

基于优化概率神经网络和红外多光谱融合的大气层外空间弹道目标识别

张国亮^{*①} 杨春玲^① 王瞰来^②

^①(哈尔滨工业大学电气工程及自动化学院 哈尔滨 150001)

^②(中国运载火箭技术研究院 北京 100076)

摘要: 针对大气层外空间弹道目标难识别的问题, 该文利用红外多光谱数据融合的思想, 提出一种基于粒子群优化概率神经网络(PNN)的大气层外空间弹道目标识别方法。该方法首先通过一种新的多色测温方法提取出弹道目标的温度变化率和有效辐射面积两类动态特征, 然后利用高斯粒子群优化(GPSO)方法对 PNN 的平滑因子进行优化, 最后利用优化的 PNN 完成 4 类典型空间目标的识别。该方法融合了多光谱信息并提取出了多个动态特征, 具有较强的鲁棒性。另外, 该方法充分利用了概率神经网络的较高的稳定性和样本容错能力。仿真实验给出了 4 类典型空间弹道目标的多光谱红外辐射强度序列数据, 并进行了目标识别研究。仿真测试结果表明, 提出的优化 PNN 网络对多个弹道目标具有良好的识别能力。

关键词: 目标识别; 弹道目标; 多光谱红外数据融合; 粒子群优化; 概率神经网络

中图分类号: TP391.4; TN219

文献标识码: A

文章编号: 1009-5896(2014)04-0896-07

DOI: 10.3724/SP.J.1146.2013.00623

Discrimination of Exo-atmospheric Targets Based on Optimization of Probabilistic Neural Network and IR Multispectral Fusion

Zhang Guo-liang^① Yang Chun-ling^① Wang Jian-lai^②

^①(School of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin 150001, China)

^②(China Academy of Launch Vehicle Technology, Beijing 100076, China)

Abstract: A Probabilistic Neural Network (PNN) based on Particle Swarm Optimization (PSO) is proposed for ballistic target recognition due to its difficulty in this paper. The fusion of multispectral infrared data is achieved through the use of this method. Firstly, the temperature and emissivity-area of targets are extracted by using a novel multi-colorimetric technology, then the parameter of the PNN is optimized with Gaussian PSO (GPSO), and finally the four typical ballistic targets are classified via the optimized PNN. The method fuses the multi-spectral and multiple dynamic features, hence allowing this algorithm to be quite robust. In addition, the method fully exploits the PNN's capability for its higher stability and fault-tolerance mechanism. The simulation experiments present multi-spectral infrared radiation intensity sequence of four ballistic targets, and the results show that the proposed method based on the PNN is able to recognize the multiple ballistic targets.

Key words: Target recognition; Ballistic target; Multi-spectral infrared data fusion; Particle Swarm Optimization (PSO); Probabilistic Neural Network (PNN)

1 引言

在自动目标识别 (Automatic Target Recognition, ATR) 研究领域, 大气层外空间弹道目标的自动识别是一个挑战性的难题^[1]。这主要是因为空间弹道目标的自动识别具有如下难点: (1) 弹道目标存在多样性, 包括弹头, 导弹碎片以及诱饵(可能又包含重诱饵和轻诱饵)等; (2) 弹道目标的辐射特性

表现出动态时变性; (3) 远距离探测时, 获取目标的信息量非常有限。这些难点反应在实际应用中主要就是如何提取用于目标识别的有效特征以及如何设计有效的目标分类算法。针对空间目标识别的这些问题, 很多学者进行了此方面的研究^[2-4]。文献[2-4]中的方法主要是利用雷达的时频域量测特征进行的目标识别, 其中主要包括目标的雷达散射截面积 (Radar Cross Section, RCS), 目标的运动轨迹, 以及目标的多普勒特征等。但当有多个真假目标同时在中段飞行时, 弹头并不存在区别其它诱饵的固有频率, 而且弹头和诱饵的轨迹相近^[5], 这给弹道目标

2013-05-06 收到, 2013-12-02 改回

国家自然科学基金(61378046)和航空科学基金(20120177006)资助课题

*通信作者: 张国亮 zglhit@hit.edu.cn

的识别造成很大困难。光谱信息是由物体内在的物理性质决定的, 所以通过分析物体光谱信息, 可以获得其它方法不能获得的目标固有属性。因此目标的光谱差异信息可以作为识别目标的一种重要手段。另外, 由于神经网络良好的并行性和自学习能力, 近年来被广泛用于空间弹道目标识别。文献[6]设计了三波段的空间弹道目标识别算法, 采用反向传播(Back Propagation, BP)神经网络对空间弹道目标进行了识别。文献[7]利用双波段红外辐射特性提出了一种时延回归神经网络(Time-Delay Recurrent Neural Network, TDRNN)用于空间弹道目标识别。文献[8]利用目标的红外特性提出一种时延神经网络(Time-Delay Neural Network, TDNN)弹道目标识别方法。文献[9]提出了一种自适应时延神经网络(Adaptive Time-Delay Neural Network, ATNN)识别大气层外弹道目标。通过分析可知, TDNN 在空间目标识别中较为常用, 如 ATNN 和 TDRNN 就是 TDNN 的变种。但 TDNN 本质上和 BP 极为相似, 属于 BP 神经网络的“增强版”^[8]。BP 类神经网络的学习和记忆具有不稳定性, 即如果增加学习样本, 训练好的网络需要从头重新训练, 对以前网络的权值和阈值没有记忆, 且易陷入局部极小值。另外上述神经网络学习算法复杂度较高, 这可能会限制它们在实际中的应用。

概率神经网络(Probabilistic Neural Network, PNN)近年来已在不同模式识别领域得到应用^[10,11], 因为 PNN 具有学习过程简单, 收敛于贝叶斯最优解等优点。另外, 近年来多光谱红外数据在 ATR 领域表现出极大的潜力, 主要是它们可同时提供目标的时域特征和光谱特征。因此利用多光谱数据融合目标的时谱特性可能会进一步提高目标识别性能。本文就是从多光谱数据融合的优势出发, 通过对大气层外空间弹道目标的多光谱红外辐射序列的仿真和实验研究, 提出一种基于粒子群优化 PNN 的空间弹道目标识别方法。该方法通过融合弹道目标的多光谱红外辐射数据, 提高了目标识别的稳健性, 利用提出的多比色测温方法提高了动态特征提取的精确度。文中首先介绍了 PNN 模型及其学习算法。其次采用粒子群优化方法对 PNN 进行优化。然后提出一种基于比色测温的多色测温方法对空间弹道目标的动态特征进行提取。最后利用仿真实验数据对 4 类典型空间弹道目标进行了识别研究。

2 概率神经网络模型

PNN 是由径向基神经网络发展而来的一种前馈型神经网络, 最早由 Specht^[12]提出。其基本原理

为假设有 d 维输入特征向量 $\mathbf{x} = [x_1, x_2, \dots, x_d]^T$, 它属于 c 个分类 $\omega_1, \omega_2, \dots, \omega_c$ 之一。 $P(\omega_i)$ 和 $p(\mathbf{x} | \omega_i)$ 分别为类 ω_i 的先验概率和类条件概率密度函数(似然函数)。贝叶斯决策理论通过最小化总风险做出相应决策, 如果正确分类损失为 0, 错误分类损失为 1, 即损失函数为 0-1 函数, 其判决规则为

$$a(\mathbf{x}) = \arg \max_{\omega_i} p(\mathbf{x} | \omega_i) P(\omega_i), \quad i = 1, 2, \dots, c \quad (1)$$

其中 $a(\mathbf{x})$ 为决策, 该判决规则同时最小化平均错误概率。Parzen 窗非参概率密度函数估计方法可用于类条件概率密度函数 $p(\mathbf{x} | \omega_i)$ 的估计。相比传统的 Parzen 窗方法, Cacoullos 采用多元高斯核函数作为窗函数^[12], 即 $p(\mathbf{x} | \omega_i)$ 的 Parzen 窗估计可以表示为

$$p(\mathbf{x} | \omega_i) = \frac{1}{N_i (2\pi)^{d/2} \sigma^d} \sum_{j=1}^{N_i} \exp \left[-\frac{(\mathbf{x} - \mathbf{x}_i^j)^T (\mathbf{x} - \mathbf{x}_i^j)}{2\sigma^2} \right] \quad (2)$$

式(2)的 N_i 是类 ω_i 的训练样本个数, \mathbf{x}_i^j 为类 ω_i 的第 j 个训练样本, σ 为平滑因子。

PNN 模型包括输入层、模式层、求和层和输出层 4 部分。输入层神经元个数与特征矢量 \mathbf{x} 的维数相等, 该层负责接收测试集的样本并将该样本的特征矢量传递给网络。模式层含有 c 组神经元(每组神经元对应一个模式类), 每组神经元的个数与训练集该类别的样本数相同, 该层负责计算特征矢量 \mathbf{x} 与训练集各个样本的匹配关系, 因而每个神经元都与输入层完全连接, 第 i 组第 j 个神经元的输出为

$$\varphi_{ij}(\mathbf{x}; \sigma) = \frac{1}{(2\pi)^{d/2} \sigma^d} \exp \left[-\frac{(\mathbf{x} - \mathbf{x}_i^j)^T (\mathbf{x} - \mathbf{x}_i^j)}{2\sigma^2} \right] \quad (3)$$

其中 $i = 1, 2, \dots, c, j = 1, 2, \dots, N_i, \mathbf{x}_i^j$ 是类 ω_i 的第 j 个训练样本, 同时也是该神经元的权值向量。求和层含有 c 个神经元(每个神经元对应一个模式类), 每个神经元只与属于自己类别的模式层神经元相连, 将模式层所有该类神经元的输出累积后取均值, 得到

$$f_i(\mathbf{x}; \sigma) = \frac{1}{N_i} \sum_{j=1}^{N_i} \varphi_{ij}(\mathbf{x}; \sigma) \quad (4)$$

由式(4)可知, 求和层各神经元的输出与类条件概率密度函数的 Parzen 窗估计相等。输出层含有 c 个神经元(每个神经元对应一个模式类), 该层负责接收求和层输出的各类别条件概率密度函数, 每个神经元的输出为

$$O_i = P(\omega_i) \times f_i(\mathbf{x}; \sigma) \quad (5)$$

式(5)中的 $P(\omega_i)$ 是第 i 类的先验概率。针对未知类别的输入特征矢量 \mathbf{x} , 如果对于所有的 $j \neq i (i, j \in \{1, 2, \dots, c\})$, 存在

$$O_i > O_j \quad (6)$$

则将特征矢量 \mathbf{x} 判为 ω_i 类。

需要指出的是,在仿真实验中平滑因子 σ 对 PNN 的性能有一定的影响。平滑因子较小时会造成网络的过拟合,易受噪声干扰。虽 σ 越大时逼近函数越平滑,但 σ 过大会造成模式层的神经元个数过多,进而增加计算量。因此应用 PNN 的关键是如何选取合适的 σ 值。

3 高斯粒子群优化 PNN

粒子群优化算法(Particle Swarm Optimization, PSO)是一种基于种群智能方法的演化计算技术^[13]。PSO 具有收敛速度快、算法简单等优点,而且它不要求被优化函数具有可导、可微等性质。由于经典的 PSO 算法严重依赖加速度常数和惯性权值的设置,本文拟采用一种高斯粒子群优化(Gaussian PSO, GPSO)^[14]方法对 PNN 的 σ 值进行优化。

设粒子群数目为 N ,第 n 个粒子在 D 维空间中的位置和速度分别为 $\beta_n = [\beta_{n1}, \beta_{n2}, \dots, \beta_{nD}]^T$ 和 $\mathbf{v}_n = [v_{n1}, v_{n2}, \dots, v_{nD}]^T$ 。 $\mathbf{p}_n = [p_{n1}, p_{n2}, \dots, p_{nD}]^T$ 代表粒子 n 的历史最好位置(最好拟合值的位置), $\mathbf{p}_g = [p_{g1}, p_{g2}, \dots, p_{gD}]^T$ 是第 n 个粒子所在邻域的历史最佳位置(通常将邻域选为整个种群,即全局模型)。粒子速度迭代方程为

$$\mathbf{v}_n^k = |\text{rand}|(\mathbf{p}_n^k - \beta_n^k) + |\text{Rand}|(\mathbf{p}_g^k - \beta_n^k) \quad (7)$$

其中 k 为种群代数(或迭代次数)。 $|\text{rand}|$ 和 $|\text{Rand}|$ 是正随机数,可由高斯概率密度的绝对值产生,即 $\text{abs}[N(0,1)]$,其中 $N(0,1)$ 表示零均值、单位方差的标准正态分布。

粒子的位置更新方程为

$$\beta_n^{k+1} = \beta_n^k + \mathbf{v}_n^k \quad (8)$$

式(8)中粒子速度和位置都是随机矢量。式(7)和式(8)显示 GPSO 只需要用户设置粒子数 N ,不需要别的参数。

本文计算每一个网络在训练集上产生的均方误差,并以此作为目标函数。通过目标函数构造相应的适应度函数,用来计算每个粒子的适应度。目标函数为

$$E(\beta_n) = \frac{1}{2m} \sum_{j=1}^m \sum_{i=0}^c (O_i^j(\mathbf{x}_j; \beta_n) - t_i^j)^2 \quad (9)$$

其中 m 是训练样本总数, c 是模式输出类数, $O_i^j(\mathbf{x}_j; \beta_n)$ 是第 j 个训练样本 \mathbf{x}_j 在第 i 模式端的实际输出, t_i^j 是训练样本 \mathbf{x}_j 在第 i 模式端的给定输出。因此由目标函数可定义适应度函数为

$$F(\beta_n) = \frac{1}{1 + E(\beta_n)} \quad (10)$$

综上所述,本文提出的高斯粒子群优化 PNN

(GPSO-PNN)算法流程如下:(1)训练集中的样本都归一化为单位长度,即 $\sum_1^d x_i^2 = 1$;(2)将 PNN 的目标函数设置为 GPSO 的目标函数,进而求得适应度函数,即式(10);(3)将 PNN 中的待优化参数写为 GPSO 的粒子位置;(4)初始化 GPSO 中的主要参数,限定粒子的搜索空间,并确定算法的终止条件;(5)利用归一化训练样本训练每个 PNN。运行 GPSO 算法,按式(7)和式(8)更新,直到满足终止条件;(6)如果终止条件不满足,返回到第(4)步;(7)返回粒子群全局最优值 \mathbf{p}_g 作为平滑因子的最优值,并利用此值进行实验得到最终识别结果。

4 大气层外空间弹道目标的动态特征提取

通过大量的仿真实验研究,我们决定将温度变化率和有效辐射面积变化范围作为空间目标识别的有效特征。当前空间目标的温度测量通常采用比色测温法^[15]。假设绝对温度为 T 的空间目标在红外探测系统处产生的辐照度为

$$E(\lambda_i, T) = \frac{\tau_a(\lambda_i) A_p}{\pi R^2} \int_{\lambda_i}^{\lambda_i + \Delta\lambda_i} \varepsilon(\lambda, T) M_b(\lambda, T) d\lambda \approx \frac{\tau_a(\lambda_i) A_p}{\pi R^2} \varepsilon(\lambda_i, T) M_b(\lambda_i, T) \Delta\lambda_i \quad (11)$$

其中 $\tau_a(\lambda_i)$ 是大气光谱透过率; $\varepsilon(\lambda_i, T)$ 为目标光谱发射率; R 是目标到探测系统的距离; A_p 是目标对探测方向的投影面积; $M_b(\lambda_i, T)$ 为光谱辐射出射度,它通常由普朗克黑体辐射定律给出

$$M_b(\lambda, T) = c_1 (e^{c_2/\lambda T} - 1)^{-1} / \lambda^5 \quad (12)$$

式(12)中 c_1 和 c_2 是辐射常数。当 $\exp(c_2/\lambda T) \gg 1$ 时,式(12)可以近似表示为

$$M_b^W(\lambda, T) = c_1 e^{-c_2/\lambda T} / \lambda^5 \quad (13)$$

式(13)又称为维恩辐射定律。对于比色测温,结合式(11)和式(13),在假设 $\tau_a(\lambda_i) = \tau_a(\lambda_j)$, $\Delta\lambda_i = \Delta\lambda_j$ 的情况下,双波段比色测温法可表示为

$$\frac{E(\lambda_i, T)}{E(\lambda_j, T)} = \frac{\varepsilon(\lambda_i, T) M_b^W(\lambda_i, T)}{\varepsilon(\lambda_j, T) M_b^W(\lambda_j, T)} = \frac{\varepsilon(\lambda_i, T) \lambda_j^5 e^{c_2/\lambda_j T}}{\varepsilon(\lambda_j, T) \lambda_i^5 e^{c_2/\lambda_i T}} \quad (14)$$

整理式(14)后得到

$$\frac{1}{T} = \left[\ln \frac{E(\lambda_i, T)}{E(\lambda_j, T)} - 5 \ln \frac{\lambda_j}{\lambda_i} - \ln \frac{\varepsilon(\lambda_i, T)}{\varepsilon(\lambda_j, T)} \right] / \left[\frac{c_2}{\lambda_j} - \frac{c_2}{\lambda_i} \right] \quad (15)$$

通常假设空间目标为灰体,即有 $\varepsilon(\lambda_i, T) = \varepsilon(\lambda_j, T)$ 。则目标的比色温度 $T_C(\lambda_i, \lambda_j)$ 可以表示为

$$\frac{1}{T_C(\lambda_i, \lambda_j)} = \left[\ln \frac{E(\lambda_i, T)}{E(\lambda_j, T)} - 5 \ln \frac{\lambda_j}{\lambda_i} \right] / \left[\frac{c_2}{\lambda_j} - \frac{c_2}{\lambda_i} \right] \quad (16)$$

利用比色测温估计空间目标温度,其精确度不

仅取决于信噪比的大小，还取决于目标温度的波动范围以及目标发射率在所测量波段的变化差异。目标发射率的大小与波长、温度及其表面状态有关，即使相当小的波段变化也可能造成发射率的较大波动。由于比色测温法无法从根本上消除目标发射率在不同测量波段变化所引起的误差，本文提出了一种基于比色测温的多色测温方法，通过对目标发射率比的自然对数进行建模，从而进一步提高其温度测量的精确度。具体来说，通过联合式(15)和式(16)可以得到

$$\ln \frac{\varepsilon(\lambda_i, T)}{\varepsilon(\lambda_j, T)} - c_2 \left(\frac{1}{\lambda_i} - \frac{1}{\lambda_j} \right) \frac{1}{T} = -c_2 \left(\frac{1}{\lambda_i} - \frac{1}{\lambda_j} \right) \frac{1}{T_C(\lambda_i, \lambda_j)} \quad (17)$$

在传统的多光谱辐射测温方法中，发射率通常用一个含有未知参数的关于波长的平滑函数来描述。为此，本文将式(17)中发射率比的自然对数用

$$\begin{aligned} \Phi &= \begin{bmatrix} (\lambda_1 - \lambda_2) & \cdots & (\lambda_1 - \lambda_2)^{L-2} & -c_2(1/\lambda_1 - 1/\lambda_2) \\ \vdots & \ddots & \vdots & \vdots \\ (\lambda_{L-1} - \lambda_L) & \cdots & (\lambda_{L-1} - \lambda_L)^{L-2} & -c_2(1/\lambda_{L-1} - 1/\lambda_L) \end{bmatrix} \\ \theta &= [a_1 \quad \cdots \quad a_{L-2} \quad 1/T]^T \\ \mathbf{b} &= -c_2 [(1/\lambda_1 - 1/\lambda_2)/T_C(\lambda_1, \lambda_2) \quad \cdots \quad (1/\lambda_{L-1} - 1/\lambda_L)/T_C(\lambda_{L-1}, \lambda_L)]^T \end{aligned} \quad (20)$$

误差函数一般用误差平方和来表示，即

$$\text{Err} = \|\Phi\theta - \mathbf{b}\|_2 \quad (21)$$

其中 $\|\cdot\|_2$ 表示 2 范数。由此得到的解为非一致方程组的最小二乘解，其数学表达式为

$$\theta_{\text{LS}} = (\Phi^T \Phi)^{-1} \Phi^T \mathbf{b} \quad (22)$$

通过减小未知目标发射率的不确定性，上述方法能够进一步提高温度测量的精确度。一旦获取了空间目标的绝对温度，利用空间目标测轨所提供的距离信息，还可以得到另一个识别特征量——目标的有效辐射面积 $\varepsilon(\lambda_i, T)A_p$ ，由式(11)可得

$$\varepsilon(\lambda_i, T)A_p = \frac{\pi R^2 E(\lambda_i, T)}{\tau_a(\lambda_i) M_b(\lambda_i, T) \Delta \lambda_i} \quad (23)$$

5 仿真实验数据及目标识别结果

红外探测器接收到的目标信号强度受诸多因素的影响(如目标动力学特性，表面温度，有效辐射面积，目标距探测器距离等)，因此很难精确描述目标的红外辐射强度。目标信号时间序列的仿真只能依托于某些特定模型，其中较为常用的是 BODE (Bhattacharyya Optical Decoy Evaluation) 模型。利用简化后的二阶 BODE 模型，则 t 时刻目标在第 l

一个关于波长的多项式函数来描述，即

$$\ln \frac{\varepsilon(\lambda_i, T)}{\varepsilon(\lambda_j, T)} = \sum_{l=0}^{L-2} a_l (\lambda_i - \lambda_j)^l \quad (18)$$

当 $\lambda_i \rightarrow \lambda_j$ 时， $\lim \ln[\varepsilon(\lambda_i, T)/\varepsilon(\lambda_j, T)] = 0$ ，因此易知 $a_0 = 0$ 。将式(18)代入式(17)，可以得到

$$a_1(\lambda_i - \lambda_j) + \cdots + a_{L-2}(\lambda_i - \lambda_j)^{L-2} - c_2 \left(\frac{1}{\lambda_i} - \frac{1}{\lambda_j} \right) \frac{1}{T} = -c_2 \left(\frac{1}{\lambda_i} - \frac{1}{\lambda_j} \right) \frac{1}{T_C(\lambda_i, \lambda_j)} \quad (19)$$

针对 L 个探测波段，存在 $L(L-1)/2$ 个辐射率比，从而能够得到 $L(L-1)/2$ 个形如式(19)的方程构成方程组。这里视系数 a_l 和目标的绝对温度 T 为未知变量，共 $L-1$ 个。当 $L > 2$ 时，由于方程组所含方程个数大于其未知变量个数，从而方程组为超定非一致的。这种方程组通常不存在严格意义上的解，只能求得近似解。通常希望寻找一个使其误差函数为最小的解。为便于描述问题，定义

个波段的相对光谱辐照度 $a_l(t)$ 可以表示为

$$a_l(t) = A_l + B_l t + C_l t^2 + S_l \sin(\omega t + \phi) \quad (24)$$

其中 A_l, B_l 和 C_l 分别代表目标相对光谱辐照度在该波段随时间零次项，一次项和二次项的变化程度； S_l, ω 和 ϕ 分别为正弦调制项的幅值，角速度和初相角，以上 3 个参数用于描述空间目标的进动运动对目标相对光谱辐照度造成的影响，因此对某一特定目标而言， ω 和 ϕ 在各个波段的值是相同的。 $n_i(t)$ 认为是均值为 0 的加性噪声。第 i 波段的信噪比(单波段信噪比)SNR 定义为正弦调制项幅值 S_l 与噪声方差的比值。

$$\text{SNR} = S_l^2 / E[n_i^2(t)] \quad (25)$$

根据 BODE 模型和表 1 中的参数，4 种典型空间目标某波段的相对光谱辐照度随时间的变化曲线如图 1 所示，这里的单波段信噪比 $\text{SNR}=1$ 。本文采用 12 个光谱波段数据做测试，这些波段均匀地分布在 $4 \sim 15 \mu\text{m}$ 。

根据上述仿真实验数据，利用本文提出的多比色测温法可以很容易地提取出该目标的动态温度。图 2 比较了两种不同测温法提取出的目标温度与目标原始温度的差异，其中前者为传统的双色测温法，

后者为本文提出的多比色测温法。观察图 2 可以发现，相比传统的双色测温法，多比色测温法的测量误差更小。因此多比色测温方法进一步提高了温度测量的准确性。

为衡量两个时变特征对弹头、重诱饵、导弹碎片以及气球诱饵 4 种典型空间目标的识别能力，我们给出了上述 4 种目标针对每个特征的概率密度函数，如图 3(a)和图 3(b)所示。这里把目标特征随时间的变化曲线视为该目标特征的概率密度函数，从

而可以利用其差异达到识别目标的目的。观察上述两图可以发现，以上 4 种空间目标的概率密度函数差异明显，因此利用上述两个时变特征可有效对目标进行区分。由于重诱饵和弹头在形状上相似，本文将详细阐述利用上述特征识别弹头和重诱饵的有效性。尽管重诱饵初始释放温度跟弹头相近或者相同，但重诱饵的温度变化率大于弹头，也就是说重诱饵的温度相比弹头下降要快。另外，重诱饵不可能做到和弹头一模一样，且往往由于实际条件的限

表 1 空间目标的基本物理参数

目标类型	弹头	重诱饵	导弹碎片	气球诱饵 I	气球诱饵 II
释放时的温度(K)	700	700	600	300	300
表面涂层材料	铝	铝	铝	铝	聚酯薄膜
形状	圆锥体	圆锥体	圆柱体	球体	球体
比热(J/(g·K))	0.904	0.904	0.904	0.904	1.15
密度(g/m ³)	2.7×10 ⁶	2.7×10 ⁶	2.7×10 ⁶	2.7×10 ⁶	1.39×10 ⁶
吸收率	0.192	0.192	0.192	0.192	0.17
发射率	0.036	0.036	0.036	0.036	0.5




图 1 利用 BODE 模型生成的目标相对光谱辐照度(SNR=1)






图 2 原始温度与预测温度的比较



(a)温度的概率密度函数



(b)有效辐射面积的概率密度函数

图 3 4 种典型空间目标特征的概率密度函数

制其尺寸和重量比弹头小的多，因此重诱饵的有效辐射面积变化范围通常是小于弹头的。因此利用上述特征可对弹头和重诱饵有效区分。

训练数据集共有 400 个样本数据，其中弹头、重诱饵、导弹碎片和气球诱饵各 100 个。将提取出的目标时变温度和时变有效辐射面积以 0.5 s 的时间间隔进行采样，共持续 5 s，即每个动态特征均有 11 个样本点用于构建其概率密度函数，将 22 维的特征矢量送入 GPSO-PNN 神经网络进行训练，具体训练过程参见本文第 3 节。由于本文使用了 GPSO 技术对 PNN 优化，不需要反复手动调节 PNN 的平滑因子。

本文比较了不同单波段信噪比条件下采用 GPSO-PNN 神经网络和 BP 神经网络进行目标识别的结果，如表 2 所示。其中 W, HD, F 和 BD 分别代表弹头、重诱饵、导弹碎片和气球诱饵，其余参数设置同前。表 2 的识别结果证明本文提出的方法对 4 类典型空间目标是有效的。另外观察表 2 可以

发现，在低信噪比条件下，与传统 BP 神经网络相比，GPSO-PNN 神经网络能够获得更好的分类识别性能。

6 结论

本文提出了一种基于优化概率神经网络和多光谱红外数据融合的方法用于大气层外空间弹道目标的识别。该方法充分融合了多光谱红外数据的时间信息和光谱信息，在此基础上提出了一种基于比色测温的多色测温方法用于提取目标的动态特征，提高了温度测量的精确度，进而提高了目标识别的准确率。利用 PNN 训练得到各模式类的后验概率，优于传统的硬性判决。针对 PNN 中的平滑因子选取问题，本文采用 GPSO 优化方法进行了优化，避免了手动操作。利用仿真实验数据进行了测试，并比较了不同单波段信噪比条件下的平均识别成功率。仿真结果显示在低信噪比条件下，本文算法的识别性能优于传统的 BP 神经网络。

表 2 GPSO-PNN 和 BP 两类识别方法的结果比较

目标类型	单波段信噪比(dB)											
	1				2				3			
	W	HD	F	BD	W	HD	F	BD	W	HD	F	BD
GPSO-PNN 平均成功率(%)	73.5	71.3	70.1	69.2	87.8	85.7	84.1	84.5	98.9	98.3	98.1	98.6
BP 平均成功率(%)	63.8	61.7	60.5	62.5	72.2	70.4	70.8	73.8	89.5	88.4	86.6	88.3

参考文献

- [1] 高乾, 周林, 王森, 等. 弹道导弹中段目标特性及识别综述[J]. 装备指挥技术学院学报, 2011, 22(1): 78-82.
Gao Qian, Zhou Lin, Wang Sen, et al. Summarize of target characteristics and recognition of ballistic missile in trajectory midcourse[J]. *Journal of the Academy of Equipment Command & Technology*, 2011, 22(1): 78-82.
- [2] 范成礼, 邢清华, 付强, 等. 基于直觉模糊核聚类的弹道中段目标识别方法[J]. 系统工程与电子技术, 2013, 35(7): 1362-1367.
Fan Cheng-li, Xing Qing-hua, Fu Qiang, et al. Technique for target recognition in ballistic midcourse based on intuitionistic fuzzy kernel clustering[J]. *Systems Engineering and Electronics*, 2013, 35(7): 1362-1367.
- [3] 寇鹏, 刘永祥, 朱得糠, 等. 基于轨迹特性的中段目标识别方法[J]. 宇航学报, 2012, 33(1): 91-99.
Kou Peng, Liu Yong-xiang, Zhu De-kang, et al. Discrimination strategy for midcourse target based on trajectory characteristics[J]. *Journal of Astronautics*, 2012, 33(1): 91-99.
- [4] 田巳睿, 蒋跃红, 郭汝江, 等. 基于时频变换的弹道目标微多普勒特征提取[J]. 现代雷达, 2012, 34(1): 40-43, 48.
Tian Si-rui, Jiang Yue-hong, Guo Ru-jiang, et al. Ballistic target micro-doppler feature extraction method based on the time-frequency analysis[J]. *Modern Radar*, 2012, 34(1): 40-43, 48.
- [5] 武春风, 张伟, 李洁, 等. 基于时空信息的红外成像系统在探测识别目标时所面临的问题及分析[J]. 光学技术, 2005, 31(2): 231-234.
Wu Chun-feng, Zhang Wei, Li Jie, et al. Problems and its analysis of infrared imaging detection and identification facing[J]. *Optical Technique*, 2005, 31(2): 231-234.
- [6] Haberstroh R and Kadar I. Multispectral data fusion using neural networks[C]. Conference on Signal Processing, Sensor Fusion, and Target Recognition, Orlando, USA, 1993: 65-75.
- [7] 刘涛, 吕江北, 王书宏, 等. 基于 TDRNN 的大气层外弹道式空间红外目标识别[J]. 电子与信息学报, 2010, 32(1): 80-85.
Liu Tao, Lü Jiang-bei, Wang Shu-hong, et al. Exo-atmospheric discrimination of infrared ballistic space target

- based on the time-delay recurrent neural network[J]. *Journal of Electronics & Information Technology*, 2010, 32(1): 80-85.
- [8] Resch C. Exo-atmospheric discrimination of thrust termination debris and missile segments[J]. *Johns Hopkins APL Technical Digest*, 1998, 19(3): 315-321.
- [9] Lin D T. Target components discrimination using adaptive time-delay neural network[J]. *Journal of Information Science and Engineering*, 2004, 20(5): 959-980.
- [10] 李新德, 杨伟东, Dezert Jean. 一种飞机图像目标多特征信息融合识别方法[J]. *自动化学报*, 2012, 38(8): 1298-1307.
Li Xin-de, Yang Wei-dong, and Dezert Jean. An airplane image target's multi-feature fusion recognition method[J]. *Acta Automatica Sinica*, 2012, 38(8): 1298-1307.
- [11] 高志华, 贲可荣, 章林柯. 一种基于直推置信的遗传优化概率神经网络[J]. *南京大学学报(自然科学)*, 2012, 48(1): 48-54.
Gao Zhi-hua, Ben Ke-rong, and Zhang Lin-ke. An optimized probabilistic neural network based on transductive confidence[J]. *Journal of Nanjing University (Natural Sciences)*, 2012, 48(1): 48-54.
- [12] Specht D F. Probabilistic neural networks[J]. *Neural Networks*, 1990, 3(1): 109-118.
- [13] Kennedy J and Eberhart R. Particle swarm optimization[C]. *Proceedings of the IEEE International Conference on Neural Networks*, Piscataway, USA, 1995, 4: 1942-1948.
- [14] Krohling R A. Gaussian swarm: a novel particle swarm optimization algorithm[C]. *Proceedings of the IEEE Conference on Cybernetics and Intelligent Systems*, Singapore, 2004: 372-376.
- [15] 李云红, 王瑞华, 李禹萱. 双波段比色测温技术及实验测试[J]. *激光与红外*, 2013, 43(1): 71-75.
Li Yun-hong, Wang Rui-hua, and Li Yu-xuan. Dual waveband colorimetric temperature measurement technology and experiment[J]. *Laser & Infrared*, 2013, 43(1): 71-75.
- 张国亮: 男, 1986年生, 博士生, 研究方向为雷达信号与红外图像处理、目标检测与模式识别等.
- 杨春玲: 女, 1965年生, 教授, 研究方向为红外系统仿真、精确制导与目标识别.
- 王瞰来: 男, 1982年生, 博士, 研究方向为信号检测与估计、遥感图像处理等.