

引用格式:郭小康,简涛,董云龙.基于 PSO-KPCA-LVQ 神经网络的雷达一维距离像识别[J].电光与控制,2019,26(6):22-26. GUO X K, JIAN T, DONG Y L. Radar one-dimensional range profile recognition based on PSO-KPCA-LVQ neural network[J]. Electronics Optics & Control, 2019, 26(6): 22-26.

基于 PSO-KPCA-LVQ 神经网络的雷达一维距离像识别

郭小康, 简涛, 董云龙

(海军航空大学信息融合研究所, 山东烟台 264001)

摘要: 针对雷达目标一维距离像识别研究,将子空间法中的核主成分分析方法(KPCA)与LVQ神经网络相结合应用到雷达目标一维距离像识别中,提出了KPCA-LVQ算法,并取得了较好的识别效果。研究中发现,在使用核主成分分析时,存在核函数中未知参数难以确定的问题。针对此问题,深入分析核函数矩阵和核函数参数之间的关系发现,主成分的贡献率与核函数的参数之间存在着一定的对应关系。据此,确定了基于主成分贡献率的优化问题,并采用粒子群算法(PSO)进行优化求解,得到最优的核参数。实验分析结果表明,该方法克服了核主成分分析方法中依靠经验来确定未知参数的缺点,降低了计算量,提高了目标识别率。

关键词: 一维距离像; 目标识别; KPCA; 粒子群算法; LVQ神经网络

中图分类号: TN957 文献标志码: A doi:10.3969/j.issn.1671-637X.2019.06.005

Radar One-Dimensional Range Profile Recognition Based on PSO-KPCA-LVQ Neural Network

GUO Xiao-kang, JIAN Tao, DONG Yun-long

(Research Institute of Information Fusion, Naval Aviation University, Yantai 264001, China)

Abstract: The Kernel Principal Component Analysis (KPCA) method in the subspace method was used together with the LVQ neural network (KPCA-LVQ) for radar target one-dimensional range image recognition, which has achieved good recognition results. The study found that the unknown parameters in kernel function are difficult to determine when using KPCA. An in-depth analysis of the relationship between the kernel function matrix and the kernel function parameters revealed that there is a certain correspondence between the contribution rate of the principal component and the parameters of the kernel function. In this regard, an optimization problem based on principal component contribution rate was established, and Particle Swarm Optimization (PSO) algorithm was used for obtaining the optimal solution. The experimental analysis showed that the method overcomes the problem that the unknown parameters in KPCA is determined depending on experience, reduces the calculation cost and improves the target recognition rate.

Key words: one-dimensional range image; target recognition; KPCA; particle swarm optimization; LVQ neural network

0 引言

雷达目标高分辨距离像(High Resolution Range Profile, HRRP)能够反映出雷达目标在距离向上的信息、目标的几何结构、散射点的分布等情况,是一种极其重

要的目标识别技术^[1]。一维距离像相较于二维距离像等来说获取的方式比较简单,同时更加容易处理,成为现代战争环境下雷达目标识别研究常用的方法,具有很高的研究价值和意义。但是雷达目标一维距离像数据往往存在数据量大、冗余度高的问题,若直接用于目标识别,在增大计算量的同时又会造成识别率降低。主成分分析(Principal Component Analysis, PCA)方法是一种常用的特征提取降维的数据处理方法,可以将高维环境中多指标问题转化成低维的综合指标问题,极大地降低了数据维度,在极大地保留原始信息的同时又提高了数据处理的效率。但是主成分分析是一种

收稿日期:2018-08-01 修回日期:2018-08-28

基金项目:国家自然科学基金(61471379,61790551,61102166);国防科技基金项目基金(2102028);装备发展部“十三五”预研项目(41413060101);泰山学者工程专项经费资助

作者简介:郭小康(1993—),男,安徽合肥人,硕士生,研究方向为雷达目标识别、智能信息处理。

线性处理的方法,在实际利用雷达目标一维距离像识别过程中常常会遇到非线性情况,此时主成分分析很难解决这类问题。因此,本文利用主成分分析的扩展形式——核主成分分析(KPCA)^[2-3]进行数据的特征提取和降维处理,并结合神经网络应用于雷达目标一维距离像的识别研究。同时,针对核主成分分析方法中未知参数难以确定的问题,对核函数矩阵的特征值与核函数参数之间的关系进行研究,建立基于贡献率的优化问题,采用粒子群算法(Particle Swarm Optimization, PSO)求解,确定核函数的参数,从而提高雷达目标一维距离像的识别率。

1 LVQ 神经网络

神经网络作为一种性能优良的分器,近些年来得到了飞速发展^[4],其最大的特点就是具有很强的自适应能力,不但能够自适应学习,还能自适应调整网络规模的大小。学习向量量化(Learning Vector Quantization, LVQ)神经网络拥有很强的分类识别能力,因而得到了广泛的应用^[5]。

LVQ 是一种用于训练竞争层的有监督的网络,其算法源自于 Kohonen^[6]竞争算法。

图 1 所示为 LVQ 神经网络模型^[7]。




图 1 LVQ 神经网络模型

Fig.1 LVQ neural network model

LVQ 神经网络有输入层、竞争层和输出层 3 层神经元。该网络输入层和竞争层之间采用全连接的方式,其连接权值在进行网络训练时会发生改变。竞争层和输出层为部分连接,每个竞争层神经元只与一个输出层神经元连接,且连接权值恒为 1,而每个输出层神经元可与多个竞争层神经元相连接,竞争层和输出层神经元值只能为 0 或 1。当一个输入模式进入网络后,依据距离最近准则,与输入模式最近的竞争层神经元被“激活”,神经元的状态为“1”,其他为“0”,而与竞争层相连接的输出层的神经元状态也为“1”,其他为“0”。每个输出神经元表示不同的类别,状态为“1”的神经元给出输入模式的类别。

2 优化核主成分分析 (PSO-KPCA) 法的基本思想

核主成分分析(KPCA)法是对主成分分析(PCA)算法的非线性扩展,为了更好地处理数据,引入一个非线性映射函数 Φ ,将原始空间 R^N 中的样本向量 x_k 映射到高维空间 F 中,即 $R^N \rightarrow F, x_k \rightarrow \Phi(x_k)$,将原本线性不可分的变成线性可分,然后再在高维空间 F 中进行主成分分析。

假设中心化后的样本集合为 $X, \{x_1, x_2, \dots, x_N\}$ 为 R^N 空间中样本集合,有 N 个样本,每个样本维度均为 d ,将其映射到高维空间 F 中得到 $\Phi(X)$,其中, $\sum_{i=1}^N \Phi(x_i) = 0$ 。设高维空间中的特征向量为 $v_i, i = 1, 2, \dots, d$,对应的特征值为 $\lambda_i, i = 1, 2, \dots, d$,其中,特征向量可用空间中的样本集合线性表示,即存在一组参数 $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_N)$ 满足

$$v_i = \sum_{i=1}^N \alpha_i \Phi(x_i) = \alpha \Phi(X) \quad (1)$$

在高维空间中使用 PCA,有

$$\Phi(X) \Phi(X)^T v_i = \lambda_i v_i \quad (2)$$

将式(1)代入式(2)可得

$$\Phi(X) \Phi(X)^T \Phi(X) \alpha = \lambda_i \Phi(X) \alpha \quad (3)$$

式(3)两边同时左乘 $\Phi(X)^T$ 得

$$\Phi(X)^T \Phi(X) \Phi(X)^T \Phi(X) \alpha = \lambda_i \Phi(X)^T \Phi(X) \alpha \quad (4)$$

此时两边都含有 $\Phi(X)^T \Phi(X)$,将其用核矩阵 K 来替换。

核函数通常满足 Mercer 定理,常用的核函数有:多项式核函数

$$K(x, x_i) = [a(x, x_i) + b]^q \quad (5)$$

高斯核函数

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (6)$$

多层感知器核函数

$$K(x, x_i) = \tanh(v(x, x_i) + c) \quad (7)$$

其中, a, b, σ, v 和 c 均为核函数参数。式(4)可以变换为

$$K^2 \alpha = \lambda_i K \alpha \quad (8)$$

两边同时消去一个 K ,得到 $K \alpha = \lambda_i \alpha$,形式上和主成分分析相同, K 的特征值 λ^k 对应的特征向量为 α^k ,此时对于任意的测试样本向量 x_{new} ,映射到高维空间中有

$$\begin{aligned} (\alpha^k \Phi(x_{\text{new}})) &= \sum \alpha_i^k (\Phi(x_i) \cdot \Phi(x)) = \\ &= \sum \alpha_i^k K(x_i, x) \end{aligned} \quad (9)$$

观察式(5)~式(7)可发现,通常核函数中都存在未知的参数,这些参数影响着 KPCA 的效果,参数选取

合适时,效果较好,可以更大程度地降低数据维度,减小计算量。目前来说,核函数参数的选择大多依赖于经验,或者利用大量的实验确定合适的参数,增加了实验成本、计算量以及不确定性。经过多次的实验总结以及对核函数矩阵和核函数参数之间关系的研究发现,主成分贡献率与核函数的参数之间存在着一定的对应关系。以第一主成分贡献率为目标函数,以核函数的参数为变量,建立一个最优化的问题来确定在实际问题处理过程中最佳的核函数参数。将粒子群优化(PSO)算法应用于该问题,利用 PSO 算法求解优化问题,提出了优化核主成分分析(PSO-KPCA)算法。

粒子群优化算法是由 KENNEDY 等提出的模拟鸟的群体智能行为的一种优化算法^[8]。粒子群算法中,一个粒子代表一只鸟,每个粒子用其自身的位置和速度来表示,并依据自身的初定方向、自己的经验最优方向和周围粒子的经验最优方向来更新其位置和速度,通过定义适应度函数来评价每个粒子的表现。

3 PSO-KPCA 算法实现

原始样本为 X_2 , 选定合适的核函数将数据映射到高维空间 F 中,依据实验总结的经验初步设置核函数的参数,并给定核函数参数的变化范围,计算核矩阵 K ,对核矩阵进行中心化处理,即

$$\hat{K} = K - L * K / m - K * L / m + L * K * L / (m * m) \quad (10)$$

式中: m 为矩阵 K 的维度; L 为元素全为 1 的 $m \times m$ 的矩阵。而后求出中心化后的矩阵 \hat{K} 的特征值 $\lambda_i, i=1, 2, \dots, d$, 将特征值按从大到小顺序排列为 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d$, 其对应的单位正交特征向量为 $v_i, i=1, 2, \dots, d$, 单位正交特征向量矩阵 $V = (v_1, v_2, \dots, v_d)$ 。最大的特征值 λ_1 对应的主成分为第一主成分,计算第一主成分的贡献率为

$$\eta_1 = \lambda_1 / \sum_{i=1}^d \lambda_i \quad (11)$$

当核函数参数不同时,对应的第一主成分贡献率 η_1 也会发生变化,故将核函数参数作为变量用粒子群优化算法进行优化,以主成分贡献率作为目标函数也即适应度函数建立优化问题,并利用粒子群算法解决此优化问题。

设置 PSO 算法的参数 c_1, c_2, r_1 和 r_2 , 初始化粒子群即定义种群规模、迭代次数等参数,初始化粒子的速度和位置。通过计算得到每个粒子的初始适应度函数,将适应度最大值作为初始的全局最优,而后进行粒子群的迭代更新。

粒子的速度算式为

$$v_{ij}(t+1) = v_{ij}(t) + c_1 r_1 [y_{ij}(t) - x_{ij}(t)] +$$

$$c_2 r_2 [\hat{y}_j(t) - x_{ij}(t)] \quad (12)$$

粒子的位置算式为

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (13)$$

式中: $v_{ij}(t)$ 是粒子 i 在 t 时刻第 j 维上的速度, $i=1, 2, \dots, m, m$ 为粒子个数, $j=1, 2, \dots, J, J$ 为粒子的维度(或搜索空间的维度); c_1 和 c_2 是正数的加速度常量; r_1 和 r_2 是区间 $[0, 1]$ 之间的随机数; $y_{ij}(t)$ 是第 i 个粒子过去的最优位置; $\hat{y}_j(t)$ 是整个粒子群过去的最优位置; $x_{ij}(t)$ 是第 i 个粒子在 t 时刻第 j 维上的位置。粒子每一维上位置和速度的变化都有一定的范围: $v_{ij} \in [-V_{\max}, V_{\max}]$, $x \in [-X_{\max}, X_{\max}]$, V_{\max} 和 X_{\max} 均为正的常数。

粒子群的每次更新也对应着粒子适应度的更新,以及粒子群全局最优和粒子最优的更新,个体最优和全局最优又作用于粒子群的更新。当迭代完成时,得到最优的适应度值及对应的粒子。图 2 为使用粒子群优化算法优化核函数参数流程图。

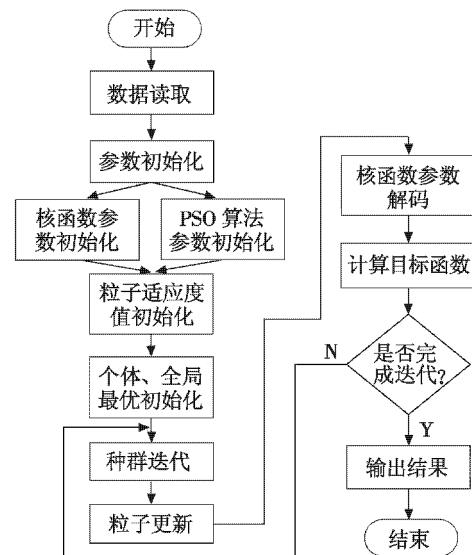


图2 PSO 算法优化核函数参数算法流程图

Fig. 2 Flow chart of PSO algorithm optimizing kernel function parameter algorithm

解码得到最优的核函数参数,将其代入重新计算核函数矩阵,得到新的特征值和特征向量,计算各个主成分的贡献率及累计贡献率,设前 j 个主成分的累计贡献率为 η_j , 即

$$\eta_j = \sum_{i=1}^j \lambda_i / \sum_{i=1}^d \lambda_i \quad j \leq d \quad (14)$$

前 j 个特征值特征向量矩阵为 $V_2 = (v_1, v_2, \dots, v_j)$, 则前 j 个主成分为 $Y = (Y_1, Y_2, \dots, Y_j)^T = V_2^T X$ 。

4 实验分析

4.1 数据处理

实验采用的实测数据是国内某研究所的 ISAR 实验飞机数据,实验飞机有 3 种,分别为安-26、“桨状”和

雅克-42。雷达为逆合成孔径 C 波段雷达,中心频率约为 5.5 GHz,波长约为 0.05 m,信号带宽为 400 MHz,距离分辨力为 0.375 m,采样点数为 256。每种飞机记录了 7 段数据,每段数据含 26 000 个宽、窄带信号(间隔 2.5 ms)。宽带信号为全去斜后的正交双通道信号(其快速傅里叶变换(FFT)即为一维距离像),每段数据含 260 个宽带正交双通道信号。实验数据为 3 种飞机各取 1 段的 260 幅距离像。

一维距离像存在着方位敏感性和幅度敏感性,它们是一维距离像识别的关键问题之一。为了有效地识别目标,必须进行数据的预处理。FFT^[9]法在频域具有平移不变性,对目标的一维距离像做傅里叶变换,在时域里的平移对频域没有产生影响,这样能够克服雷达目标一维距离像的平移敏感性,对距离像幅度谱进行归一化解决幅度敏感性^[10]。为克服一维距离像的幅度和平移敏感性,分别对数据进行如下两步处理:

- 1) 归一化,将每一幅图像用其总能量归一化;
- 2) 距离对准,利用 FFT 的平移不变性,将一维距离像做 FFT 即可对齐。

每种目标选取 160 个样本组成训练集,剩余 100 个样本组成测试集。设置隐含层神经元个数为 50,粒子种群规模的规模为 50,迭代次数为 50。

进行 LVQ 神经网络训练。随机产生 $n \times m$ 维的初始权值矩阵(n 为 LVQ 网络的竞争层神经元数目, m 为数据维度),将分别经过主成分分析方法、核主成分分析方法以及优化核主成分分析方法处理的训练数据集输入网络中进行训练,得到训练模板库。

4.2 结果分析

对雷达目标一维距离像数据进行预处理之后,分别采用主成分分析方法、核主成分分析方法以及优化核主成分分析方法(为叙述方便,后文以方法 1、方法 2 和方法 3 替代)提取特征,计算主成分,图 3 所示为 3 种算法的主成分维数与累计贡献率之间的关系。

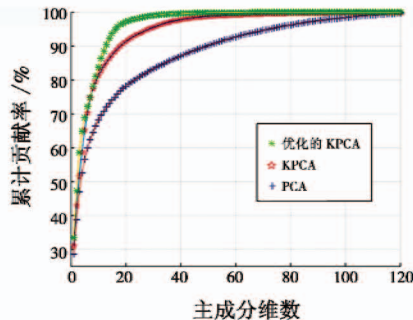


图 3 3 种算法的主成分维数与累计贡献率的关系
Fig. 3 The relationship between the principal component dimension and the cumulative contribution rate of the three algorithms

由图 3 可知,当主成分维数相同时,方法 3 的累计贡献率高于方法 2,而方法 2 又高于方法 1。以主成分贡献率超过 90% 为界限,当累计贡献率达到 90% 时,方法 1 数据需要 50 维,方法 2 数据由 50 维降到 18 维,而方法 3 数据仅需 13 维。由此可知,在达到规定要求的识别率的基础上,从方法 1 到方法 3,所需数据的规模逐渐变小,有利于减小计算量,降低算法复杂度。

表 1 所示为 PCA 网络平均识别率与竞争层神经元个数关系的分析表格,目标的识别率和 LVQ 神经网络的竞争层神经元之间有着一定的关系,神经元太少会影响分类识别率,神经元太多又容易导致计算量过大。

表 1 PCA 网络平均识别率与竞争层神经元个数关系

Table 1 Relationship between average PCA-network recognition rate and number of competitive layer neurons

	神经元个数					
	20	30	50	70	100	200
PCA 网络平均识别率/%	82.5	87.3	90.7	92.2	93.6	94.1

从表 1 可知,随着竞争层神经元数据的增加,采用 PCA 网络的平均识别率也在提高,但增加幅度开始减小,经过实验分析,本文采用 50 个竞争层神经元进行实验分析。

表 2 所示为在相同的神经网络规模下,3 种识别系统的平均识别率和数据规模的比较,表 3 所示为 4 种网络在不同的训练步数时,网络训练所需时间的对比分析。

表 2 相同网络规模下各识别系统平均识别率及数据规模
Table 2 Average recognition rate and data size of each identification system under the same network scale

	识别系统		
	PCA-LVQ 网络	KPCA-LVQ 网络	PSO-KPCA-LVQ 网络
平均识别率/%	90.7	91.5	92.3
数据规模	25/64	9/64	7/64

表 3 4 种网络训练所需时间对比分析表

Table 3 Training time of the four networks

识别系统	网络训练步数				
	40	80	120	160	200
LVQ 网络	55	106	163	220	275
PCA-LVQ 网络	41	82	121	163	205
KPCA-LVQ 网络	29	60	87	119	150
PSO-KPCA-LVQ 网络	29	59	87	118	150

由表 2 和表 3 可知,PSO-KPCA-LVQ 网络的识别率高于 KPCA-LVQ 网络和 PC-LVQ 网络,且其所用数据规模比二者小,此外,经过方法 1、方法 2 优化后的 LVQ 神经网络所需的训练时间大大缩短,其中方法 2 对网络的优化提升效果又优于方法 1。因此,这 3 种算法在降低数据规模、计算量的同时,依旧能保持较好的识别效果。

5 结 论

基于雷达目标一维距离像的目标识别方法在雷达目标识别领域中占据着重要的地位,本文以 LVQ 神经网络作为目标识别的分类器,同时分析比较了主成分分析、核主成分分析以及粒子群优化的核主成分分析用于特征提取。经实验表明:由粒子群算法优化后的核主成分分析应用于特征提取,首先克服了原核主成分分析方法中依靠经验来确定未知参数的缺点,能够准确地得到最优的参数;其次,大大降低了数据的复杂程度,减小了计算量,又确保具有较高的识别率。

参 考 文 献

- [1] 刘宏伟,杜兰,袁莉,等. 雷达高分辨距离像目标识别研究进展[J]. 电子与信息学报,2005,27(8):1328-1334.
- [2] 彭红星,潘梨莉,赵鸿图. 一种改进的 KPCA 传感器故障识别方法及其应用[J]. 仪表技术与传感器,2016(6):92-94.
- [3] 曾番,黄文龙,夏伟鹏,等. 小波包特征能量算子与多核函数组合 KPCA 的声目标识别[J]. 电光与控制,2017,24(4):5-7.
- [4] 王力,周志杰,赵福均. 基于 BP 神经网络和证据理论的超声检测缺陷识别[J]. 电光与控制,2018,25(1):65-69.
- [5] 宋娟,邹翔,尹俭芳,等. 基于神经网络的人脸朝向识别研究[J]. 工业控制计算机,2017,30(4):111-112.
- [6] KOHONEN T. Self-organization and associative memory [M]. 3rd ed. Berlin:Springer, 1989.
- [7] 夏飞,罗志疆,张浩,等. 混合神经网络在变压器故障诊断中的应用[J]. 电子测量与仪器学报,2017,31(1):118-124.
- [8] MUNLIN M, ANANTATHANAVIT M. Hybrid radius particle swarm optimization [C]//Region 10 Conference, IEEE, 2017:1-5.
- [9] 袁莉,刘宏伟,保铮. 基于中心矩特征的雷达 HRRP 自动目标识别[J]. 电子学报,2004,32(12):2078-2081.
- [10] DU L, LIU H, BAO Z, et al. Radar automatic target recognition using complex high-resolution range profiles [J]. LET Radar, Sonar & Navigation, 2007, 1(1):18-26.
- (上接第 21 页)
- [4] 潘国锋. 基于 K-S 算法的水质硝酸盐含量光谱检测方法研究[J]. 光谱实验室,2011,28(5):2700-2704.
- [5] 梁晨. 近红外光谱多元校正模型传递方法的研究[D]. 北京:北京化工大学,2016.
- [6] 王菊香,孟凡磊,刘林密,等. 样品选择结合分段直接校正法和偏最小二乘法用于近红外光谱分析模型传递研究[J]. 兵工学报,2016,37(1):91-96.
- [7] LIANG C, ZHAO Z, CAO Y T, et al. A new study of calibration model transfer method for near-infrared spectral analysis[J]. Spectroscopy and Spectral Analysis, 2017, 37(5):1587-1594.
- [8] 王晓阳,张洪渊,沈良忠,等. 基于相似性度量的高维数据聚类算法研究[J]. 计算机技术与发展,2013,23(5):30-33.
- [9] 陈海燕,刘晨晖,孙博. 时间序列数据挖掘的相似性度量综述[J]. 控制与决策,2017,32(1):1-10.
- [10] 李海林,郭崇慧. 时间序列数据挖掘中特征表示与相似性度量研究综述[J]. 计算机应用研究,2013,30(5):1285-1291.