

## 基于中心矩特征和 GA-BP 神经网络的雷达目标识别

赵东波<sup>1,2</sup>, 李 辉<sup>2</sup>

- (1. 西安航空学院 电子工程学院, 陕西 西安 710077;  
2. 西北工业大学 电子信息学院, 陕西 西安 710129)

**摘 要:** 在雷达目标识别中, 利用核主分量分析(KPCA)方法来进行目标特征提取, 忽略了高分辨率距离像(HRRP)的本身特性。提取一种平移不变特征-中心矩作为特征向量, 采用 KPCA 进行特征降维; 由于 BP 神经网络易陷入局部极小, 采用遗传算法(GA)对 BP 网络节点权值和阈值进行优化选择。基于雷达实测数据的实验结果表明: 平移不变的 KPCA 特征提取方法实现了平移不变和降维的结合, 同时, 利用 GA 优化 BP 神经网络提高了分类器稳定性改善易陷入局部最小的缺陷, 提高了雷达目标识别的性能。

**关键词:** 高分辨率距离像; 核主分量分析; 中心矩; 遗传算法; BP 神经网络  
**中图分类号:** TN959.1   **文献标志码:** A   **DOI:** 10.3788/IRLA201847.0826005

## Radar target recognition based on central moment feature and GA-BP neural network

Zhao Dongbo<sup>1,2</sup>, Li Hui<sup>2</sup>

- (1. School of Electronic Engineering, Xi'an Aeronautical University, Xi'an 710077, China;  
2. School of Electronic Information, Northwestern Polytechnical University, Xi'an 710129, China)

**Abstract:** When using the method of kernel principal component analysis (KPCA) to extract feature of target in radar target recognition, the HRRP characteristic is ignored. A translation invariant features-central moments was extracted as feature vector, KPCA was used to reduce the dimensionality; The BP neural network was easy to fall into local minimum, the genetic algorithm(GA) was used to optimize the BP network node weights and threshold. The experimental results based on the measured radar data show that the translation invariant KPCA feature extraction method achieve the combination of translation invariant and descending dimension, and the BP neural network optimized by GA improves the stability of classifier and improves the defect of falling into local minimum easily.

**Key words:** high resolution range profile (HRRP); kernel principal component analysis; central moment; genetic algorithm (GA); BP neural network

收稿日期: 2018-03-09; 修订日期: 2018-04-12

基金项目: 国家自然科学基金(61571364); 陕西省自然科学基金(2017JM6037); 陕西省教育厅专项研究计划(17JK0397)

作者简介: 赵东波(1979-), 男, 讲师, 硕士, 主要从事模式识别、信号处理方面的研究。Email: alien\_dffy@163.com

## 0 引言

雷达目标识别是通过对雷达目标电磁散射机理的分析,根据雷达目标的回波信号,提取包含在其中的特征信息,实现对雷达目标类型和属性的识别。在高分辨雷达系统中,高分辨率距离像(HRRP)反映了目标散射中心的散射强度和相对位置沿雷达视线的分布,且易于获取和处理,从而为雷达目标识别提供了一种可行的方法。由于从目标回波数据中提取目标极点受噪声干扰的限制,所以基于 HRRP 的目标识别技术有待进一步研究。

BP 神经网络作为人工神经网络最成熟的模型,具有自学习自组织等优点,适合处理非线性分类问题,所以被应用在对雷达 HRRP 的识别当中<sup>[1]</sup>。但高识别率分类器的前提是首先要有一个能充分表达目标特征的特征提取方法<sup>[2]</sup>。

目前比较常用的特征提取方法是主分量分析法(PCA),此方法算法简单效率高,但不适用于高维非线性结构<sup>[3]</sup>。核主分量分析法(KPCA)与 PCA 方法有相同的数学和统计特性,但因为 KPCA 方法引入核函数把原输入向量映射到一个高维特征空间,所以更适合应用于雷达目标一维距离像数据。但对雷达目标一维距离像来说,若直接通过 KPCA 对雷达回波数据处理只能实现数据特征的降维,并没有考虑 HRRP 本身的特性,如平移敏感性及姿态敏感性。基于此,文中通过对雷达回波数据的分析提取一种平移不变的特征——中心矩,同时采用等间隔非相干平均距离像松弛姿态敏感性,通过 KPCA 方法进行特征降维,再使用遗传算法优化的 BP 神经网络对降维后的数据进行识别,以此获得雷达目标的高识别率<sup>[4]</sup>。

## 1 平移不变的 HRRP 特征提取与降维

### 1.1 特征提取

#### 1.1.1 平移不变性的特征

在雷达目标识别中,雷达距离像具有平移敏感性的特点。所谓平移敏感性指的是因为目标相对雷达的距离不同以及距离窗获取的雷达回波数据中有一定余度的向量,而导致距离像在距离窗中的位置会随距离不同而发生平移<sup>[5]</sup>。

消除距离像平移敏感性的方法有多种。有使用

如滑动最大相关法这种平移配准法,但此种方法的缺点是运算量巨大。还有采用距离像绝对对齐的方法,例如零相位绝对对齐,这种方法计算相对简单,但也随之产生对齐精度较低的缺点。也有采用提取的平移不变特征在特征域直接进行识别,因为其运算量低且易平移不变特征向量融入到分类器中,这种方法也是雷达目标识别中较好的选择。文中提取雷达目标一维距离像中心矩特征作为一种平移不变的特征向量。

设  $x_i(i=1, 2, \dots, n)$  为雷达目标一维距离像,其中  $n$  定义为距离单元数。归一化处理为:

$$\bar{x}_i = \frac{x_i}{\sum_{i=1}^n x_i} \quad (1)$$

式中:  $x_i \in [0, 1]$ 。距离像  $\bar{x}$  的  $p$  阶中心矩定义为:

$$f_j = \sum_{i=1}^n (i - i_0)^j \bar{x}_i \quad (2)$$

其中,  $i_0 = \sum_{i=1}^n i x_i$  为一阶原点矩,即距离像的散射重心。当目标在雷达视线内做平移运动时散射点的位置也随之运动,所以一阶原点矩是与平移有关的。然而目标各散射点与距离像的散射重心之间的位置不变,所以可以以一阶原点矩为参照的高阶中心矩来描述雷达一维高分辨距离像,可以消除平移的影响。由于  $f_1=0$ ,取  $(2-P)$  阶中心矩生成  $(P-1)$  维特征向量:

$$m_1 = [m_{11}, m_{12}, \dots, m_{1(p-1)}]^T \quad (3)$$

显然,特征向量  $f$  包含距离像的形状信息,保留了 HRRP 中雷达目标散射点的特征,并且消除了因目标平移引起的距离敏感问题,因而可以作为 HRRP 识别的模式特征向量<sup>[6]</sup>。

#### 1.1.2 平均距离像松弛姿态敏感性

雷达目标距离像不但有平移敏感性而且还有姿态敏感性。姿态敏感性是指当目标相对于雷达角度变化时,目标上散射点相对于雷达的距离会发生变化,而使 HRRP 对目标姿态变化非常敏感。

通过提取雷达目标距离像中心矩特征可实现距离平移不变性,却无法消除距离像的目标姿态敏感性。所以在提取中心矩特征的同时也要松弛距离像的方位敏感性。研究表明:在散射点不发生越距离徙动的基本视角范围内,对距离像做非相干平均,得到的平均距离像可以获得很好的稳健性。所以文中在

不发生越距离徙动的基本视角范围内均匀划分视角,然后提取每间隔内的平均距离像。平均距离像的定义为:

$$\bar{x} \approx \frac{1}{M} \sum_{i=1}^M |x_i(i)| \approx \sqrt{\sum_{k=1}^K |a_{ik}|^2}, i=1, 2, \dots, n \quad (4)$$

式中:  $n$  为距离单元个数。平均划分的视角范围下  $\bar{x}$  是接班稳定不变的。

## 1.2 核主分量分析

### 1.2.1 方法概述

核主分量分析是通过核函数把原变量空间经过非线性变换映射到高维特征空间,在特征空间内做内积运算然后提取特征值和特征向量达到降维的目的,所以很适于提取数据中的非线性结构解决非线性问题<sup>[6]</sup>。对于 HRRP 这种高维非线性数据, KPCA 的特点可以得到极大的发挥。

### 1.2.2 算法实现

假设训练数据  $x_k(k=1, 2, \dots, l)$  为一组零均值的雷达目标一维距离像,距离像为  $l$  维数据。定义  $\phi: R^n \rightarrow F$  是一非线性映射,对  $x_k$  作非线性变换  $\phi(x_k)$ ,得集合  $A = \{\phi(x_1), \phi(x_2), \dots, \phi(x_l)\}$ 。

高维特征空间样本的协方差矩阵为:

$$\bar{C} = \frac{1}{l} \sum_{j=1}^l \phi(\bar{x}_j) \phi(\bar{x}_j)^T \quad (5)$$

对  $C$  作特征分解可以得到高维特征空间中的主成分:

$$\bar{C}v = \lambda v \quad (6)$$

$\bar{C}$  的特征值非负,定义  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$ ,则对应的特征向量  $V = [v_1, v_2, \dots, v_n]$  在  $F$  空间展开,即满足:

$$v = \sum_{j=1}^l \alpha_j \phi(\bar{x}_j) \quad (7)$$

定义一个内积核函数:  $K_{ij} = k(\bar{x}_i, \bar{x}_j) = \phi^T(\bar{x}_i) \phi(\bar{x}_j)$ ,使其满足 Mereer 核条件。

首先对映射后的数据进行 0 均值处理:

$$\bar{\phi}(\bar{x}_i) = \phi(\bar{x}_i) - \frac{1}{l} \sum_{j=1}^l \phi(\bar{x}_j) \quad (8)$$

代入核函数可以得出其相对应的中心化核矩阵:

$$\bar{K} = \left( I_n - \frac{1}{l} \mathbf{1}_n \right) K \left( I_n - \frac{1}{l} \mathbf{1}_n \right) \quad (9)$$

式中:  $I_n$  和  $\mathbf{1}_n$  分别为  $l$  维的单位矩阵和全 1 矩阵。将

公式(2)等号两边左乘  $\phi(\bar{x}_i)$ ,则可得到:

$$\phi(\bar{x}_i) \bar{C} v = \lambda \phi(\bar{x}_i) v \quad (10)$$

将公式(5)、(7)代入到公式(10)中,得:

$$\bar{K} \alpha = l \lambda \alpha = \lambda' \alpha \quad (11)$$

令  $\lambda_1' \geq \lambda_2' \geq \dots \geq \lambda_p' \geq 0$ ,则对应的特征向量为  $\alpha_1, \alpha_2, \dots, \alpha_p$ ,这是前  $p$  个特征值及相应的特征向量。通过条件  $\lambda' \alpha K^T \alpha_s = \delta_{ks}, \forall k=1, 2, \dots, p$  对  $v$  归一化即可得到  $\bar{C}$  的特征向量  $v_k$ 。而输入样本  $x_i$  在特征空间  $v_k$  中的投影为:

$$y_k = [v_k \cdot \phi(x)] = \sum_{j=1}^l \alpha_j^k [\phi(\bar{x}_j) \cdot \phi(x)] = \sum_{j=1}^l \alpha_j^k k(\bar{x}_j, x) \quad (12)$$

$k=1, 2, \dots, p$

$y_k$  为对应的第  $p$  个主元分量。至此由投影值组成的变量  $y_k(x) = [y_k(x), y_{k+1}(x), \dots, y_m(x)]^T$  就确定为样本的特征变量。

计算  $y_k$  利用核函数避免了点积运算造成的计算量巨大的问题,但不同的核函数效果不同。在雷达目标识别中为了提取距离像的全局特征,提高目标识别率,考虑到高斯核函数是全局核,所以文中采用了高斯核函数:

$$k(x, y) = \exp \left\{ -\frac{\|x - y\|^2}{2\sigma^2} \right\} \quad (13)$$

## 1.3 雷达目标距离像特征提取步骤

(1) 不发生越距离徙动的基本视角范围内均匀划分视角,然后提取每间隔内的平均距离像。

(2) 对 HRRP 进行归一化处理,得到一阶原点矩,然后取  $2-P$  阶中心矩生成  $(P-1)$  维特征向量。

(3) 为了避免同一样本的不同阶次中心距特征由于量纲不同而形成的数值上的差别,要对识别前的数据进行归一化:

$$m_{ij} = m_i / \sqrt{\sum_{i=1}^n m_{ij}^2} \quad (14)$$

(4) 之后再利用核主分量分析对平移不变的平均距离像来降维,去除冗余特征。

## 2 GA 优化的 BP 神经网络分类器

### 2.1 BP 神经网络

BP 神经网络利用输出误差按照梯度下降法来修正各层权值,直至实际输出达到目标设定值<sup>[7]</sup>。整个修正过程分为信息的正向传播和误差的反向传递<sup>[8]</sup>。

在信息的正向传播过程中, 隐含层的输出可以由公式得出:

$$y_i = f(\text{net}_i) = f\left(\sum_{i=1}^{n+1} (\omega_{ij}x_i + \theta_j)\right) \quad (15)$$

式中:  $x_i$  为网络样本输入  $i=1, \dots, n, j=1, \dots, m$ ;  $\omega_{ij}$  为输入层到隐层的连接权值;  $f(t)$  为激活函数;  $n$  为输入层神经元个数。同时可以得出输出层的输出:

$$o_k = f\left(\sum_{k=1}^{m+1} (\omega_{kj}y_i)\right) \quad (16)$$

式中:  $y_i$  为隐层输出;  $w_{ki}$  为隐层到输出层间的权值;  $k$  为输出层神经元个数;  $m$  为输出层神经元个数。

以目标函数的均方误差作为误差值:

$$E = \frac{1}{2} \sum_k (t_k - o_k)^2 \quad (17)$$

以误差  $E$  梯度变化反向不断调整权值, 使实际输出值逐渐收敛于期望值。通过权值的不断修正来实现网络对样本的学习即网络的训练, 直至误差达到目标值或学习次数达到设定值。

### 2.2 GA 优化的 BP 神经网络

BP 神经网络虽使用广泛但也有其缺点: 网络训练速度慢; 通过梯度下降法做权值调整得到的最小值可能是局部最小值。基于此文中采用具有全局搜索能力的 GA 对 BP 神经网络的权重 (权值和阈值) 进行优化, 以提高 BP 神经网络分类器对雷达目标识别的精度。

遗传算法是一种函数最优化的方法, 与其他最优化方法不同的是, 遗传算法是从种群而非单个解开始并行处理多个个体, 所以可以避免出现局部最优的结果; 而且遗传算法根据目标函数计算适应度不需要其他信息引导, 是一种自组织自适应的学习算法, 搜索效率更高<sup>[6]</sup>。

应用遗传算法优化结构确定 BP 神经网络的权值和阈值。首先要对作为遗传算法个体的 BP 网络的连接权值和阈值进行编码, 构建适应度函数进行算法迭代, 直至满足迭代终止条件, 得到优化的神经网络。在此过程中有两个关键问题: 权重编码方式和适应度函数的构造。

(1) 编码方式: 文中采用实数编码。神经网络的各个权值按照一定的顺序级联为一个长串, 串上的每一个位置对应着网络的一个权值<sup>[3]</sup>。

(2) 适应度函数: 文中选择权重各参数的均方误

差作为遗传算法的适应度函数:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (18)$$

式中:  $y_i$  为参数的输出值;  $\bar{y}_i$  为参数的实际值。

遗传算法优化网络权重的具体实现步骤如下:

- (1) 确定权值编码方式。
- (2) 初始化。构建 BP 神经网络; 随机生成权重初值。
- (3) 求出种群中个体的适应度函数值。
- (4) 采用遗传算子对种群进行选择、交叉和变异, 找到最优个体及种群。
- (5) 计算新种群的适应度值, 直至满足结束条件, 否则返回执行步骤(3)。具体流程如图 1 所示。

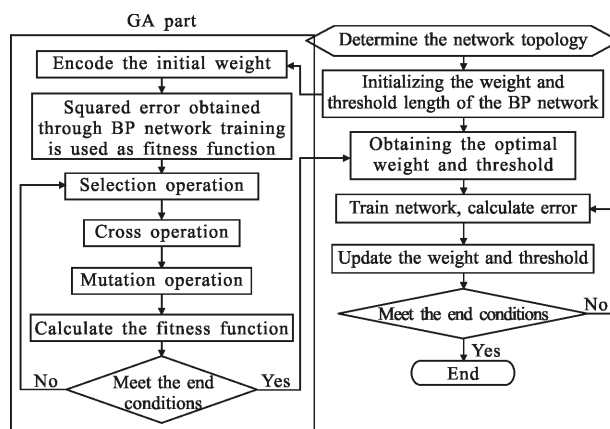


图 1 基于 GA 改进的 BP 神经网络算法流程图

Fig.1 Flow chart of improved BP neural network algorithm based on GA

## 3 实验仿真

### 3.1 实验数据

实验采用三种飞机(安-26、奖状、雅克 42)目标转台实测数据, 雷达发射脉冲的带宽为 400 MHz(距离分辨率为 1 m, 雷达径向取样间隔为 0.5 m)。数据包含了目标相对雷达 180°角域内的回波信息, 实验中将雷达目标回波按方位角度划分每 2°为一间隔, 将此区域内的回波进行非相干平均, 提取平均距离像作为该区域的回波信号<sup>[5]</sup>。

### 3.2 结果及分析

文中设计的分类器是单隐含层的三层网络 BP 神经网络, 在输出层设计以 (100, 010, 001) 分别表示

三类目标,因此输出层的节点数为 3;因为在 KPCA 之后的数据维数为 3,所以隐含层的节点数选择为 7。隐含层神经元传递函数选用 tan-sigmoid 正切函数,而输出层神经元传递函数选用 log-sigmoid 对数函数;学习速率是 0.01,确定期望误差值 0.001。使用遗传算法对其权重(权值和阈值)进行优化后建立 BP 神经网络分类器模型。然后按照特征提取、特征降维、目标分类识别的顺序进行实验。

### 3.2.1 不同姿态角下的识别

高分辨距离像具有姿态敏感性,所以,此实验以均匀划分全方位视角,并在每个间隔提取平均距离像,以此松弛距离像的姿态敏感性。对三类目标进行了识别,结果如表 1 所示。通过数据可以发现:通过均匀划分方位角提取平均距离像很好地松弛了距离像的姿态敏感性。

表 1 三类飞机目标不同姿态角下的识别结果

Tab.1 Recognition results of three kinds of aircraft targets under different attitude angles

Attitude angle/(°)	an-26	Citiaton	Jacques 42	Average recognition rate
0-60	99.6%	99.2%	98.46%	99.1%
60-120	99.4%	98.5%	98.3%	98.7%
120-180	99.7%	98.8%	97.5%	98.7%

### 3.2.2 不同特征提取方法的比较

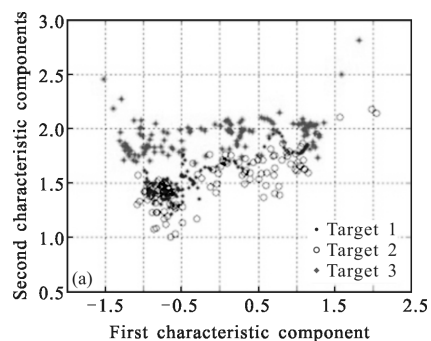
对三类目标依次采用 PCA 特征提取、KPCA 特征提取和中心矩+KPCA 特征提取方法后进行了识别,结果如表 2 所示。由结果可以看出:采用 KPCA 特征提取后进行识别的识别率显然高于 PCA 特征提取识别率;KPCA 特征提取的识别率也显然高于中心矩+KPCA 特征提取的识别率。

表 2 三类飞机目标不同特征提取方法下的识别结果

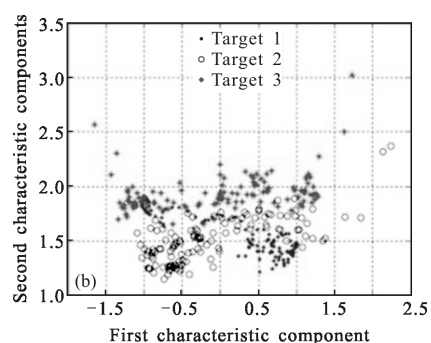
Tab.2 Recognition results of three types of aircraft targets under different feature extraction methods

Extraction method	an-26	Citiaton	Jacques 42	Average recognition rate
PCA	95.77%	93.21%	92.54%	93.84%
KPCA	100%	98.5%	97.5%	98.67%
Center moment+KPCA	98.26%	97.85%	96.8%	97.64%


图 2 为文中涉及的三种特征提取方法进行的仿真实验结果。图 2(a)、(b)是对距离像在不同平移距离 R(R 为雷达与目标的距离)下做 PCA 特征提取的



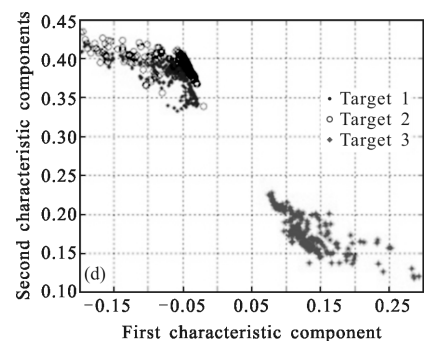
PCA, R=100 km



PCA, R=120 km



KPCA, R=100 km



KPCA, R=120 km

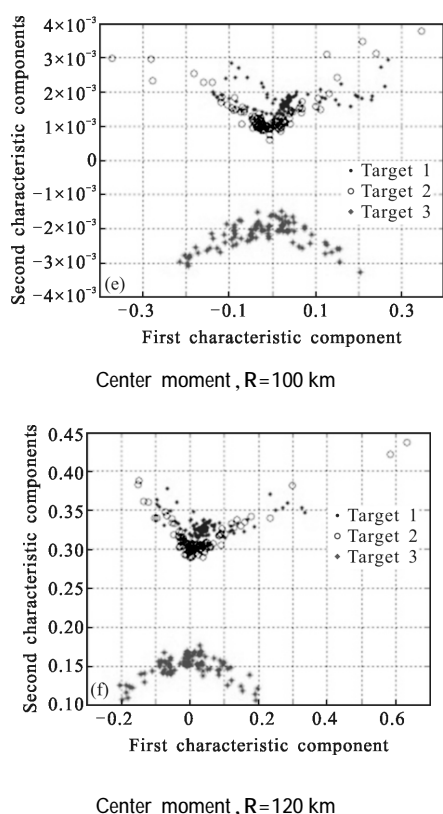


图 2 三类飞机目标不同特征提取方法下的结果

Fig.2 Results of three types of aircraft targets under different feature extraction methods

仿真结果。图 2(c)、(d)是在不同平移距离下做 KPCA 特征提取的仿真结果。对比发现:KPCA 提取的结果明显好于 PCA 的结果。图 2(e)、(f)为在不同平移距离下做中心矩特征提取的仿真结果。从仿真图 2(e)和 2(f)可以发现:三类目标在不同的距离下采用中心矩特征提取的结果相似,这也证明了此方法松弛距离像的平移性的有效性。

分析认为:虽然 KPCA 特征提取有很高的识别率,但它却忽略了 HRRP 的平移敏感性这个特性;而中心矩特征提取利用中心矩的平移不变性很好地解决了这个问题。但中心矩的特征提取方法在提取距离像的平移不变特征过程中,在降低特征维数的同时,也损失了大量信息,以至于距离像的失真程度比传统 KPCA 大,所以识别率低于 KPCA<sup>[6]</sup>。

### 3.2.3 BP 神经网络和 GA-BP 神经网络两种分类器的分类效果比较

图 3 是 BP 神经网络和 GA-BP 神经网络的误差逼近曲线对比结果(标准 BP 网络的迭代次数是 20,GA-BP 神经网络的迭代次数是 5)。由图 3 可

见,GA 优化的 BP 神经网络收敛速度远高于标准 BP 神经网络。GA 优化的 BP 神经网络克服了易陷入局部最小的缺陷,能够越过误差曲面的平坦区,收敛至极小点。

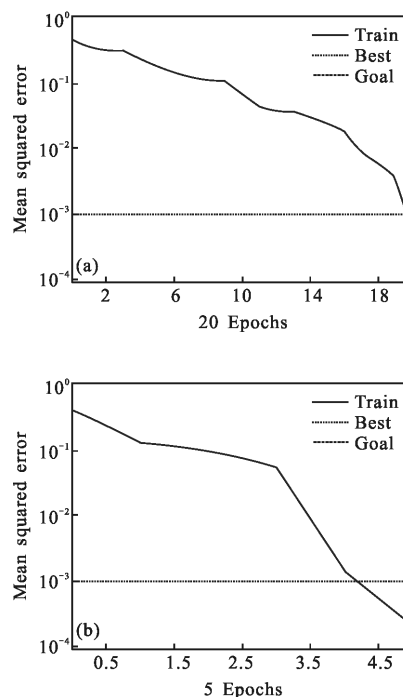


图 3 BP 神经网络和 GA-BP 神经网络的误差逼近曲线

Fig.3 Error approximation curves of BP neural network and GA-BP neural network

表 3 是标准的 BP 神经网络与 GA 优化 BP 神经网络两种算法在识别率和训练时间上的比较。由表 3 可以看出:GA-BP 神经网络对平移不变的 HRRP 的识别,在识别率和训练时间两方面都是优于标准 BP 神经网络的。同时,采用遗传算法对神经网络进行权值和阈值优化求解,得到相应的权值和阈值,从而可以稳定地控制 BP 神经网络结构,实现问题的快速高效求解,并且大大提高算法稳定性。

表 3 标准 BP 神经网络与 GA-BP 神经网络的比较  
Tab.3 Comparison between standard BP neural network and GA optimized BP neural network

Classifier	BP neural network	GA-BP neural network
Recognition rate	93.21%	95.77%
Training time/s	43	43

## 4 结 论

对于雷达 HRRP 的识别,文中提取一种平移不变特征-中心矩作为特征向量,采用等间隔非相干平均距离像松弛姿态敏感性,再通过 KPCA 方法进行特征维数压缩,这种方法既考虑了距离像本身特性又实现了输入数据的降维。同时针对 BP 神经网络分类器易陷入局部最小的问题,采用遗传算法对其进行优化,通过实测数据实验证明,结合中心矩+KPCA 特征提取,优化的 BP 神经网络分类器有较高的识别率和较快的训练时间,对 HRRP 的识别具有较好的实用价值。

### 参考文献:

- [1] Xu Bin, Chen Bohai, Liu Hongwei, et al. Based on the recurrent neural network model, radar high resolution distance image target recognition [J]. *Journal of Electronics and Information*, 2016, 38(12): 2988-2995. (in Chinese)
- [2] Wu Zhanjun, Niu Min, Xu Bing, et al. Research on recognition method based on spectral regression feature reduction and backward propagation neural network [J]. *Journal of Electronic and Information*, 2016, 38 (4): 978-984. (in Chinese)
- [3] Li Haipeng, Li Jingjiao, Yan Aiyun, et al. The parallel realization of genetic neural network in face recognition [J]. *Computer Science*, 2015, 42(6A): 168-174. (in Chinese)
- [4] Yang Xufeng, Lin Wei, Yan Weidong, et al. SAR image target recognition using thermonuclear characteristics [J]. *Infrared and Laser Engineering*, 2014, 43(11): 3794-3801. (in Chinese)
- [5] Li Hui, Jin Baolong, Zhai Haitian. High resolution radar signal translation invariant KPCA feature extraction algorithm [J]. *Computer Simulation*, 2012, 29(1): 9-12. (in Chinese)
- [6] Sun Shaoyuan, Li Linna, Zhao Haitao. Depth estimation of monocular vehicle infrared images using KPCA and BP neural networks [J]. *Infrared and Laser Engineering*, 2013, 42(9): 2348-2352. (in Chinese)
- [7] Yuan Pu, Mao Jianlin, Xiang Fenghong, et al. Improved network fault diagnosis based on genetic optimization BP neural network [J]. *Power System and Automation Journal*, 2017, 29(1): 118-122. (in Chinese)
- [8] Liu Yanju, Kou Guohao, Song Jianhui. Air target recognition technology based on RBF neural network [J]. *Fire and Command Control*, 2015, 40(8): 9-13. (in Chinese)
- [9] Cheng Liang, Zhu Li. Millimeter wave radiometer target recognition based on PCA optimized radial basis function neural network [J]. *Acta Microwave Sinica*, 2015, 10: 225-229. (in Chinese)
- [10] Yang Wenxiu, Fu Wenxing, Zhou Zhiwei, et al. Lidar rapid target recognition based on projection dimension reduction [J]. *Infrared and Laser Engineering*, 2014, 43 (S): 0001-0007. (in Chinese)
- [11] Qin Guohua, Xie Wenbin, Wang Huamin. Tool wear detection and control based on neural network and genetic algorithm [J]. *Optics and Precision Engineering*, 2015, 23(5): 1314-1321. (in Chinese)
- [12] Nie Haitao, Long Kehui, Ma Jun, et al. Fast object recognition under multiple varying background using improved SIFT method [J]. *Optics and Precision Engineering*, 2015, 23(8): 2349-2356. (in Chinese)
- [13] Xiao Yongsheng, Huang Lizhen, Zhou Jianjiang. RATR of adaptive angular-sector segmentation based on grey incidence analysis model [J]. *Grey Systems: Theory and Application*, 2017, 7(1): 71-79.
- [14] Cao Wei, Zhou Hui, Zhou Zhimin, et al. An approach for high resolution radar target recognition based on BP neural network [C]//International Conference on Intelligent Computing, ICIC 2011: Advanced Intelligent Computing, 2011: 33-39.
- [15] Zhou Daiying. Radar target HRRP recognition based on reconstructive and discriminative dictionary learning [J]. *Signal Processing*, 2016, 126(11): 52-64.
- [16] Huang Xiayuan, Nie Xiangli, Hong Weiwua, et al. SAR target configuration recognition based on the biologically inspired model [J]. *Neurocomputing*, 2017, 234(4): 185-191.