

## 基于类决策树分类的特征层融合识别算法

尚朝轩<sup>1</sup>, 王品<sup>1</sup>, 韩壮志<sup>1</sup>, 彭刚<sup>2</sup>

(1. 军械工程学院 电子与光学工程系, 石家庄 050003; 2. 中国人民解放军 77618 部队, 拉萨 850000)

**摘要:** 针对雷达组网量测数据不确定性大、信息不完备等特点, 基于决策树分类算法的思想, 创建类决策树的概念, 提出一种基于类决策树分类的特征层融合识别算法。所给出的算法无需训练样本, 采用边构造边分类的方式, 选取信息增益最大的属性作为分类属性对量测数据进行分类, 实现了对目标的识别。该算法能够处理含有空缺值的量测数据, 充分利用量测数据的特征信息。仿真实验结果表明, 类决策树分类算法是一种简单有效的特征层融合识别算法。

**关键词:** 决策树; 特征层融合; 目标识别; 分类; 类决策树

中图分类号: TP391

文献标志码: A

### Feature-level fusion recognition algorithm based on analogy decision tree classification

SHANG Chao-xuan<sup>1</sup>, WANG Pin<sup>1</sup>, HAN Zhuang-zhi<sup>1</sup>, PENG Gang<sup>2</sup>

(1. Department of Electronic and Optical Engineering, Ordnance Engineering College, Shijiazhuang 050003, China; 2. The 77618 Unit of PLA, Lasa 850000, China. Correspondent: WANG Pin, E-mail: wangpin17@163.com)

**Abstract:** Considering the big uncertainty and incomplete information of radar network measurement data, the concept of analogy decision tree is created and a feature-level fusion recognition algorithm based on decision tree analogy is proposed. The proposed algorithm uses a way of while constructing while classifying without training samples. The greatest information gain property feature is selected as the classification feature to classify the measurement data, which achieves the goal of recognizing the target. The algorithm can deal with the measurement data containing vacancies and makes full use of measurement data. Simulation results show that the analogy decision tree classification algorithm is a simple and effective feature-level fusion recognition algorithm.

**Keywords:** decision tree; feature-level fusion; target recognition; classification; analogy decision tree

### 0 引言

现代战场环境日益复杂, 在各种干扰存在的情况下, 雷达回波得到的目标量测信息不确定性大, 很难满足作战系统目标识别的需求。基于雷达组网的目标融合识别有助于增强系统的抗干扰能力和环境适应能力<sup>[1-2]</sup>, 提高目标识别的可信度及准确性, 能够为作战指挥辅助决策提供重要依据。

目标融合识别是利用不同传感器得到的关于目标属性的数据形成一个融合后的目标身份属性判别<sup>[3]</sup>的过程。根据信息的抽象层次, 目标融合识别可分为数据层融合、特征层融合和决策层融合<sup>[4-5]</sup>。数据层融合直接融合来自多个传感器的原始观测信息, 在

融合的数据中进行特征提取并进行分类, 从而得到目标的类别, 具有较高的信息利用率。但是, 数据层融合处理的信息量大, 抗干扰能力差, 且其仅对产生同类观测的传感器是适用的; 决策层融合是较高层次的融合。因高层次融合的信息量小, 且实现难度相对较小<sup>[6]</sup>, 所以目前目标识别大都采用此方法。但是, 决策层融合损失了大量的特征信息, 在量测数据受到干扰时识别可信度降低; 而特征层融合属于中间层次, 既保留了足够数量的重要信息, 又实现了客观的信息压缩。在现代战争中, 为掩盖军事行动的目的, 敌方会采取欺骗、遮盖等干扰手段, 从而使雷达得到的量测数据往往不确定性很大, 甚至是不完备的。针对雷达组

收稿日期: 2015-05-21; 修回日期: 2015-09-16。

作者简介: 尚朝轩(1964—), 男, 教授, 博士生导师, 从事电子装备性能检测与故障诊断、雷达信号处理等研究; 王品(1991—), 女, 硕士生, 从事雷达信号处理、模式识别的研究。

网量测数据的这些特点, 本文创建了类决策树的概念, 提出一种类决策树分类方法, 在特征层对目标进行融合识别, 提高了识别结果的可信度。

## 1 决策树分类

特征层融合实质上是分类问题. 分类即按照样本的不同特征, 依据一定的分类准则判断未知样本应该属于哪一个已知类的过程. 特征层目标识别就是利用分类的思想将雷达回波中提取的关于待识别目标的特征与目标类别数据库的特征进行比较, 判断待识别目标的类别, 并作出决策. 选择合适的分类方法是使融合识别得到高识别率的关键. 由于分类准则的不同, 分类方法主要有决策树分类、距离分类、贝叶斯分类、费希尔分类等<sup>[7]</sup>. 其中, 决策树分类<sup>[8-15]</sup>是分类算法中的一种应用最广泛的技术, 它通过寻找数据间的联系, 描述数据的关系模型, 从而能够作出预测<sup>[16]</sup>. 决策树是一种自顶向下的树形结构, 每一个内部节点代表数据的一个属性, 每一个分支代表一个测试路径, 每一个叶子节点代表一种分类, 树的最顶层节点是该决策树的根节点<sup>[7]</sup>.

如同大多数的分类算法一样, 决策树分类算法分为两步: 学习过程和分类过程. 学习过程就是决策树的构造过程, 而实际战场环境复杂多变, 用于学习过程的训练样本无论是通过仿真模拟获取还是通过实际测试收集获取, 往往与真实的雷达量测数据背景不同. 也就是说, 与量测数据背景相同的训练样本几乎是不存在的, 这就造成了分类的不准确、不可靠. 本文提出的分类算法无需训练样本, 依据一定的先验信息, 按照当前量测数据属性的特点选择分类属性进行分类.

## 2 特征层目标融合识别算法

本文提出的特征层目标融合识别算法采用决策树算法的归纳过程: 自上而下、分而治之<sup>[7]</sup>. 该算法构造了一个类决策树. 所谓类决策树, 不是传统意义上的决策树, 不采用先构造再分类的方式, 而是采用边构造边分类的方法. 分类过程同时也是分支的生长过程, 这正是与决策树分类算法最大的区别所在. 类决策树是一个虚拟的树, 由已知先验信息, 即类别及相应的属性信息直接构成类决策树的叶节点. 当需要对一个待识别目标的量测数据进行分类时, 通过将该数据从根节点向下追溯, 选择合适的分类属性, 在类决策树的每个节点进行判断, 产生相应的分支继续向下, 同时剪掉无效分支, 直至到达某个叶节点, 从而完成对待识别目标的分类或识别.

### 2.1 分类属性的选取

类决策树分类的一个重要问题是在树的非叶节点处寻找一个合适的分类属性, 该属性能够最有效地将量测数据进行分类. 依据 ID3 算法的核心思想, 用信息增益<sup>[17]</sup>作为类决策树中各级节点选择分类属性的标准. 熵是衡量一个系统混乱程度及不确定性的统计量, 熵越大代表系统越混乱. 分类的目的是使不确定转化为确定的过程, 使系统更加有序, 所以选择的分类属性是使分类后熵减小量最大的属性. 在每一个非叶节点对量测数据分类时, 分别计算每个属性的信息增益, 选取信息增益最大的属性作为分类属性<sup>[16]</sup>.

一组雷达的量测数据可以表示为一个多维数组  $X = \{x_1, x_2, \dots, x_n\}$ , 其中每个数据  $x_i (i = 1, 2, \dots, n)$  都是在某个属性变量下相应的取值, 则数组的维数由属性变量的个数决定. 对于同一目标观测, 设雷达组网由  $s$  部雷达构成, 要求每部雷达产生的量测数据维数相同, 都为  $n$  维量测数据. 表示成矩阵形式, 可以得到  $s$  组  $n$  维量测数据  $X_{s \times n}$ .

**定义 1** 假设有  $m$  类目标类别  $\{A_1, A_2, \dots, A_m\}$ , 对于量测数据集合  $X_{s \times n}$  和完全未知类别, 认为其属于任何一类的可能性均等, 则对数据集合分类所需的信息熵为

$$I = -s \times \log_2 \left( \frac{1}{m} \right). \quad (1)$$

**定义 2** 依据目标数据库中已积累的数据, 给出各类目标关于不同属性变量的量值及波动范围. 设一个属性变量为  $c_k (k = 1, 2, \dots, n)$ , 目标类别  $A_j (j = 1, 2, \dots, m)$  关于属性  $c_k$  的标准值和标准偏差分别为  $\theta_{jk}$  和  $\delta_{jk}$ , 取

$$a_{jk} = \theta_{jk} - 2\delta_{jk},$$

$$b_{jk} = \theta_{jk} + 2\delta_{jk},$$

则目标  $A_j (j = 1, 2, \dots, m)$  关于属性  $c_k$  的取值范围是  $(a_{jk}, b_{jk})$ .

假设  $A$  表示全体目标类别, 这里取

$$a_k = \min_{j=1}^m (\theta_{jk} - 3\delta_{jk}),$$

$$b_k = \max_{j=1}^m (\theta_{jk} + 3\delta_{jk}),$$

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

则全体目标  $A$  关于属性  $c_k$  的取值范围是  $(a_k, b_k)$ .

**定义 3** 若属性变量  $c_k (k = 1, 2, \dots, n)$  被选为分类属性, 则利用  $c_k$  划分当前数据集合所需要的信息熵为

$$E(c_k) = \sum_{i=1}^s \left( - \sum_j^m p_k(i, j) \log_2 p_k(i, j) \right),$$

$$k = 1, 2, \dots, n. \quad (2)$$

其中

$$p_k(i, j) = \frac{p_k^0(i, j)}{\sum_{j=1}^m p_k^0(i, j)}, \quad (3)$$

$$p_k^0(i, j) = \frac{|X(i, k) - \theta_{jk}|}{\|X(i, k) - 0.5 \times (a_k + b_k) - |X(i, k) - \theta_{jk}|\|}, \quad (4)$$

其中:  $i = 1, 2, \dots, s; j = 1, 2, \dots, m; k = 1, 2, \dots, n$ .  $p_k^0(i, j)$  是在分类特征  $c_k$  下, 对第  $i$  组量测数据与目标类别  $A_j$  之间距离的描述.  $p_k^0(i, j)$  越小, 表示第  $i$  组量测数据属于目标类别  $A_j$  的可能性越大;  $p_k^0(i, j)$  越大, 表示第  $i$  组量测数据属于目标类别  $A_j$  的可能性越小. 每组量测数据以不同的可能性属于不同的类别, 若属性变量  $c_k$  为分类属性, 则此时状态的混乱程度用信息熵来度量. 对  $p_k^0(i, j)$  归一化后, 计算其熵值, 即为利用  $c_k$  划分第  $i$  组量测数据的信息熵, 该熵值表示分类后第  $i$  组量测数据的不确定性. 对  $s$  组量测数据的信息熵求和, 得到利用  $c_k$  划分当前量测数据集合的信息熵  $E(c_k)$ . 若分类后  $E(c_k)$  数值较小, 则表示利用  $c_k$  划分当前量测数据集合后, 该状态下的混乱程度较小, 量测数据相对确定地属于某个类别, 这正是分类识别要达到的目的.

利用属性变量  $c_k$  作为分类属性, 对当前分支节点数据集合进行分类, 所得的信息增益为

$$\text{Gain}(c_k) = I - E(c_k). \quad (5)$$

$\text{Gain}(c_k)$  即为分类后信息熵的减少量. 通过计算每一个属性变量的信息增益, 将具有最大信息增益的属性作为分类属性对当前节点数据集合进行分类.

## 2.2 分类过程

**定义 4** 若属性变量  $c_k (k = 1, 2, \dots, n)$  为分类属性, 则第  $i (i = 1, 2, \dots, s)$  组量测数据对目标类别  $A_j (j = 1, 2, \dots, m)$  的隶属度<sup>[18]</sup>为

$$K(i, j) = \begin{cases} \frac{-\rho(X(i, k), A_j)}{|A_j|}, & X(i, k) \in (a_{jk}, b_{jk}); \\ \frac{\rho(X(i, k), A_j)}{\rho(X(i, k), A) - \rho(X(i, k), A_j)}, & X(i, k) \notin (a_{jk}, b_{jk}). \end{cases} \quad (6)$$

其中

$$\begin{aligned} \rho(X(i, k), A_j) &= \\ \left| X(i, k) - \frac{1}{2}(a_{jk} + b_{jk}) \right| - \frac{1}{2}(b_{jk} - a_{jk}) &= \\ |X(i, k) - \theta_{jk}| - 2 \times \delta_{jk}, \end{aligned}$$

$$i = 1, 2, \dots, s, j = 1, 2, \dots, m, \quad (7)$$

$\rho(X(i, k), A_j)$  为第  $i$  组量测数据与目标类别  $A_j$  的关联系数;

$$\begin{aligned} \rho(X(i, k), A) &= \\ \left| X(i, k) - \frac{1}{2}(a_k + b_k) \right| - \frac{1}{2}(b_k - a_k), & \\ i = 1, 2, \dots, s, & \end{aligned} \quad (8)$$

$\rho(X(i, k), A)$  为第  $i$  组量测数据与全体目标类别的关联系数;

$$|A_j| = b_{jk} - a_{jk} = 4 \times \delta_{jk}, \quad j = 1, 2, \dots, m, \quad (9)$$

$|A_j|$  为目标类别  $A_j$  的宽度.

$K(i, j)$  表示在当前分类属性下, 第  $i$  组量测数据所观测目标属于目标类别  $A_j$  的程度. 当  $K(i, j) \geq 0$  时, 判定所观测目标为目标类别  $A_j$ ; 当  $K(i, j) < 0$  时, 判定所观测目标不是目标类别  $A_j$ , 而是其他类别.

由该分类属性下的隶属度创建分支, 并进行分类. 对产生的每个分支继续选择下一级的分类属性, 递归地拓展类决策树的分支. 在分类完成后, 利用每组量测数据最后一级分类产生的隶属度计算该识别结果的可信度.

**定义 5**  $w_i$  是第  $i$  组量测数据的权重, 它表示对第  $i$  组量测数据的信任程度. 判定第  $i$  组量测数据所观测目标是目标类别  $A_j$  的可信度定义为

$$B_i = \frac{(e^{K(i, j)})^2}{\sum_{j=1}^m (e^{K(i, j)})^2}. \quad (10)$$

对量测数据集合  $X_{s \times n}$  进行分类识别, 判定识别结果为  $A_j$  的可信度为

$$B = \sum_{i=1}^s w_i B_i. \quad (11)$$

若无事先说明, 可以认为各雷达的量测数据权重相同, 取  $w_i = 1/s$ .

## 2.3 分类规则

本文提出的类决策树分类算法的分类规则描述如下.

1) 由目标数据库给出各类别目标关于不同属性的量值及波动范围, 各类别构成类决策树的叶节点.

2) 以全体量测数据集合创建第 1 个节点, 即根节点.

3) 选取具有最大信息增益的属性作为分类属性. 对当前分支节点数据集合依据 2.2 节分类过程进行分类, 产生类决策树的分支.

4) 使用相同的过程, 递归地形成树的分支. 一旦

一个属性变量在某节点处被选为分类属性, 则在该节点的任何后代上, 选择分类属性时就不必考虑该属性变量.

5) 当不同类别目标在同一属性变量上特性相近时, 可能产生一组数据同时属于多类别目标的情况. 由于雷达量测数据存在干扰, 可能产生一组数据不属于任何类别的情况. 以上情况可归纳为分类结果没有唯一确定, 也就是说, 经过一级分类不能得到识别结果. 此时, 将没有唯一确定分类结果的量测数据组再次进行下一级分类.

6) 当且仅当以下条件之一成立时, 递归步骤停止:

① 所有有效的量测数据产生唯一、相同的分类结果, 即到达类决策树的某叶节点;

② 没有剩余属性变量可以用来对数据进行分类.

对于①, 将分类结果判定为目标类别; 对于②, 不能再进行分类时将当前节点转换为叶节点, 并使用多数表决, 将数据中绝大部分所属的类判定为目标类别. 在分类完成后, 计算识别结果的可信度, 用于对识别准确性的评估.

分类过程中, 还需要注意以下两个关键问题.

1) 对于空缺值的处理方法.

若某组量测数据中含有某个属性对应的值空缺, 则在选择分类属性时只计算非空属性值分类所需的信息熵, 忽略空缺值对分类属性的熵值的影响. 对含有空缺值的数据进行分类时, 若该分类属性下量测数据空缺, 则该组数据跳过本级分类, 进入下一级分类, 直到确定该量测数据类别.

2) 边构造边剪枝.

通常决策树多采用事后剪枝, 即在决策树构造完成后剪掉多余的分支, 以便获得更准确的决策树. 事前剪枝, 是在适当时候停止分支过程, 在当前节点上判断是否需要继续划分该节点所含数据集. 由于雷达量测数据存在干扰, 导致数据不确定性大, 会形成异类分支. 本文采用边构造边剪枝的方式, 即当前节点产生相应的分支, 并暂时保留每个分支, 进行下一级分类. 若连续两次某分支相对其余分支为异类分支, 则将该分支视为无效, 其他分支继续进行分类, 直到确定所有量测数据类别, 从而提高识别算法的抗干扰能力.

本文提出的类决策树分类识别算法处理流程如图 1 所示.

类决策树分类算法依据信息增益最大的准则, 从可供选择的特征属性中选择对于目标识别最有效的

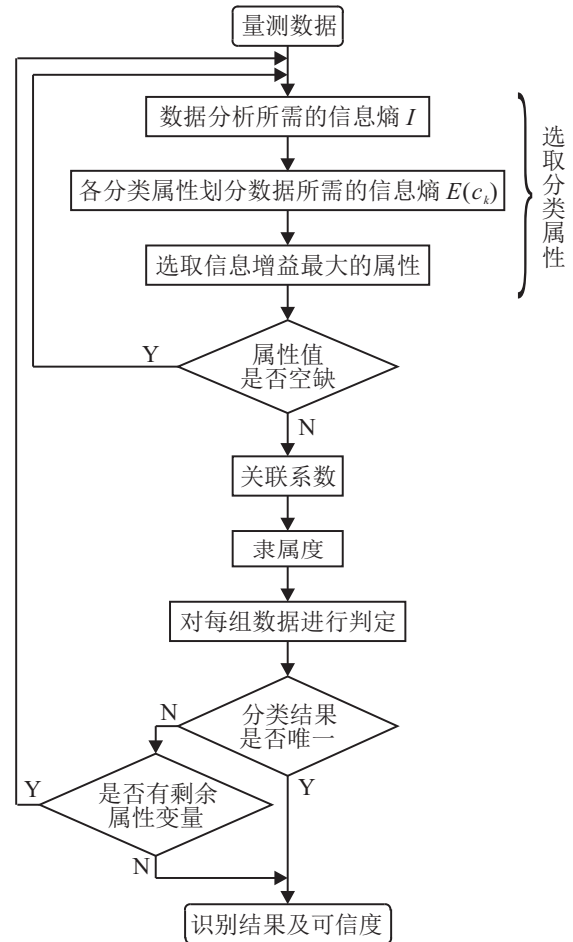


图 1 类决策树分类识别算法处理流程

特征, 可以最大程度地缩短枝干长度, 时效性好, 有利于实时处理. 该算法可有效对含有空缺值的量测数据进行分类识别, 具备一定的抗干扰能力.

### 3 仿真实验

为说明类决策树分类算法在处理特征层融合识别时的优势, 本文从以下两个方面进行仿真实验研究.

#### 3.1 针对可信度的对比仿真实验

**例 1** 假设现有雷达组网中 3 部雷达对一空中目标进行探测识别. 已知 3 种目标类别  $A_1$ 、 $A_2$ 、 $A_3$ . 选取 4 项用于识别的属性变量  $c_1$ 、 $c_2$ 、 $c_3$  和  $c_4$ , 标准值分别为  $\theta_1$ 、 $\theta_2$ 、 $\theta_3$  和  $\theta_4$ , 标准偏差分别为  $\delta_1$ 、 $\delta_2$ 、 $\delta_3$  和  $\delta_4$ , 由先验知识给出 3 种目标类别的参数模板如表 1 所示.

表 1 目标类别的标准值及标准偏差

A	$\theta_1$	$\delta_1$	$\theta_2$	$\delta_2$	$\theta_3$	$\delta_3$	$\theta_4$	$\delta_4$
$A_1$	1	0.18	200	6.5	15	2.3	350	12
$A_2$	0.6	0.11	139	4.8	80	4.1	235	16
$A_3$	0.2	0.06	64	3.9	46	3.9	433	11

每部雷达经时空配准和关联处理后的量测数据记录如表 2 所示, 试确定该空中目标的类别.

表2 雷达量测数据

X	$x_1$	$x_2$	$x_3$	$x_4$
$X_1$	0.9	209	21	372
$X_2$	1.2	188	14	330
$X_3$	0.8	222	19	385

1) 由表1先验信息构成类决策树的叶节点.

2) 创建第1个节点. 由式(1)得到对量测数据集合分类所需的信息熵为  $I = 4.7549$ . 依据式(2)~(5)计算每一个属性变量的信息增益, 将具有最大信息增益  $\text{Gain}(c_2) = 3.0497$  的属性  $c_2$  作为分类属性, 对当前节点数据集合分类, 分类过程如式(6)所示. 得到隶属度

$$K_1 = \begin{bmatrix} 0.1538 & -0.6704 & -0.8402 \\ 0.0385 & -0.4373 & -0.7116 \\ -0.2769 & -0.8147 & -0.9198 \end{bmatrix}.$$

由隶属度可以看出, 第1组和第2组数据得到唯一的分类结果, 即第1类目标, 而第3组数据通过第1级分类未能作出有效识别.

3) 对第3组数据进行下一级分类, 重复上述过程. 计算除  $c_2$  以外每一个属性变量的信息增益, 将具有最大信息增益的属性  $c_3$  作为分类属性对当前节点数据集合分类, 得到隶属度

$$K_2 = [0.0652 \quad -0.6592 \quad -0.4201].$$

由隶属度可以看出, 第3组数据得到了唯一的分类结果, 即第1类目标. 至此, 所有的量测数据产生唯一、相同的分类结果, 即到达类决策树的叶节点, 停止分类. 识别结果为第1类目标.

4) 取  $w_i = 1/3, i = 1, 2, 3$ , 依据式(10)和(11)计算得到识别结果的可信度为  $B = 0.6645$ .

在没有训练样本的情况下, 本文算法实现了对待识别目标的分类识别, 而绝大多数的分类方法并不适用. 为此, 选用决策层融合中证据理论的方法对例1进行目标识别: 利用量测数据与参数模板之间的向量夹角余弦作为基本概率指派, 再应用证据理论进行融合, 得到识别结果为第1类目标, 可信度为0.5797. 将该识别结果与本文算法的识别结果进行对比, 可以得出两种方法的最终识别结果是一致的, 且本文算法具有更高的识别可信度.

### 3.2 针对空缺值的仿真实验

**例2** 沿用例1, 3种目标类别的先验知识如表1所示. 假设雷达组网的量测数据存在部分空缺值, 将原量测数据任意设置空缺值得到表3, 试确定该空中目标的类别.

表3 雷达量测数据(含空缺值)

X	$x_1$	$x_2$	$x_3$	$x_4$
$X_1$	0.9	209	0	372
$X_2$	0	188	14	330
$X_3$	0.8	222	19	0

基于类决策树分类的识别算法过程如同例1, 相同部分不再赘述. 在第1个节点处, 计算每一个属性变量的信息增益. 由于存在空缺值, 只计算非空属性值分类所需的信息熵. 将具有最大信息增益属性  $c_3$  作为分类属性对当前节点数据集合分类, 得到隶属度

$$K_1 = \begin{bmatrix} 0 & 0 & 0 \\ 0.0913 & -0.5216 & -0.3295 \\ 0.0652 & -0.6592 & -0.4201 \end{bmatrix}.$$

由隶属度可以看出, 第2组和第3组数据得到了唯一的分类结果, 即第1类目标, 而第1组数据含有属性  $c_3$  下的空缺值, 从而不参与本级分类. 进行下一级分类, 重复上述过程, 计算除  $c_3$  以外每一个属性变量的信息增益, 将具有最大信息增益的属性  $c_2$  作为分类属性对当前节点数据集合分类, 得到隶属度

$$K_2 = [0.1538 \quad -0.6704 \quad -0.8402].$$

由隶属度可以看出, 第1组数据得到了唯一的分类结果, 即第1类目标. 至此, 所有的量测数据产生唯一、相同的分类结果, 停止分类. 识别结果为第1类目标, 可信度为0.6506. 这与例1的识别结果一致.

例2验证了所提出的算法能够对含有空缺值的量测数据进行分类识别.

## 4 结 论

基于类决策树分类的目标识别算法在特征层进行融合识别, 相比决策层融合, 提高了信息利用率, 能够对含有空缺值的量测数据进行正确分类, 提高了目标识别结果的可信度. 相比数据层融合, 克服了数据量过大, 抗干扰能力差的不足. 并且, 采用信息增益最大的属性作为分类属性进行分类, 使得根节点到达叶节点的路径较短, 从而提高了分类速度. 类决策树分类算法无需训练样本, 是一种简单有效的特征层融合识别算法, 普遍适用于战时雷达组网目标融合识别, 特别是针对量测数据不准确、不完备的情况, 能够对其进行合理的分类识别. 该方法不仅适用于雷达组网的目标识别, 也可推广到其他多传感器的决策问题.

### 参考文献(References)

[1] Yan Y, Zhanrong J, Tian G, et al. Multi-sources information fusion algorithm in airborne detection systems[J]. J of Systems Engineering and Electronics, 2007, 18(1): 171-

- 176.
- [2] 陈娟. 基于多特征融合的雷达目标识别[D]. 西安: 西安电子科技大学, 2010.  
(Chen J. Radar target recognition based on multi-features fusion[D]. Xi'an: Xidian University, 2010.)
- [3] 吴瑕, 周焰, 蔡益朝, 等. 多传感器目标融合识别系统模型研究现状与问题[J]. 宇航学报, 2010, 31(5): 1413-1420.  
(Wu X, Zhou Y, Cai Y C, et al. Research actualities and problems on multisensor target recognition system model[J]. J of Astronautics, 2010, 31(5): 1413-1420.)
- [4] 蒋晓瑜, 梁浩聪, 王加, 等. 目标识别中多传感器信息融合算法比较[J]. 计算机系统应用, 2013, 22(4): 10-13.  
(Jiang X Y, Liang H C, Wang J, et al. Comparison of multi-sensor information fusion algorithms based on target recognition[J]. Computer Systems & Applications, 2013, 22(4): 10-13.)
- [5] 何友, 王国宏, 关欣, 等. 信息融合理论及应用[M]. 北京: 电子工业出版社, 2010: 91-101.  
(He Y, Wang G H, Guan X, et al. Information fusion theory with applications[M]. Beijing: Publishing House of Electronics Industry, 2010: 91-101.)
- [6] 周伟芳, 叶学义, 何文韬, 等. 基于 SVM 特征层融合的集成性身份识别模型[J]. 计算机应用与软件, 2013, 30(9): 81-83.  
(Zhou W F, Ye X Y, He W T, et al. A feature-level SVM fusion based integration identification model[J]. Computer Applications and Software, 2013, 30(9): 81-83.)
- [7] 丁世飞, 靳奉祥, 赵相伟. 现代数据分析与信息模式识别[M]. 北京: 科学出版社, 2013: 43-46.  
(Ding S F, Jin F X, Zhao X W. Modern data analysis and information pattern recognition[M]. Beijing: Science Press, 2013: 43-46.)
- [8] Burduk R, Wozniak M. Different decision tree induction strategies for a medical decision problem[J]. Central European J of Medicine, 2012, 7(2): 183-193.
- [9] 刁智华, 赵春江, 郭新宇, 等. 一种新的基于平衡决策树的 SVM 多类分类算法[J]. 控制与决策, 2011, 26(1): 149-152.  
(Diao Z H, Zhao C J, Guo X Y, et al. A new SVM multi-class classification algorithm based on balance decision tree[J]. Control and Decision, 2011, 26(1): 149-152.)
- [10] 王一, 杨俊安, 刘辉. 一种基于遗传算法的 SVM 决策树多分类方法[J]. 信号处理, 2010, 26(10): 1495-1499.  
(Wang Y, Yang J A, Liu H. A GA-based SVM decision-tree multi-classification method[J]. Signal Processing, 2011, 26(1): 1495-1499.)
- [11] Cheng Y C, Wang P C. Packet classification using dynamically generated decision trees[J]. IEEE Trans on Computers, 2015, 64(2): 582-586.
- [12] Saqib F, Dutta A, Plusquellic J, et al. Pipelined decision tree classification accelerator implementation in FPGA(DT-CAIF)[J]. IEEE Trans on Computers, 2015, 64(1): 280-285.
- [13] Wang X, Liu X, Pedrycz W, et al. Fuzzy rule based decision trees[J]. Pattern Recognition, 2015, 48(1): 50-59.
- [14] Genrikhov I E. Analysis of the generalization ability of a full decision tree[J]. Computational Mathematics and Mathematical Physics, 2014, 54(6): 1046-1059.
- [15] Ihsan A Kareem, Mehdi G Duaimi. Improved accuracy for decision tree algorithm based on unsupervised discretization[J]. Int J of Computer Science and Mobile Computing, 2014, 3(6): 176-183.
- [16] 穆建伟. 决策树分类的研究[D]. 大连: 大连交通大学, 2010.  
(Mu J W. Research on classification of decision tree[D]. Dalian: Dalian Jiaotong University, 2010.)
- [17] Adler M, Heeringa B. Approximating optimal binary decision trees[J]. Algorithmica, 2012, 62(3/4): 1112-1121.
- [18] 蔡文. 物元模型及其应用[M]. 北京: 科学技术文献出版社, 1994: 267-271.  
(Cai W. The matter-element model and its application[M]. Beijing: Scientific and Technical Documentation Press, 1994: 267-271.)
- [19] 万树平, 董久英. 空袭目标识别的证据理论方法[J]. 计算机工程与应用, 2010, 46(1): 206-207.  
(Wan S P, Dong J Y. Method of evidence theory for air target recognition[J]. Computer Engineering and Applications, 2010, 46(1): 206-207.)

(责任编辑: 曹洪武)