式(1)所示:

$$\mathbf{H} = \begin{bmatrix} h(x_1) \\ \vdots \\ h(x_N) \end{bmatrix}_{N \times L} \quad (1)$$

(2) 求解输出权值 β 的最小二乘范数解, 如式(2)所示:

$$\beta = \mathbf{H}^T \left(\frac{\mathbf{I}}{C} + \mathbf{H}\mathbf{H}^T \right)^{-1} \mathbf{Y} \quad (2)$$

其中, \mathbf{I} 是单位矩阵, C 是常数, \mathbf{Y} 是期望矩阵。

由此可得出, 采用 ELM 的分类公式如式(3)所示:

$$f(x) = \text{sign}(h(x)\mathbf{H}^T(\frac{\mathbf{I}}{C} + \mathbf{H}\mathbf{H}^T)^{-1}\mathbf{Y}) \quad (3)$$

1.2 KELM

根据 ELM 的输出矩阵 $\mathbf{H}, h(x_i)$ 可视作 x_i 的非线性映射。当映射关系未知时, 可通过构造核函数来替代 $\mathbf{H}\mathbf{H}^T$, 如式(4)所示:

$$\left\{ \begin{array}{l} \mathbf{H}\mathbf{H}^T(i, j) = K(x_i, x_j) \\ \mathbf{H}\mathbf{H}^T = \boldsymbol{\Omega}_{\text{ELM}} = \begin{bmatrix} K(x_1, x_1) & \cdots & K(x_1, x_N) \\ \vdots & \ddots & \vdots \\ K(x_N, x_1) & \cdots & K(x_N, x_N) \end{bmatrix} \\ h(x)\mathbf{H}^T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix} \end{array} \right. \quad (4)$$

那么, 将式(4)带入式(3)可得式(5):

$$f(x) = \text{sign} \left(\begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \left(\frac{\mathbf{I}}{C} + \boldsymbol{\Omega}_{\text{ELM}} \right)^{-1} \mathbf{Y} \right) \quad (5)$$

由此可见, KELM 在 ELM 的基础上引入核函数, 增强了其非线性分类能力, 而核函数的选择影响其分类效果^[12]。KELM 的推演过程可见文献[13]。

2 LSO 算法

2.1 基本原理

LSO 寻优主要来源于狮王、母狮和幼狮的社会行为。其中, 狮王社会行为包括保护和分配食物给幼狮, 面对自身种群的优胜劣汰机制以及外来群种的挑战来获得首领的地位; 母狮主要负责养育幼狮并根据猎物踪迹范围来猎食, 猎食范围从大范围勘探直至收缩范围; 幼狮在狮王和母狮的保护下历经索取食物、学习捕猎、被狮王驱逐, 公狮则挑战原有狮王地位。

LSO 的寻优思想为: 从初始位置(待寻优空间), 狮王处于最佳适应度值的位置; 在捕猎狮(一定比例)通过相互配合捕猎获得比狮王现有猎物更优质的猎物, 狮王将其占有; 幼狮在狮王和母狮的护佑下进食和学习捕猎, 即使在被驱赶后可凭借记忆向待寻优空间靠近, 不断重复搜寻, 最终可获得目标函数最优值。

2.2 相关参数

成年狮所占比例因子 β : 在整个狮群中, 如果成年狮

所占比例越大, 则幼狮占比越少。幼狮位置更新多样性, 可增加种群的差异性, 从而提高算法的搜索能力。成年狮为 0~1 区间的随机值, 为加快收敛速度, 一般小于 0.5。

母狮移动范围扰动因子 α_f : 在快取得全局最优解的位置附近通过增加扰动因子来增强局部搜索能力, 使得母狮的捕猎范围能够由大范围逐步缩小, 直至趋于 0 的微小值。增加母狮移动范围扰动因子可有效避免早熟问题, 使得能够在全局和局部搜索能力间获得均衡, 可获得最优解, 如式(6)所示:

$$\alpha_f = \text{step} \cdot e^{-\left(\frac{30t}{T}\right)^{10}} \quad (6)$$

其中, $\text{step}=0.1(\overline{\text{high}}-\overline{\text{low}})$, 表示狮子在活动范围内的最大值均值和最小值均值, T 表示最大迭代次数, t 表示当前迭代次数。

幼狮移动范围扰动因子 α_c : 幼狮在索取食物和学习捕猎活动均会在一定范围内, 幼狮移动范围扰动因子可有效控制该范围, 该范围亦从大到小, 呈线性下降趋势, 表达式如式(7)所示:

$$\alpha_c = \text{step} \left(\frac{T-t}{T} \right) \quad (7)$$

2.3 算法原理

假设在 D 维空间中由 N 个狮子组成狮群, 成年狮子数量为 nleader, 其范围如式(8)所示:

$$2 \leq nleader \leq N/2 \quad (8)$$

其中, 仅有的一头公狮为狮王, 其余则为母狮。那么, 第 i ($1 \leq i \leq N$) 个狮子的位置如式(9)所示:

$$x_i = (x_{i1}, x_{i2}, \dots, x_{iD}), 1 \leq i \leq N \quad (9)$$

成年狮的数量为 $nleader=[N\beta]$, 幼狮数量为 $N-nleader$ 。狮王、母狮以及幼狮的位置移动分别如式(10)~式(12)所示:

$$x_i^{k+1} = g^k (1 + \gamma \left| \left| p_i^k - g^k \right| \right|) \quad (10)$$

$$x_i^{k+1} = \frac{p_i^k + p_c^k}{2} (1 + \alpha_f \gamma) \quad (11)$$

$$x_i^{k+1} = \begin{cases} \frac{g^k + p_i^k}{2} (1 + \alpha_c \gamma), & q < \frac{1}{3} \\ \frac{g_m^k + p_i^k}{2} (1 + \alpha_c \gamma), & \frac{1}{3} \leq q < \frac{2}{3} \\ \frac{\bar{g}^k + p_i^k}{2} (1 + \alpha_c \gamma), & \frac{2}{3} \leq q < 1 \end{cases} \quad (12)$$

其中, γ 为正态分布 $N(0, 1)$ 的随机数, p_i^k 为第 i 个狮子第 k 代的历史最优位置, g^k 为第 k 代群体最优位置, p_c^k 为第 k 代母狮群众随机的捕猎伙伴的历史最佳位置, g_m^k 为幼狮随母狮的第 k 代历史最佳位置, q 为均匀分布 $U(0, 1)$ 随机数。

3 本文算法

KELM 有效避免了 ELM 算法的随机初始化问题并

适用于小样本的非线性分类问题,其训练速度快,泛化性能好,且具有较好的鲁棒性,广泛应用于数据分类及预测问题。本文采用高斯径向基核函数,其属于局部核函数,优势在于局部学习能力强,但全局泛化能力差,易陷入局部最优解。为提高其全局寻优能力,可结合全局寻优的相关算法。为此,采用 LSO 智能算法来提升其全局泛化能力,从而兼顾全局和局部寻优能力。在迭代运算中,基于不同狮子的不同移动位置规则,个体最优的被保留,否则将被适应度高的个体所替换。在 LSO 算法中,采用 KELM 计算的测试准确率作为其适应度函数,用以判断全局最优位置和历史最优位置,从而获得全局最优解。

优化思想:以适应度函数作为评价优化算法分类高低函数,适应度值越高表明其分类准确率越高,其倒数可反映优化算法的收敛速度。在初始化过程中计算适应度值,确定最优位置为狮王位置以及历史最优位置作为母狮及幼狮的位置;在迭代过程中,不同类型的狮子按照式(10)~式(12)更新位置,并计算适应度值,此适应度值与历史最优适应度值有所变化,从而寻求最优适应度值。

本文算法的步骤描述如下:

- (1)训练集与测试集在训练前先采用归一化处理;
- (2)建立 KELM 的神经网路结构,确定核函数;
- (3)确定 LSO 相关参数,如种群数量、最大迭代次数、维度、成年狮占比等;
- (4)狮群种群初始化,计算初始适应度值等;
- (5)设定适应度函数,根据迭代过程中的移动位置不断获取最优适应度值;
- (6)判断迭代次数,如达到则终止,否则进行执行步骤(5)。

4 实验分析

实验采用部分 UCI 数据集,其数据包括类别信息及特征数据。其中,Wine 数据集包括 3 类数据 178 条记录(1 类 59 个样本,2 类 71 个样本,3 类 48 个样本),每条记录包含 13 种属性特征。

采用 MATLAB 2013a 软件测试。KELM 采用径向基核函数,迭代次数为 50,初始种群为 30,维度为 2,训练样本为分别选择 36、89。LKELM 的分类效果对比分别如图 1、图 2 所示。

由图 1、图 2 可知,针对不同数量的训练样本,在迭代次数很低的情况下,采用 LKELM 可快速获得较高的分类预测精度。训练样本为 36 时,LKELM 分类精度为 0.791 67,KELM 分类结果为 0.777 67,精度差异为 0.014;训练样本为 89 时,LKELM 分类精度为 0.825 4,KELM 分类结果为 0.814 4,精度差为 0.011。为进一步对比不同测试集的分类效果,其实验结果如表 1 所示。

UCI 测试集较多,本文以表 1 中 4 种数据集为例进

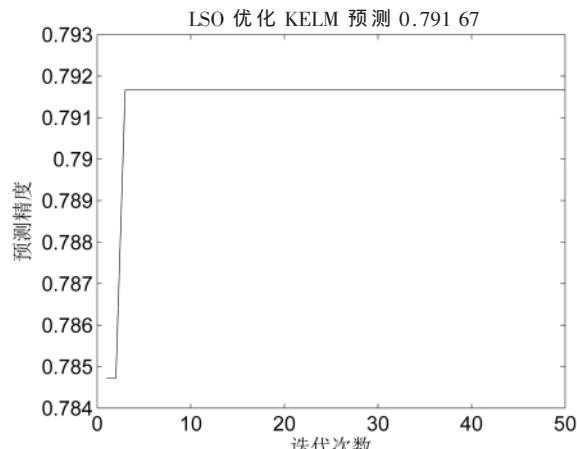


图 1 LSO 优化 KELM 分类效果(训练样本 36)

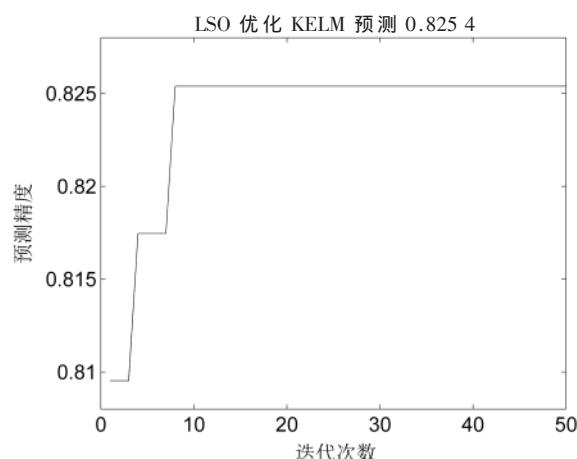


图 2 LSO 优化 KELM 分类效果(训练样本 89)

表 1 不同测试集不同训练样本的分类对比

数据集	测试样本	训练样本	KELM/%	LKELM/%
iris	30	120	94.17	96.68
	60	90	94.44	95.56
	90	60	96.67	98.83
balance	125	500	93.83	97.21
	250	375	98.67	1.00
	375	250	1.00	1.00
wine	36	142	81.25	82.64
	79	79	91.11	92.22
	100	78	93.04	95.41
cmc	146	1 327	79.05	80.71
	293	1 180	83.47	86.61
	440	1 033	85.19	91.58

行分析。通过表 1 数据可知,LKELM 比 KELM 在分类精度上均有提高。这也表明,LKELM 是 KELM 的一种有效的可用于数据分类的提高算法。

为了进一步对比智能算法的优化效果,本文选取 SSA 优化 KELM 进行对比。SSA 算法于 2020 年提出,文献[14]指出其在优化方面有着良好特性。在同等样本条

件下,两种智能优化算法的迭代情况如图3、图4所示。

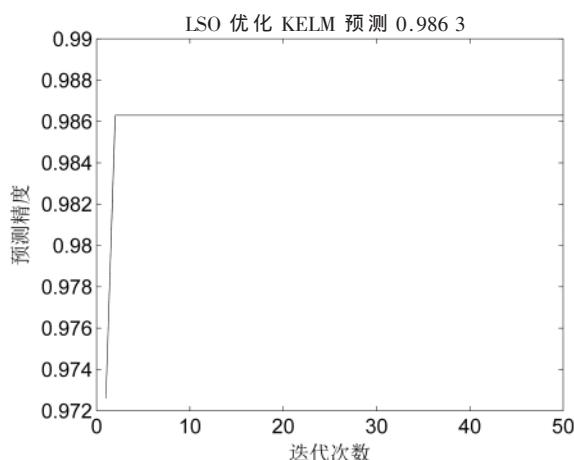


图3 LSO 优化 KELM 分类效果

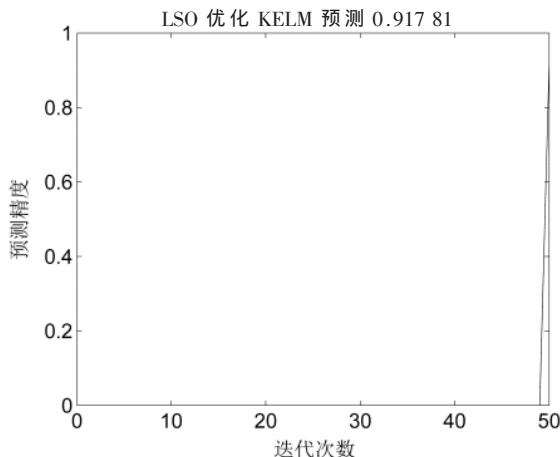


图4 SSA 优化 KELM 分类效果

由图3、图4可知,采用LSO优化KELM算法比SSA优化KELM算法的收敛速度更快,其优化的精度更高。这也表明,LSO优化KELM算法在优化性能方面高于SSA优化KELM算法。

5 结论

本文提出的LSO优化KELM算法结合了KELM与LSO的优质特性,兼顾了全局搜索能力和局部学习能力,通过以测试准确率作为适应度函数,在迭代过程中可获得更高的分类精度。较KELM算法,LSO优化KELM在UCI数据集测试获得了更高的分类效果;较SSA优化KELM算法,LSO优化KELM同样表现出更优的分类性能。

参考文献

- [1] 陈海挺.改进蝙蝠算法优化极限学习机的图像分类[J].激光杂志,2014,35(11):26-29.
- [2] 蔡悦,苏红军,李茜楠.萤火虫算法优化的高光谱遥感影像极限学习机分类方法[J].地球信息科学学报,2015,17(8):986-994.
- [3] 林怡,季昊巍,NICO S,等.基于鱼群算法的极限学习机影像分类方法优化[J].农业机械学报,2017,48(10):156-164.
- [4] 何阳,闫德勤,刘德山.局部信息保持极限学习机的遥感图像分类[J].计算机应用与软件,2019,36(1):263-270,324.
- [5] 楚恒,蔡衡,单德明.高分辨率遥感影像的多特征多核ELM分类方法[J].计算机工程与科学,2019,41(10):1816-1822.
- [6] 陆云飞,陆飞,方路平,等.应用小波多尺度特征检测机械通气人机不同步[J].小型微型计算机系统,2020,41(12):2677-2682.
- [7] 王杰,李自豪.脉象分类识别的小波核极限学习机方法[J].计算机工程与设计,2019,40(5):1472-1476.
- [8] 杨迪,曹佳琦,张潇月,等.核极限学习机诊断乳腺良性肿瘤块样病变[J].中国医学影像技术,2019,35(4):507-510.
- [9] 刘生建,杨艳,周永权.一种群体智能算法——狮群算法[J].模式识别与人工智能,2018,31(5):431-441.
- [10] 杨艳,刘生建,周永权.贪心二进制狮群优化算法求解多维背包问题[J].计算机应用,2020,40(5):1291-1294.
- [11] 周宁亚,黄友锐,韩涛.基于狮群优化的FastSLAM算法[J].计算机应用与软件,2020,37(7):206-211.
- [12] 徐睿,梁循,齐金山,等.极限学习机前沿进展与趋势[J].计算机学报,2019,42(7):1640-1670.
- [13] 孙中华,杨晓迪,古丽米拉·克孜尔别克.一种多尺度小波核极限学习机的图像检索仿真[J].红外技术,2015,37(6):484-487.
- [14] 温泽宇,谢珺,谢刚,等.基于新型拥挤度距离的多目标麻雀搜索算法[J/OL].计算机工程与应用:1-10[2021-03-14].

(收稿日期:2021-03-19)

作者简介:

刘新建(1991-),男,本科,助理工程师,主要研究方向:计算机应用技术。

孙中华(1989-),男,硕士,助理工程师,主要研究方向:计算机应用技术。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所