

doi: 10.7690/bgzdh.2021.09.001

基于粒子群优化极限学习机的雷达识别方法

刘 傲, 周 正

(海军航空大学, 山东 烟台 264001)

摘要: 针对相控阵雷达识别的问题, 提出一种基于粒子群优化极限学习机(PSO-KELM)的识别方法。在核函数极限学习机(kernel extreme learning machine, KELM)的基础上, 引入粒子群优化算法(particle swarm optimization, PSO), 求得核函数参数最优解, 提高相控阵雷达识别准确率。通过构建雷达数据库, 使用粒子群优化极限学习机的方法对不同噪声情况下的雷达数据进行识别, 并与核函数极限学习机、核函数支持向量机(kernel support vector machine, KSVM)和半监督式迁移学习(semi-supervised and transfer learning, SSSL)的方法进行对比。仿真结果表明: 在不同雷达种类和不同噪声情况下, 该方法识别准确率均高于其他方法。

关键词: 相控阵雷达; 辐射源识别; 粒子群优化; 核函数; 极限学习机(extreme learning machine, ELM)

中图分类号: TN95 文献标志码: A

Radar Recognition Method Based on Particle Swarm Optimization and Extreme Learning Machine

Liu Ao, Zhou Zheng

(Naval Aviation University, Yantai 264001, China)

Abstract: Aiming at the problem of phased array radar recognition, a recognition method based on particle swarm optimization extreme learning machine (PSO-KELM) is proposed. On the basis of kernel extreme learning machine (KELM), particle swarm optimization (PSO) algorithm is introduced to obtain the optimal solution of kernel function parameters and improve the recognition accuracy of phased array radar. By constructing radar database, the method of particle swarm optimization extreme learning machine is used to identify radar data under different noise conditions, and compared with kernel function extreme learning machine, kernel support vector machine (KSVM) and semi-supervised and transfer learning(SSSL). The simulation results show that the recognition accuracy of this method is higher than other methods under different radar types and different noises.

Keywords: phased array radar; emitter recognition; particle swarm optimization; kernel function; extreme learning machine (ELM)

0 引言

电子侦察是获取电子情报的重要手段, 是实施电子对抗行动的前提, 也是现代战争的重要组成部分。雷达广泛应用于多种武器平台上, 对雷达的侦察和信息处理在电子战中占据重要的地位^[1]。雷达识别是雷达信息处理中信号分选后的一个重要环节, 将分选后的雷达信号与雷达识别数据库中的先验雷达信息进行匹配, 以确定信号类型。随着相控阵等新型雷达的出现和技术的不断发展, 雷达系统的智能化程度越来越高。在日益复杂的电磁环境中, 实时、高精度地识别相控阵雷达辐射源, 已成为雷达对抗中亟待解决的问题^[2]。

雷达辐射源的识别主要分为特征提取和识别方法研究 2 部分。第一部分是特征提取, 基于射频(RF)、到达时间(TOA)、脉冲幅度(PA)、脉冲宽度

(PW) 和到达角(DOA)这些经典特征参数的识别已经难以满足准确率的要求, 在现代战争中不可行, 因此对新型特征的提取至关重要^[3]。文献[4]基于 3 维分布特征和迁移学习的雷达辐射源识别方法, 提出了时频能量分布的立方特征来描述雷达辐射源的脉内调制信息, 具有更好的精度和鲁棒性。文献[5]提出一种基于模糊函数主脊切片(AF)和奇异值分解(SVD)的雷达辐射源信号识别方法, 通过计算识别信号的 AF, 确定主脊片包络, 提取主脊片包络的旋转角和对称 Holder 系数作为特征向量的元素; 采用 SVD 消除噪声对主脊切片包络的影响, 获得了较好的识别率。此外还有基于时频特性^[6]、对角切片^[7]、分形特征^[8]等的雷达辐射源识别。第二部分是研究新的识别方法。特征选择完成后, 雷达辐射源的识别实际就是一个模式识别的过程, 方法的选

收稿日期: 2021-05-24; 修回日期: 2021-06-27

基金项目: 国防科技卓越人才基金(2017-JCJQ-ZQ-003); 泰山学者工程专项经费(ts201712072)

作者简介: 刘 傲(1996—), 男, 河北人, 硕士, 从事信号处理、雷达辐射源识别研究。E-mail: liuaol30923@163.com。

取直接影响到识别效果。辐射源识别的方法主要包括特征参数匹配法^[9]、专家系统法^[10]、神经网络法^[11]等。特征参数匹配法是最传统的方法，其原理简单，通过对比数据库与所得信号的基本参数，就可以识别出其类型；但随着雷达所处环境日益复杂，这种方法依赖于数据库中的先验知识，没有运用专家经验知识，没有学习能力，灵活性不够，无法对新体制雷达做出有效识别。人工智能技术的引入，解决了参数匹配法存在的问题，提高了识别准确率，使雷达辐射源的识别又向前迈进一大步；但仍有不足，如支持向量机完成的是二识别，不便于解决多识别问题，而且调参繁琐，核函数难选难调。神经网络方法需要大量参数，且学习过程比较长，有可能陷入局部极小值等。

Deng C W 等在 2006 年提出的极限学习机(ELM)是一种训练参数少、精度高、泛化能力强的单隐层前馈神经网络^[12]，已成功应用于模式识别、状态预测等方面。粒子群优化(PSO)算法是近年来由 J. Kennedy 和 R. C. Eberhart 等开发的一种基于迭代的进化算法^[13]。系统先进行初始化，得到随机律解，经过不断迭代来找到最优解。PSO 算法简单容易实现，并且不需要过多参数调整，大多数情况下，所有的粒子能更快地收敛于最优解^[14]。目前 PSO 算法已广泛应用于优化函数、训练神经网络和其他领域。笔者提出一种粒子群优化极限学习机(PSO-KELM)的方法，通过将 PSO 算法和核函数极限学习机运用到相控阵雷达辐射源识别中，用 PSO 算法求得核函数极限学习机的最佳参数，避免了由于参数设置而导致识别率不佳的问题，提高了相控阵雷达识别率。

1 核函数极限学习机

对于广义单隐层前馈神经网络，传统的学习算法，如 BP 神经网络或支持向量机(support vector machine, SVM)，通过优化过程来调整网络的权值和偏差值。由于网络训练过程可能陷入局部极小值，这类学习技术通常速度较慢，可能会降低网络的泛化能力。

ELM 是一种新兴的广义单隐层前馈神经网络学习算法(single-hidden-layer feedforward neural network, SLFN)，其隐层参数是随机产生，不需要调整，因此在获取训练样本前就可以建立隐层节点。ELM 的输出层权重用最小二乘法一步得到。

假设有任意 N 个不同样本 $\{(x_i, t_i) | x_i \in R^n, t_i \in R^L, i=1, 2, \dots, N\}$ ，其中： x_i 为训练数据向量； t_i 为每个样本的目标； L 为隐藏节点的个数； $h(x)$ 为激励函数。单隐层前馈网络可以建模为：

$$f_j(x) = \sum_{i=1}^L \beta_i h(w_i \cdot x_j + b_i), j=1, 2, \dots, N. \quad (1)$$

式中： $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]$ 为连接输入层节点到第 i 个隐藏节点的权重； $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{iL}]^T$ 为连接第 i 个隐藏节点到输出层节点的权重向量； b_i 为第 i 个隐藏节点的阈值； $f_j(x)$ 为第 j 个输入数据的神经网络输出。ELM 为使输出结果 $f(x)$ 与目标结果 $f_o(x)$ 间的误差最小，即：

$$\lim_{L \rightarrow \infty} \|f(x) - f_o(x)\| = \lim_{L \rightarrow \infty} \left\| \sum_{i=1}^L \beta_i h_i(x) - f_o(x) \right\| = 0. \quad (2)$$

ELM 通过输出权重 β 达到最小值，以保证神经网络有更好的泛化能力。一般权重 β 取最小二乘解：

$$\beta = \mathbf{H}^+ \mathbf{T} = \mathbf{H}^T (\mathbf{H} \mathbf{H}^T)^{-1} \mathbf{T} = \mathbf{H}^T (\mathbf{I}/C + \mathbf{H} \mathbf{H}^T)^{-1} \mathbf{T}. \quad (3)$$

式中： C 为调节系数，可以使结果具有更好的泛化能力； \mathbf{I} 为单位矩阵； \mathbf{H} 为隐藏层矩阵，

$$\mathbf{H} = \begin{bmatrix} h(w_1 x_1 + b_1) & \cdots & h(w_L x_1 + b_L) \\ \vdots & & \vdots \\ h(w_1 x_N + b_1) & \cdots & h(w_L x_N + b_L) \end{bmatrix}_{N \times L}. \quad (4)$$

\mathbf{H}^+ 为 \mathbf{H} 的广义逆矩阵； \mathbf{T} 为样本预期输出矩阵。

经过训练 ELM 模型的输出为：

$$f(x) = h(x) \beta = h(x) \mathbf{H}^T (\mathbf{I}/\lambda + \mathbf{H} \mathbf{H}^T)^{-1} \mathbf{T}. \quad (5)$$

标准 ELM 使用随机算法，无法保证稳定性和持续性，引入核函数能有效避免随机参数的使用，使模型更稳定，提高了准确性。笔者采用径向基核函数，提高数据区分度，解决数据线性不可分的问题。基于核函数极限学习机(KELM)的输出函数可表示为：

$$f(x) = h(x) \mathbf{H}^T (\mathbf{I}/\lambda + \mathbf{H} \mathbf{H}^T)^{-1} \mathbf{T} = \begin{bmatrix} k(x, x_1) \\ \vdots \\ k(x, x_N) \end{bmatrix}^T \left(\frac{\mathbf{I}}{\lambda} + \mathcal{Q}_{\text{ELM}} \right)^{-1} \mathbf{T}. \quad (6)$$

式中 \mathcal{Q}_{ELM} 为径向基函数， $\mathcal{Q}_{\text{ELM}}_{ij} = \exp(-\|x_i - x_j\|^2 / 2\sigma^2)$ 。对于 KELM，不需知道隐藏层矩阵 \mathbf{H} ，只需调节核函数参数即可。

2 粒子群优化算法

粒子群算法最早由 Eberhart 和 Kennedy 提出, 基本概念源于对鸟群觅食行为的研究。用一种粒子来模拟鸟类个体, 每个粒子可视为 D 维搜索空间中的个体, 粒子当前所在位置是相关优化问题的一个候选解, 粒子的不断移动, 构成了该个体搜索最优解的过程。粒子移动速度可由粒子之前最优位置和种群之前最优位置不断调整。粒子仅具有 2 个属性: 速度和位置, 速度代表移动的快慢, 位置代表移动的方向。每个粒子单独搜寻的最优解叫个体极值, 粒子群中最优的个体极值作为当前全局最优解, 不断迭代, 更新速度和位置, 最终得到满足终止条件的最优解。

假定在 D 维搜索空间中, 存在种群 $X=(X_1, X_2, \dots, X_n)$, $X_i=(X_{i1}, X_{i2}, \dots, X_{iD})$ 代表第 i 个粒子在 D 维搜索空间中的位置。每个粒子都对应一个根据目标函数决定的适应值。第 i 个粒子的速度为 $V_i=(V_{i1}, V_{i2}, \dots, V_{iD})^T$, 其个体极值为 $P_i=(P_{i1}, P_{i2}, \dots, P_{iD})^T$, 种群群体极值为 $P_g=(P_{g1}, P_{g2}, \dots, P_{gD})^T$ 。先将粒子初始化, 随机初始位置与速度, 再通过迭代找到最优解。粒子通过多次迭代, 跟踪 2 个“极值” (P_i, P_g) 来更新自身。找到这 2 个最优值后, 粒子通过式(7)和式(8)更新自身的速度及位置:

$$\begin{aligned} V_{id}^{k+1} &= V_{id}^k + c_1 \times \text{rand}_1() \times (P_{id}^k - X_{id}^k) + \\ &\quad c_2 \times \text{rand}_2() \times (P_{gd}^k - X_{id}^k); \end{aligned} \quad (7)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1}. \quad (8)$$

式中: $d=1, 2, \dots, D$; $i=1, 2, \dots, n$; V_{id} 为粒子速度; n 为群中粒子总数; k 为当前迭代次数; $\text{rand}()$ 为在 $(0, 1)$ 间的随机数; X_{id} 为粒子当前位置; c_1, c_2 为非负常数, 称为学习因子。

式(7)中: V_{id}^k 为“记忆项”, 表示上次速度; $c_1 \times \text{rand}_1() \times (P_{id}^k - X_{id}^k)$ 为“自身认知项”, 表示从当前点粒子指向自身最佳位置的一个矢量; $c_2 \times \text{rand}_2() \times (P_{gd}^k - X_{id}^k)$ 为“群体认知项”, 是一个从当前点指向种群最佳位置的矢量, 反映了粒子间的信息互通。粒子是通过自身的经验和其他粒子中最佳经验决定之后的运动。

通过引入惯性因子 ω , 可得:

$$\begin{aligned} V_{id}^{k+1} &= \omega V_{id}^k + c_1 \times \text{rand}_1() \times (P_{id}^k - X_{id}^k) + \\ &\quad c_2 \times \text{rand}_2() \times (P_{gd}^k - X_{id}^k). \end{aligned} \quad (9)$$

其中 $\omega \geq 0$, ω 较大时, 全局优化能力强, 局部优化

能力弱。动态 ω 比固定 ω 的优化效果更佳。 ω 可以线性变化, 也可根据某个测度函数动态改变。目前使用较广泛的是线性递减权值 (linearly decreasing weight, LDW) 策略:

$$\omega = (\omega_{\text{start}} - \omega_{\text{end}})(G_k - g) / G_k + \omega_{\text{end}}. \quad (10)$$

式中: ω_{start} 为初始惯性权值; ω_{end} 为最大迭代次数时的惯性权值; G_k 为最大迭代次数。典型权值为 $\omega_{\text{start}}=0.9$, $\omega_{\text{end}}=0.4$ 。式(8)和式(9)即为 PSO 算法的标准式。

PSO 算法操作简便, 且对于优化函数没有连续可微的要求, 比较通用, 在多变量、非线性不连续和不可微问题时较占优势; 因此, 使用 PSO 算法计算径向基核函数的最优解。

基于 PSO-KELM 方法的相控阵雷达识别流程如图 1 所示。

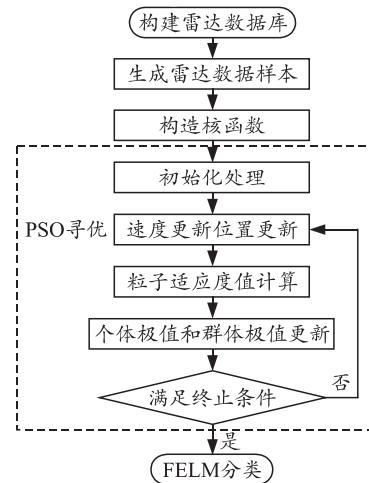


图 1 基于 PSO-KELM 方法的雷达识别流程

1) 通过相控阵雷达数据库参数, 生成用于分类器训练和测试的雷达数据样本;

2) 基于核函数的理论, 可选择径向基函数, 构造 KELM;

3) 训练 KELM 分类器, 通过 PSO, 初始化粒子速度及位置, 不断迭代更新适应度值和极值, 算得核函数的最优解;

4) 将雷达数据输入到 KELM 分类器进行识别, 得出结果。

3 仿真分析

仿真分析 PSO-KELM 运用于相控阵雷达辐射源识别的优越性。笔者选取的数据库中包含 7 种不同雷达, 粒子群优化中, 种群规模设为 20, 迭代次数为 100, 学习因子 $c_1=c_2=2$, 惯性权值为 $\omega_{\text{start}}=0.9$, $\omega_{\text{end}}=0.4$ 。在不同噪声环境下对基于 PSO-KELM 的

雷达辐射源识别进行 500 次 Monte Carlo 仿真实验，并与 KELM、KSVM 和文献[15]中的 SSTL 算法的雷达辐射源识别方法进行对比。具体实验如下：

1) 构建雷达数据库。参数选取为雷达工作频率、脉冲重复频率和脉冲宽度。工作频率服从均匀分布，脉冲重复频率和脉冲宽度服从正态分布。具体参数如表 1 所示，其中： X 为雷达种类， f 为工作频率， PRF 为脉冲重复频率， PW 为脉冲宽度。

根据上表的参数对前 5 种雷达进行仿真，每部雷达分别产生 160 个样本，总共 800 个样本，构成

雷达数据库。其中每部雷达的 100 个样本作为训练集，60 个作为测试集，得到雷达辐射源数据样本如表 2 所示。篇幅原因，表 2 只列出实际 800 个样本中的 50 个。

表 1 相控阵雷达数据库参数

X	f/MHz	PRF/Hz	PW/ms
1	[100,300]	[1 450,25]	[80,5]
2	[290,800]	[1 340,25]	[90,5]
3	[780,900]	[1 060,25]	[100,8]
4	[890,1 100]	[920,20]	[110,9]
5	[1 090,1 200]	[1 570,20]	[80,5]
6	[1 190,1 210]	[1 290,20]	[90,8]
7	[1 200,1 270]	[1 120,25]	[80,12]

表 2 相控阵雷达样本参数

X	f/MHz	PRF/Hz	PW/ms	X	f/MHz	PRF/Hz	PW/ms	X	f/MHz	PRF/Hz	PW/ms
1	197.83	1 484.64	86.09	2	322.40	1 322.72	85.66	4	971.64	952.61	112.65
1	100.88	1 450.93	84.01	2	407.95	1 320.45	92.13	4	1 063.96	913.18	104.30
1	281.83	1 489.02	87.93	2	694.58	1 333.73	92.77	4	1 051.20	903.63	97.74
1	249.24	1 414.39	80.20	3	808.51	1 074.59	99.07	4	981.68	951.98	106.47
1	133.77	1 480.83	88.71	3	835.96	1 086.87	113.62	4	1 009.65	908.13	91.55
1	133.90	1 470.89	78.29	3	871.83	1 063.18	118.01	4	995.09	953.87	107.02
1	176.51	1 427.77	86.32	3	839.45	1 048.74	95.24	5	1 107.35	1 579.51	83.61
1	248.30	1 447.03	82.09	3	815.57	1 062.04	93.11	5	1 101.85	1 592.20	80.74
1	288.87	1 428.26	76.03	3	788.28	1 027.88	103.49	5	1 137.01	1 538.23	78.71
1	228.19	1 489.64	86.25	3	877.33	1 090.07	118.50	5	1 139.21	1 572.08	77.82
2	650.16	1 342.95	84.60	3	899.81	1 104.99	91.33	5	1 175.04	1 601.36	86.22
2	641.61	1 284.34	80.27	3	895.02	1 062.04	96.26	5	1 134.71	1 576.71	82.03
2	313.29	1 372.64	94.92	3	817.42	1 082.24	105.20	5	1 104.02	1 569.77	77.05
2	350.26	1 335.51	86.28	4	1 021.56	944.01	114.58	5	1 153.64	1 602.20	79.06
2	581.77	1 392.53	85.62	4	922.10	916.78	104.08	5	1 093.64	1 597.55	84.37
2	794.83	1 328.37	86.74	4	1 035.72	950.81	109.80	5	1 129.41	1 555.26	87.05
2	629.57	1 357.73	91.40	4	1 059.22	906.06	111.43				

2) 分类器的训练。使用雷达数据库中的 500 组数据对粒子群优化极限学习机进行训练，得到训练情况如图 2 所示。由图可知期望输出与实际输出契合较好。

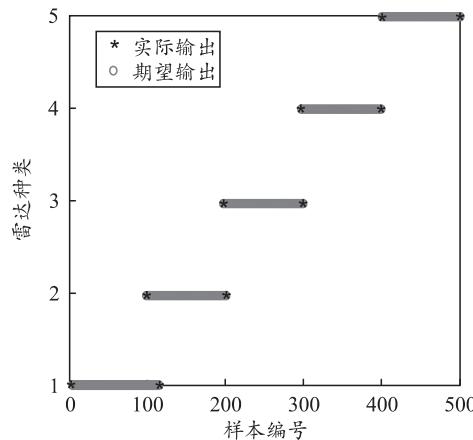


图 2 样本训练

3) 分类器的测试。对于雷达数据库中的测试集样本，先加入 4% 的高斯白噪声进行识别，如图 3 和图 4 所示。由图可知，这 5 种雷达区分度较好，此时识别准确率为 98.33%，经过 PSO-KELM 算出的径向基参数有 2 个，分别为惩罚系数 c 和 gamma 参数 g ，其值为 $c=58.56$, $g=15.73$ 。

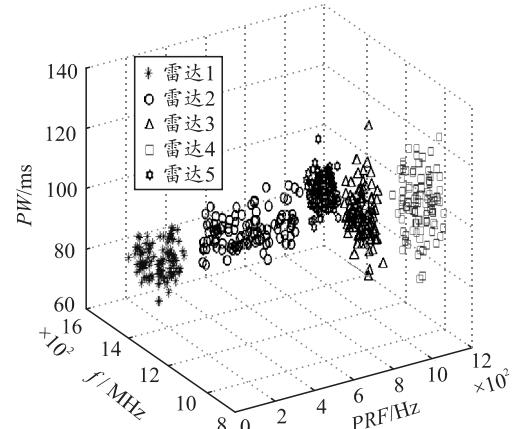


图 3 测试集识别 3 维图

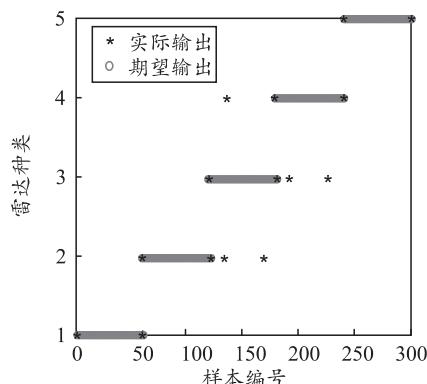


图 4 测试集识别 2 维图

4) 对比实验。对于雷达数据库中的测试集样本, 加入不同程度的高斯白噪声, 得到实际侦察到的雷达辐射源信号。首先对 5 种相控阵雷达进行识别, 分别将待测数据特征通过 PSO-KELM、KELM、FSVM 和 SSTL 方法进行识别, 在相同条件下各进行 500 次 Monte Carlo 仿真实验, 计算每种方法在相同噪声情况下的识别率, 结果如图 5 所示。再分别对前 4 种、6 种、7 种雷达进行相同实验, 得到不同雷达种类在 2%、4%、6%、8%、10% 噪声情况下的平均识别率如图 6 所示, PSO-KELM 在不同雷达种类下的识别率如图 7 所示, 在 2%、6%、10%、14% 的识别率如表 3 所示, 求得的径向基最佳参数值 c 和 g 如表 4 所示, X 为雷达种类。

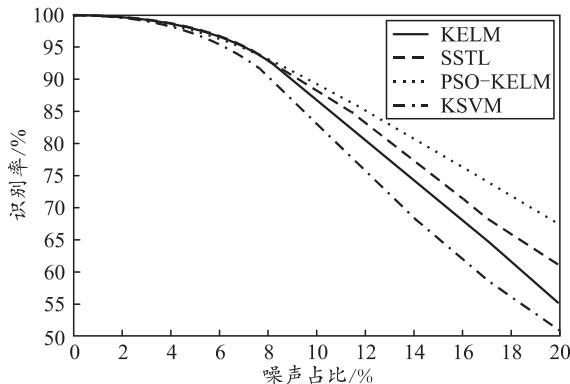


图 5 不同方法对 5 种雷达的识别率对比

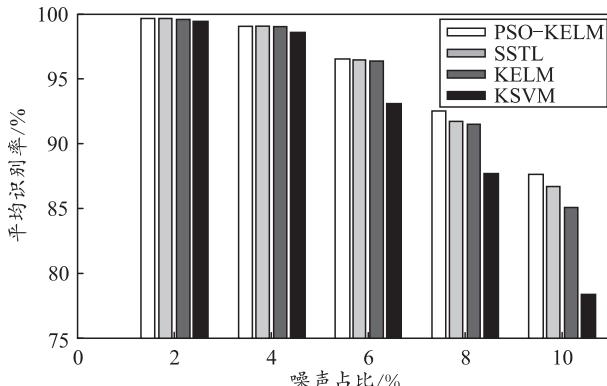


图 6 平均识别率

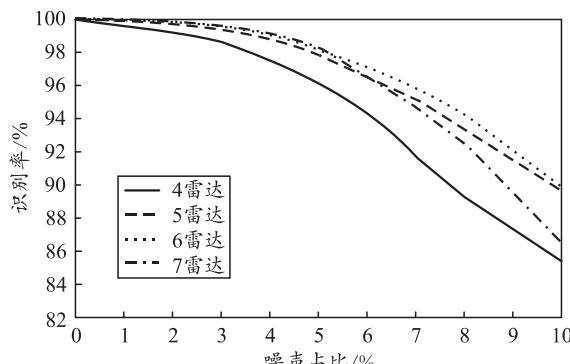


图 7 PSO-KELM 在不同雷达种类下的识别率

表 3 不同方法对雷达的识别率 %

X	噪声占比	识别率			
		PSO-KELM	SSTL	KELM	KSVM
4	2	99.20	99.19	99.19	98.97
	6	94.29	94.05	93.75	89.99
	10	84.42	83.98	81.45	75.29
	14	73.72	71.26	67.27	62.24
5	2	99.83	99.81	99.61	99.45
	6	96.53	96.52	96.52	93.67
	10	89.67	88.37	87.98	83.73
	14	80.46	77.46	74.85	68.21
6	2	99.81	99.80	99.79	99.78
	6	97.19	97.17	97.17	93.21
	10	89.92	88.98	86.37	79.38
	14	78.93	75.26	67.97	60.94
7	2	99.88	99.86	99.85	99.71
	6	98.22	98.18	98.14	95.37
	10	86.56	85.96	84.76	75.08
	14	74.46	70.21	64.35	60.63

表 4 通过 PSO-KELM 求出的最佳参数值

X	噪声占比/%	最佳参数	
		c	g
4	2	98.50	64.08
	6	45.80	87.33
	10	52.56	92.17
	14	85.12	15.69
5	2	53.85	24.36
	6	77.80	61.67
	10	94.62	70.19
	14	90.86	17.30
6	2	78.12	71.21
	6	82.50	24.27
	10	96.97	40.30
	14	91.12	80.97
7	2	45.39	87.33
	6	73.61	90.88
	10	60.17	77.55
	14	99.34	21.23

由图 5—7 可得, 几种不同的方法对雷达信号的识别率随着噪声的增多而降低, 笔者所提出的 PSO-KELM 方法在噪声含量为 10% 时, 仍能达到 86% 以上的识别率, 且在不同雷达种类、不同噪声情况下均要优于其他方法。这是因为 PSO-KELM 泛化能力强、训练参数少、精度高、收敛速度快, 并且能准确求出核函数的最佳参数。这些特性优于其他方法, 因此提高了识别精度。

4 结论

笔者提出一种基于粒子群优化极限学习机的相控阵雷达辐射源识别方法。通过将粒子群优化算法引入相控阵雷达辐射源识别中, 并与核函数极限学习机、核函数支持向量机和半监督式迁移学习算法的识别率进行对比。结果表明: 该方法优于其他方法, 且在噪声占比为 10% 时, 识别率仍在 86% 以上。

参考文献:

- [1] 张玉虎, 周正. 基于信号聚集度的相控阵雷达识别技术[J]. 火力与指挥控制, 2018, 43(8): 22–24, 30.

(下转第 10 页)