

一种雷达 HRRP 在线自适应目标识别方法*

陈 凤 侯庆禹 刘宏伟 保 铮

西安电子科技大学雷达信号处理重点实验室, 西安 710071

摘要 “边录取、边学习、边建模”是一维高分辨距离像(HRRP)雷达自动目标识别(RATR)工程化的一条路径, 宽带雷达对飞行中的机动目标录取的 HRRP 随着目标相对于雷达的姿态而变化, 完备(全姿态)的 HRRP 数据库可以看做是关于姿态(主要是方位)的非平稳过程, 常用的平稳环境下的在线算法对非平稳的环境适应能力有限. 文中通过一种在线混合专家(OME)将 HRRP 数据在线地分割成若干个近似平稳的区域, 在各个区域内使用平稳协方差函数的在线 Gauss 过程分类器(OGPC). 针对迭代在线 Gauss 过程分类(IOGPC)的参数学习算法 EP 和 EM, 提出了一种双链 Gauss 过程(Bi-OGP)来使 OGPC 的参数得以在单次数据扫描的情况下实现在线更新. 针对迭代在线混合专家网络参数的学习算法 EM, 提出了基于初值选择的单次数据扫描学习方法. 基于 HRRP 实测数据的仿真试验证明, 文中方法在单次扫描数据时就获得了高于或接近最近邻、迭代在线线性最小均方(LMS)混合专家和 OGPC 的识别率.

关键词 雷达自动目标识别(RATR) 高分辨距离像(HRRP) 在线算法 Gauss 过程分类器(GPC) 混合专家(ME)

多种雷达回波信号可用来实现对目标的自动识别, 如, 一维 HRRP、二维的合成孔径雷达(SAR)或逆合成孔径雷达(ISAR)图像等, 其中 HRRP 不需要在方位上积累就能够快速获取, 维数相对较低, 易于工程实现, 因而长期以来基于 HRRP 的目标识别是雷达 ATR 研究的一个热点^[1-3]. 然而, 基于 HRRP 的 ATR 工程化首先需要面对的问题之一就是模板库建立问题. 目前文献上的仿真实验一般是对几类(或型号)或十几类(或型号)目标的完备数据库采用成批识别算法离线训练分类器^[1-3], 而获取完备的数据库条件之一是能够获取待识别目标的电磁散射特性, 由于我国在高效、高精度目标电磁散射特性计算方面的研究进展还不能满足对雷达 ATR 工程化的需要, 故在过渡阶段, “边录取、边学习、边建模”是逐步获得完备数据库的一种方法, 即在雷达运行过程中基于实测数据来完善识别库. 由于雷达对目标的一次跟踪只能获得目标部分

姿态下的数据, 研究基于非完备训练数据集的在线自适应学习算法更具有实际意义. 另一方面, 实际上待识别的目标的种类和型号很多, 有些目标的部分姿态已经加入数据库, 有些目标还未包含在数据库中, 处理的数据量会远远大于仿真试验情况, 而雷达识别系统的内存是有限的, 成批识别算法假设数据集中已包含所有姿态下的 HRRP 样本, 同时处理所有数据对内存消耗很大, 而在线迭代方法算法假设数据集中的数据是一个接一个输入, 每次迭代在已有结果上只处理单个样本, 因而, 在线算法是缓解雷达识别系统内存损耗的有效方法. 本文正是针对上述问题提出了一种基于 Gauss 过程分类器^[4,5]和混合专家^[6,7]的稀疏在线自适应雷达 HRRP 分类方法.

GPC 是一种功能强大的非参数 Bayes 概率核方法^[4-5,8-11]. 假设存在隐空间, 在 Bayes 框架下, 一个样本属于某一类的概率随着其所对应的隐函数

2009-05-21 收稿, 2009-08-16 收修改稿

* “教育部长江学者和创新团队支持计划”(批准号: IRT0645)、国家自然科学基金(批准号: 60772140)和国防预研基金联合资助

E-mail: chenfeng6120@163.com

的值单调增加, 各个样本对应的隐变量符合 Gauss 过程先验概率(也就是多元 Gauss 分布), 利用数据来推断其后验概率并学习其参数(似然参数、核参数), 换言之, 一些非线性问题可以通过 Bayes 原理利用相对简单的代数公式就实现模型选择、密度估计等. Gauss 过程的协方差函数决定着隐空间, 当协方差函数只是关于两样本差的函数时称为平稳的协方差函数. 为了增加协方差的灵活性, 一方面可以开发非平稳的协方差函数, 另一方面可以通过 ME 的形式让每一个 Gauss 过程作用于样本空间的一个局部区域^[11], 类如文献[8—10].

开发适应雷达 HRRP 特点的在线自适应算法是本文的关键任务. 根据目标的散射点模型, 雷达目标的高分辨复距离像是宽带信号获取的目标散射点后向子回波在雷达射线上的投影的向量和, 它包含目标特定姿态下精细的结构信息, 也即姿态变化后 HRRP 随之变化(通常称做姿态敏感性)^[1-3], 故而, 全姿态的 HRRP 信号是一个关于目标姿态的非平稳的过程. 研究表明^[3], 飞机类目标的方位角敏感性远强于俯仰向和横滚向的敏感性, 在较小的方位角域($3^\circ-5^\circ$)散射点模型基本保持不变, 进而可以近似为平稳环境. Csato^[4]等在 2002 年提出了一种 Gauss 过程分类器的迭代在线算法, 该方法使用的是平稳的协方差函数, 在全姿态的 HRRP 数据试验中发现其描述能力有限, 尤其是当 HRRP 按照姿态连续变化的顺序单次输入时识别结果未能满足工程要求. 本文利用混合专家在线地将全姿态的 HRRP 数据分割成几个部分, 各个部分分别使用 Gauss 过程在线地分类, 从而实现了雷达一边录取数据一边分帧建立模板库. 随着目标种类、型号的增加, HRRP 样本数目急剧增大, 若加入一个新样本在现有分类器下直接学习新的分类器, 而并不回溯所有已有样本, 对于快速的更新系统是有利的, 开发一种单次扫描数据的在线 HRRP 学习算法是本文的目标.

1 迭代在线 Gauss 过程^[4]

Gauss 分类器假设样本集对应一个隐空间(也称作核空间), 设该空间变量的先验分布为 Gauss 过程, 并给出似然函数(也就是隐变量条件下的类别标号的条件概率), 通过 Bayes 公式推导和计算待

测样本属于各个类别的概率值, 从而实现分类的目的. 具体地, 设有数据对 (x_i, y_i) , 其中 x_i 是样本点, $y_i \in \{+1, -1\}$ 是 x_i 对应的类别标号. 假设存在一个与 x_i 相对应的隐变量 $f_i = f(x_i)$, 并设似然函数 $p(y_i | f_i)$ 为^[4]

$$p(y_i | f_i) = \text{erf}(y_i f_i / \sigma_0) \quad (1)$$

式中 σ_0 是待定参数, $\text{erf}(\cdot)$ 是误差函数, $\text{erf}(u) = \frac{2}{\sqrt{\pi}} \int_0^u e^{-t^2} dt$. 实际上, 可作为似然函数的函数形式有

多种, 例如 $\text{erf}(y_i f_i / \sigma_0)$, $\frac{1}{1 + \exp(-y_i f_i)}$, $H(y_i f_i)$, $\epsilon + (1 - 2\epsilon)H(y_i f_i)$ 等, 式中 $H(z) = 1$, 当且仅当 $z > 0$ 时, ϵ 是待定参数. 这里选用(1)式使似然函数随 f_i 单调递增, 也就是使 f_i 的值与样本类别标号正相关, 同时采用(1)式也使后续计算较简单. 设样本 $x_1, x_2, \dots, x_N$ 对应的隐变量为 $f_1, f_2, \dots, f_N$, 进而假设 $\mathbf{f} = [f_1, f_2, \dots, f_N]$ 的先验概率是 Gauss 过程, 服从多元 Gauss 分布, 通常 $\mathbf{f}$ 的均值函数设为零向量, 协方差函数设为^[4]

$$K_{ij} = k(x_i, x_j) = \theta_0 \exp \left\{ -\frac{1}{2} \sum_{m=1}^N l_m (x_i^m - x_j^m)^2 \right\} \cdot \left(1 + \sum_{m=1}^N l_m (x_i^m - x_j^m)^2 \right)^{\theta_1} \quad (2)$$

其中, x_i^m 表示样本 x_i 的第 m 维, θ_0, θ_1, l_m 是待定参数. 利用 Bayes 公式推导可得未知的新的来样本 x 的预测概率如下^[4]

$$p(y | x) = \text{erf}(y \langle f_x \rangle / \sigma_x) \quad (3)$$

其中, f_x 是 x 对应的隐变量, $\langle \cdot \rangle$ 表示求期望, $\sigma_x^2 = \sigma_0^2 + \mathbf{k}_x^* + \mathbf{k}_x^T \mathbf{C} \mathbf{k}_x$, $\mathbf{k}_x = [K_0(x_1, x), \dots, K_0(x_t, x)]^T$, $\mathbf{k}_x^* = K_0(x, x)$, $\mathbf{C}$ 是待定参数, K_0 是初始时刻协方差函数. 以上建立了 Gauss 过程模型, 可以通过最大似然函数、最大后验概率或最大 Bayes 全概率准则来学习待定参数.

为实现在线学习过程, 下面介绍一种迭代 Gauss 过程模型^[4]. 在 Bayes 在线学习框架下, 设在初始状态 $\mathbf{f}$ 的概率密度函数为 $p(\mathbf{f}) = p(\mathbf{f}_0 | D_0) = GP(0, K_0)$, D_0 表示初始状态的样本集合 $\{x_1, x_2, \dots$

$x_{N_0}\}$, N_0 是初始状态的样本数目, $f_0 = [f_1, f_2, \dots, f_{N_0}]$, $GP(0, K_0)$ 表示均值为 0 向量, 协方差函数为 K_0 的 N_0 元 Gauss 分布. 用 D_t 表示 t 时刻样本集和, 反复利用如下增量 Bayes 公式

$$p(f_t | D_t) = \frac{p(y_t | x_t, f_t) p(f_{t-1} | D_{t-1})}{\int p(y_t | x_t, f_t) p(f_{t-1} | D_{t-1}) df_t} \quad (4)$$

可以获得 t 时刻 $f_t = [f_1, f_2, \dots, f_{N_t}]$ 的后验概率 $p(f_t | D_t)$, 再利用 Bayes 公式得到测试样本的条件概率如下^[4]

$$p(y | x) = \frac{p(y | f_t) p(f_t | D_t)}{\int p(y | f_t) p(f_t | D_t) df_t} \quad (5)$$

将 $p(f_t | D_t)$ 用均值和协方差表示, 加入一个新样本 x_{t+1} 后, Gauss 过程的均值向量和协方差函数有如下递推关系^[4]

$$\langle f_x \rangle_{t+1} = \langle f_x \rangle_t + q^{(t+1)} K_t(x, x_{t+1}) \quad (6)$$

$$K_{t+1}(x, x') = K_t(x, x') + r^{(t+1)} K_t(x, x_{t+1}) K_t(x_{t+1}, x') \quad (7)$$

其中, $q^{(t+1)} = \frac{\partial}{\partial \langle f_{t+1} \rangle_t} \ln \langle P(y_{t+1} | f_{t+1}) \rangle_t$, $r^{(t+1)} = \frac{\partial^2}{\partial \langle f_{t+1} \rangle_t^2} \ln \langle P(y_{t+1} | f_{t+1}) \rangle_t$, $\langle \cdot \rangle_t$ 表示在 t 时刻求期望, K_t 是 t 时刻的协方差函数. 将 (6) 式的递推公式展开, 可得 t 时刻的均值, 协方差用初始的协方差函数和似然函数表示^[4]

$$\langle f_x \rangle_t = \sum_{i=1}^t K_0(x, x_i) \alpha_i(i) = \alpha_i^T k_x \quad (8)$$

$$K_t(x, x') = K_0(x, x') + \sum_{i,j=1}^t K_0(x, x_i) C_t(ij) K_0(x_j, x') = K_0(x, x') + k_x^T C_t k_{x'} \quad (9)$$

其中 $k_x = [K_0(x_1, x), \dots, K_0(x_t, x)]^T$, $\alpha_i = [\alpha_i(1), \dots, \alpha_i(t)]^T$, $C_t = \{C_t(ij)\}_{i,j=1,t}$, α_i 和 C_t 是需要学习的参数. 利用 (6), (7), (8), (9) 式, 可推导得到计算 α_i 和 C_t 的递推公式如下^[4]:

$$\begin{aligned} \alpha_t &= [\alpha_t(1), \dots, \alpha_t(t)]^T \\ \alpha_{t+1} &= T_{t+1}(\alpha_t) + q^{(t+1)} s_{t+1} \\ C_{t+1} &= U_{t+1}(C_t) + r^{(t+1)} s_{t+1} s_{t+1}^T \\ s_{t+1} &= T_{t+1}(C_t k_{t+1}) + e_{t+1} \end{aligned} \quad (10)$$

其中 $k_{t+1} = k_{x_{t+1}}$, e_{t+1} 是第 $t+1$ 各元素为 1 其他为 0 的 $t+1$ 维向量, T_{t+1} 在向量末尾添零, U_{t+1} 在矩阵的末行和末列添 0.

现在为止, 在线 Gauss 过程的模型已经给出. 但是, 由于 (5) 式中分母中的积分通常不能够解析表达出来, 以及协方差矩阵的元素是以样本数目二次方增加, 这些对参数学习增加了困难, 也大大限制了 GPC 的应用. 文献 [4] 通过 EP 算法迭代学习归一化因子 $\int p(Y | f_t) p(f_t | D_t) df_t$, 用 EM 算法迭代估计参数 θ_0, θ_1, l_m 和 σ_0 , 并在 KL 距离准则下寻找最能代表原样本的基向量集合以实现稀疏化. 这里不详细叙述 EM 和 EP 算法以及稀疏化的迭代在线 Gauss 过程算法, 具体算法参见文献 [4]. 但是, 需要指出的是 EM 和 EP 算法都是通过多次对全部数据的迭代来不断提高估计精度的, 因而, 不断回溯已有的大量数据是制约它在雷达 HRRP 自动目标识别的条件之一. 为了便于与本文的单次扫描数据算法比较, 我们把扫描数据的次数为 1 的迭代 Gauss 过程称为在线 Gauss 过程.

2 基于在线 Gauss 过程分类器的在线混合专家分类器

2.1 混合专家模型

由于上述迭代在线 Gauss 过程使用的是平稳的协方差函数, 在全姿态的 HRRP 数据试验中发现其描述能力有限, 尤其是当 HRRP 按照姿态连续变化的顺序单次输入时识别结果未能满足工程要求. 针对雷达 HRRP 数据的特点, 我们希望通过混合专家将方位连续变化的 HRRP 数据划分为几个近似平稳的过程. 文献 [6] 提出了一种混合专家模型, 并给出了 EM 参数学习方法: 设包含 M 个专家的门网络函数是 $g_j(x, m_j, \sum_j) = \alpha_j p(x | m_j, \sum_j) / \sum_{j=1}^M \alpha_j p(x | m_j, \sum_j)$, 其中 $\sum_{j=1}^M \alpha_j = 1, \alpha_j \geq 0, j = 1, 2, \dots, M, p(x | m_j, \sum_j) = (2\pi |\sum_j|)^{-1/2}$

$\exp\{-1/2 \cdot (x - m_j)^T \sum_j^{-1} (x - m_j)\}$. 设第 j 个专家的参数集为 Ω_j , 则似然函数可表示如下^[6]

$$p(y|x, \Theta) = \sum_{j=1}^M g_j p(y|x, \Omega_j) = \sum_{j=1}^M \alpha_j p(x|m_j, \sum_j) p(y|x, \Omega_j) / \sum_{j=1}^M \alpha_j p(x|m_j, \sum_j)$$

其中, $\Theta = \{m_j, \sum_j, \Omega_j | j = 1, 2, \dots, M\}$. 通过 EM 算法最大化 $p(y, x) = \sum_{j=1}^M \alpha_j p(x|m_j, \sum_j) p(y|x, \Omega_j)$ 从而实现参数学习, 具体分为 E 步骤和 M 步骤^[6]:
 E 步骤: 依次计算

$$h_j^{(k)}(y^{(t)} | x^{(t)}) = \alpha_j p(x|m_j, \sum_j) p(y|x, \Omega_j) / \sum_{j=1}^M \alpha_j p(x|m_j, \sum_j) p(y|x, \Omega_j) \quad (11)$$

$$Q^e = \sum_t \sum_{j=1}^M h_j^{(k)}(y^{(t)} | x^{(t)}) \ln \alpha_j, \quad \alpha = \{\alpha_1, \alpha_2, \dots, \alpha_M\} \quad (12)$$

$$Q_j^e(m_j, \sum_j) = \sum_{j=1}^M h_j^{(k)}(y^{(t)} | x^{(t)}) \ln p_j(x^{(t)}, m_j, \sum_j), \quad j = 1, \dots, M \quad (13)$$

$$Q_j^e(\Omega_j) = \sum_t h_j^{(k)}(y^{(t)} | x^{(t)}) \ln P_j(y^{(t)} | x^{(t)}, \Omega_j), \quad j = 1, \dots, M \quad (14)$$

M 步骤: 得到参数如下

$$\alpha_j^{(k+1)} = \sum_t h_j^{(k)}(y^{(t)} | x^{(t)}) / N \quad (15)$$

$$m_j^{(k+1)} = \sum_t h_j^{(k)}(y^{(t)} | x^{(t)}) x^{(t)} / \sum_t h_j^{(k)}(y^{(t)} | x^{(t)}) \quad (16)$$

$$\sum_j^{(k+1)} = \sum_t h_j^{(k)}(y^{(t)} | x^{(t)}) (x^{(t)} - m_j^{(k)}) / (x^{(t)} - m_j^{(k)})^T / \sum_t h_j^{(k)}(y^{(t)} | x^{(t)}) \quad (17)$$

$$\Omega_j^{(k+1)} = \arg \max_{\Omega_j} Q_j^e(\Omega_j) \quad (18)$$

根据 $\gamma = \sum_{k=1}^t h^k \gamma(x^t) / \sum_{k=1}^t h^k$ 可以近似改写成迭代形式^[7] $\gamma^{t+1} = \gamma + \lambda^{t+1} [\gamma(x^{t+1}) - \gamma]$, $\lambda^{t+1} = h^{t+1} / \sum_{k=1}^{t+1} h^k$, $D^{t+1} = (1 - 1/L)D^t + h^{t+1}$. (15)–(17) 式可写成如下形式^[7]

$$\alpha_j^{t+1} = \alpha_j^t + (1/L)[h_j^t - \alpha_j^t] \quad (19)$$

$$m_j^{t+1} = m_j^t + \lambda_j^{t+1}[x^t - m_j^t] \quad (20)$$

$$\sum_j^{t+1} = \sum_j^t + \lambda_j^{t+1} [(x^t - m_j^t)(x^t - m_j^t)^T - \sum_j^t] \quad (21)$$

利用(19)–(21)式反复迭代数据直至收敛, 从而实现了混合专家迭代参数学习.

2.2 双链 Gauss 过程

E 步的(14)式和 M 步的(18)式提供了将在线 Gauss 过程作为“专家”带入混合专家的方法, 即直接将 Gauss 过程学习所得的条件概率作为 $P_j(y^{(t)} | x^{(t)}, \Omega_j)$, 相应地在 M 部最大化 $\sum_j h_j^{(k)}(y^{(t)} | x^{(t)}) \ln P_j(y^{(t)} | x^{(t)}, \Omega_j)$, $j = 1, \dots, M$, 即需要在线最大化对数似然函数的加权和, 也就是说我们要在 t 时刻参数集 $\Theta = \{m_j, \sum_j, \Omega_j | j = 1, 2, \dots, M\}$ 下计算前 $t-1$ 个时刻的 $h_j^{(k)}(y^{(t)} | x^{(t)})$, 和 $\ln P_j(y^{(t)} | x^{(t)}, \Omega_j)$, $j = 1, \dots, M, t = 1, \dots, t-1$, 显然这与我们期望的单次扫描、不存储已有数据是矛盾的.

本文采用一种较为简单的解决办法就是使 h_j 只取 γ 或 0 两个值之一, 也就是

$$h_j = \begin{cases} \gamma & h_j > \frac{1}{M} \sum_{j=1}^M h_j \\ 0 & \text{其他} \end{cases} \quad (22)$$

为满足 $\sum_{j=1}^M h_j = l\gamma = 1$, $\gamma = \frac{1}{l}$. 代入(14), (18)式, 进一步简化为最大化第 j 个 Gauss 过程的条件概率, 即 $\max_{\Omega_j} \sum_t h_j^{(k)} \ln P_j(y^{(t)} | x^{(t)}, \Omega_j) = \max_{\Omega_j} 1/l \cdot \sum_s \ln P_j(y_j^{(s)} | x_j^{(s)}, \Omega_j)$, $j = 1, \dots, M$, 其中 $(y_j^{(s)}, x_j^{(s)})$ 指第 j 个分类器的第 s 个样本. 我们知道 $h_j(x, y)$ 表征样本 (x, y) 属于第 j 个分类器的后验概率, 因而可以根据 $h_j > 0$ 决定将样本加入第 j 个 OGP, 否则不加入第 j 个 OGP. 可见, 同一个样本可能被加入几个 OGP, 虽然各个 OGP 的样本空间是可能有交叠的, 但是加入各个分类器的样本是确定已知的, 因而, 现有在线 Gauss 过程的 EM, EP 参数学习法可以直接应用到参数学习中.

为了将非平稳的 HRRP 数据划分成近似平稳的几个区域, 我们希望专家个数从 1 逐渐在线的增

加。具体地,在已有 m 个专家的系统中加入某一样本 x' , 当 $\min_j [(x' - m'_j)^T \sum_j^{-1} (x' - m'_j)] > \delta$ 时, δ 是根据经验设定的门限值, 增加一个 $m_{m+1} = E(x_t)$, $\alpha_{m+1} = 0.5 \cdot \min(\alpha_i)$, $i=1, 2, \dots, m$, $\sum_{m+1} = E(x_t^2) - [E(x_t)]^2$ 的专家, 其中 $E(x_t)$, $E(x_t^2)$ 用 x_t 周围 K 个近邻来估计, 并且为了满足 $\sum_j \alpha_j = 1$, $\alpha_j \geq 0$, 令 $\min(\alpha_i) = \alpha_{m+1}$, $i=1, 2, \dots, m$.

EM 和 EP 是通过多次迭代来收敛的, IOGP 参数学习时利用 EP 计算条件概率、利用 EM 优化参数, 在线混合专家利用 EM 学习参数. 为了实现数据的一次迭代就能获得较好性能, 我们设计了一种双链 Gauss 过程: 原数据集作为样本的在线 Gauss 过程称为母 Gauss 过程, 主要用来获得基向量集合; 基向量集作为样本的在线 Gauss 过程称为核心 Gauss 过程. 如图 1 所示, 在 t 时刻雷达接收到一个新样本 x_{new} , 利用 (22) 式判别样本加入的专家序号 j , 在 $t-1$ 时刻的第 j 个母 Gauss 过程分类器中加入新样本, 按照 IOGP 类似准则决定新样本是否加入基向量集合中, 得到 t 时刻第 j 个基向量集合, 然后将这个基向量集作为全部样本利用迭代在线 Gauss 过程训练核心 Gauss 过程并学习参数. 这样, 核心 Gauss 的参数得到了更新, 而 EM

和 EP 只是对定量的基向量进行迭代. 对于混合专家门网络参数学习中的 EM, 我通过给定好的初值使其单次扫过数据接近收敛. 对于雷达 HRRP 这也是容易实现的, 由于相邻样本间的相关性很强, 只需记录 x_{new} 前 $K-1$ 个样本来估计均值、方差作为新专家门函数的参数, 对系统只增加微小的存储量和计算量, 如上段所述新增 OGP 的方法.

3 实测数据仿真试验

实验所用的数据是 ISAR 雷达实测飞机数据, 该雷达中心频率约为 5.5 GHz, 波长约为 0.05 m, 采用线性调频信号形式, 信号带宽为 400 MHz, 脉冲宽度为 25.6 μs , 采用 Dechirp 接收, 对 Dechirp 后的信号采样频率为 10 MHz, 距离分辨率为 0.375 m. 实验用的飞机有三种: “安-26” 是中小型螺旋桨飞机; “奖状” 是小型喷气式飞机; “雅克-42” 是中大型喷气式飞机. 三类飞机的平面航迹如图 2.

为了克服 HRRP 的幅度敏感性和平移敏感性, 我们采用幅度归一化的功率谱像作为特征向量, 同时为降低计算负担, 用 PCA 将 128 维的功率谱像降低至 16 维. 其中, “雅克-42” 等方位间隔抽取 1075 个方位连续变化的样本, “奖状” 和 “安-26” 各 1280 个方位连续变化的样本.




图 1 基于在线 Gauss 过程分类器的在线混合专家分类器 (双链 Gauss 过程)




图2 三类飞机的平面航迹

对于分类“奖状”和“安-26”飞机，按顺序输入“奖状”飞机的第1—320个样本，然后输入“安-26”的第1—320个样本，接着输入“奖状”的第321—640个样本，以此类推，直至所有样本都输入分类器。如图3(a)是识别率随着样本数目的变化曲线，其中ME+LMS方法是文献[7]中用线性分类器的迭代混合专家，由于单次扫描数据的结果受初始权值的影响很大，图中给出的是多次扫描数据收敛的较好结果，单次OGP指的是单次扫描数据时在线Gauss过程分类器的试验结果，观测可见，随着样本数增加，我们的算法ME+OGP识别率大概趋势是增加的，当所有样本都输入后ME+OGP获得了四种方法中的最高识别率，大约高出其他方法3个百分点。图3(b)是(a)图中ME+LMS的学习曲线，重复10次试验，最终结果是平均值。观测可见，在数据迭代大概195次之后大多数试验的学习曲线才平缓不再起伏，为保证收敛，我们必须至少重复扫描过数据 $195 \times 10 = 1950$ 次，所以，加入新样本后更新的负担很大。图3(c)对比了几种方

法的“专家数目”，其中，“在线Gauss过程”的专家指的是就是其本身，ME+LMS使用了90个专家，最近邻法分成100个角域识别，ME+OGP只需要48个专家，由于雷达自动识别目标的时间与专家个数是线性关系，因而ME+OGP识别速度较快。

通过图4，和图5，可得类似结论。总之，与最近邻相比，ME+OGP获得了更高的识别率，所用“专家”数目也远远小于最近邻的方位角域数目；与单扫描在线Gauss过程相比，ME+OGP获得了远高于其的识别率；与ME+LMS相比，ME+OGP获得了较高或接近的识别率，但是在线更新的计算负担却没有ME+LMS大。需要说明的是，图4(a)，(c)中，ME+OGP的识别率略低于ME+LMS，这是由于ME+LMS实际是一种对数据迭代1950次的成批算法，与本文算法应用环境不同。本文着重比较对数据单次扫描的算法最近邻和单次OGP，由图4知道，对于三种单次扫描算法，本文方法从识别概率最高、专家个数也比最近邻少。




图3 “奖状”和“安-26”在线识别结果以及与其他3种方法的性能比较

(a) 四种方法识别率随时间的变化曲线；(b) ME+LMS的学习曲线；(c) 四种方法的“专家”个数比较




图4 “雅克”和“安-26”在线识别结果以及与其他3种方法的性能比较

(a) 四种方法识别率随时间的变化曲线；(b) ME+LMS的学习曲线；(c) 四种方法的“专家”个数比较




图5 “雅克”和“奖状”在线识别结果以及与其他三种方法的性能比较

(a) 四种方法识别率随时间的变化曲线；(b) ME+LMS的学习曲线；(c) 四种方法的“专家”个数比较

我们知道雷达在驻留时间内有可能获得几十个HRRP, 序列HRRP包含了更多目标信息, 有利于目标的正确识别, 由于ME+OGP的判别函数有概率含义, 在Bayes框架下, 假设各个HRRP间是独立的, 很容易将上述专家模型推广到序列距离像的识别。图6(a), (b), (c)分别给出三组数据的二分类器识别率随序列距离像的长度的变化曲线, 可

见, 识别率进一步大幅度提高, 当HRRP序列长度大于8时雅克和奖状飞机就可100%在线分辨开来。

最后, 实际雷达目标识别中, 目标的数目远远不只是两类, 我们以实测数据的三类目标为例, 通过一对多(OAA)的方式来实现多类目标在线分类, 当样本全部输入后获得了86.65%的在线识别率, 相比最近邻方法提高5.13%。




图6 ME+OGP的随识别率随测试序列HRRP长度的变化曲线

(a) “奖状”和“安-26”；(b) “雅克”和“安-26”；(c) “雅克”和“奖状”

4 结论

本文基于 GPC 和 ME 开发了一种适应雷达 HRRP 在线识别的新算法, 利用 ME 在线的划分方位帧, 通过 Bi-OGP 在线更新专家参数. 基于实测数据的仿真试验证明本文方法获得了与最近邻、文献[7]方法和 OGP 相比较好或接近的识别性能, 包括正确识别率和在线识别速度; 进一步试验证明本文方法易推广到多类识别和序列距离像识别, 可进一步提高识别性能.

参 考 文 献

- 1 杜 兰. 雷达高分辨距离像目标识别方法研究. 博士论文. 西安电子科技大学, 西安, 2007
- 2 Chen B, Liu HW, Chai J, et al. Large margin feature weighting via linear programming. *IEEE Tran. on Knowledge and Data Engineering*, 2009, 279(12): 2620—2626
- 3 陈 凤, 杜 兰, 保 铮, 等. 雷达高分辨距离像自动目标识别方法的改进. *电子与信息学报*, 2007, 29(6): 1450—1454
- 4 Csato L. Gaussian processes-iterative sparse approximations. Ph D thesis. Aston University, 2002
- 5 Kim HC, Ghahramani Z. Bayesian Gaussian process classification with the EM-EP algorithm. *IEEE Trans on PAMI*, 2006, 28(12): 1948—1959
- 6 Xu L, Jordan MI, Hinton G E. An alternative model for mixtures of experts. In: *Advances in Neural Information Processing Systems 7*. MIT press, 1995
- 7 Ramamurti V, Ghosh J. Structurally adaptive modular networks for nonstationary environments. *IEEE Tran on Neural Networks*, 1999, 10(1): 152; 160
- 8 Tresp V. Mixture of Gaussian processes. In: *Advances in Neural Information Processing Systems 13*. MIT press, 2001
- 9 Rasmussen CE, Ghahramani Z. Infinite mixtures of Gaussian process experts. In: *Advances in Neural Information Processing Systems 14*. MIT press, 2002
- 10 Meeds E, Osindero S. An alternative infinite mixture Of Gaussian process experts. In: *Advances in Neural Information Processing Systems 13*. MIT press, 2001
- 11 Rasmussen CE, Williams C. *Gaussian Process for Machine Learning*. MIT Press, 2006