

# 基于证据组合的通信信号调制类型的分类识别<sup>1</sup>

吕铁军 王 河 肖先赐

(电子科技大学电子工程学院 成都 610054)

**摘 要** 该文应用 Dempster-Shafer 理论, 提出了一种有效的证据分配和组合证据最佳区间的方法, 来实现通信信号调制类型的分类识别, 在低信噪比的情况下, 识别率得到较大提高, 并且降低了分类器设计的复杂性. 计算机模拟结果证实了此方法的有效性.

**关键词** 调制识别, Dempster-Shafer 理论, 证据组合, 分类器

**中图分类号** TN911.3

## 1 引 言

通信信号调制类型的分类识别是在统计模式识别领域内比较活跃的一个分支<sup>[1]</sup>。由于通信信号在传播过程中易受各种噪声的干扰, 造成接收信号的不确定性, 给分类识别带来了困难。传统上基于 Bayes 理论的统计分类器必须借助样本集来估计类条件分布密度, 它无法给出信号类别的不确定性水平。作为 Bayes 理论的推广——Dempster-Shafer(D-S) 证据分配理论<sup>[2-4]</sup>对模式的描述和刻画更加细致、准确, 为改善调制类型识别性能提供了有力的支持。

本文应用 D-S 理论, 提出了一种证据区间的组合方法, 每一类别的证据区间由相互独立的不同分类器提供, 单个分类器采用神经网络分类器, 因为它比传统的分类器具有更强的自适应能力和更好的稳健性<sup>[5]</sup>, 使用也很简便。组合后选取“最佳”证据, 由判定逻辑给出最终类别。本文第 2 节简述 D-S 理论的特点, 第 3 节中针对通信信号调制类型分类识别的实现, 讨论了证据分配和证据组合算法, 计算机模拟结果在第 4 节给出。

## 2 Dempster-Shafer 证据分配理论

众所周知, Bayes 统计理论要求假设集合是完备且互不相容的, 同时认为假设要么正确, 要么不正确, 是一种布尔现象, 假设正确和不正确概率之和恒为 1。但是实际情况中, 我们对一种假设的不确定性水平需要了解, 以便较准确地对假设作出判断。D-S 理论认为人们并不是把对事物的可信度(证据)分配给完备和互不相容的假设集合, 而是把证据分配给假设和假设的组合, 单个假设或假设的组合分别构成简单或综合命题, 命题可以包含互相交迭和冲突的假设。考虑  $\Theta$  是由  $K$  个完备和互不相容的基本假设组成的一个集合

$$\Theta = \{\theta_1, \theta_2, \dots, \theta_K\} \quad (1)$$

$2^\Theta$  表示  $\Theta$  的布尔组合所构成的命题集合。函数  $m$  表示一种基本证据分配, 它满足:

$$(1) 2^\Theta \rightarrow [0, 1], \quad 0 \leq m(A) \leq 1, \quad A \subseteq \Theta;$$

$$(2) m(\Phi) = 0, \quad \Phi \text{ 表示空集};$$

$$(3) \sum_{A \subseteq \Theta} m(A) = 1.$$

从上面的定义可以得出 D-S 方法把证据分配给简单和综合的命题, 即对于  $A$  是集合  $2^\Theta$  的一个命题, 满足

<sup>1</sup> 1999-11-30 收到, 2000-07-13 定稿

$$m(A) + m(\neg A) \leq 1 \tag{2}$$

为了说明命题的不确定性水平，定义证据区间  $[Spt(A), Pls(A)]$ ，其中

$$Spt(A) = \sum_{A \in \Theta; 2^\Theta} m(\Theta, 2^\Theta) \tag{3}$$

表示支持命题  $A$  的证据 (可信度)。

$$Pls(A) = 1 - Spt(\neg A) \tag{4}$$

表示命题  $A$  的似乎可信度。同理可定义  $\neg A$  的证据区间  $[Spt(\neg A), Pls(\neg A)]$ ，其中

$$Spt(\neg A) = 1 - Pls(A) \tag{5}$$

表示反对命题  $A$  的证据。

$$Pls(\neg A) = 1 - Spt(A) \tag{6}$$

表示命题  $A$  的似乎不可信度。

对于两个独立的信息源，Dempster 组合规则可以表示为

$$m(C) = \frac{\sum_{A \cap B = C} m_1(A)m_2(B)}{1 - \sum_{A \cap B = \phi} m_1(A)m_2(B)} \tag{7}$$

式中， $m_1, m_2$  分别为两信息源的基本证据分配。组合规则可以推广到多个信息源的情况，但是随着信息源的增加，(7) 式中的组合项将按指数增加，造成计算的繁杂，本文提出的方法克服了这种不足。

### 3 组合分类识别

通信信号调制识别利用 D-S 理论，通过证据说明得出每个假设的联合证据区间，然后应用判定逻辑来选择具有最佳证据区间的假设，其结论就是所有分类器组合证据在该类别的一个说明。具体过程如图 1 所示。




图 1 调制分类识别示意图

假设有  $K$  种调制类型，与之相对应有  $K$  个完备和互不相容的基本假设组成辨识框架  $\Theta = \{H_1, H_2, \dots, H_K\}$ ，其中  $H_k$  表示结果是第  $k$  种调制类型。首先要对每个基本假设分配证据，证据的分配既要体现对假设的相信程度，又要满足 D-S 的约束条件，如图 1 所示，单个分类器提供了一个粗略的假设可信度，在此基础上本文定义第  $n$  个分类器上第  $k$  类假设的证据为

$$m_n(H_k) = 1 - \frac{\sum_{i=1}^K \text{ave}_{nk}(i) \ln o_{nk} + (1 - \text{ave}_{nk}(i)) \ln(1 - o_{nk})}{\sum_{k=1}^K \sum_{i=1}^K \text{ave}_{nk}(i) \ln o_{nk} + (1 - \text{ave}_{nk}(i)) \ln(1 - o_{nk})},$$

$$n = 1, 2, \dots, N \quad (8)$$

式中,  $\text{ave}_{nk}(i)$  为第  $n$  个分类器输出的第  $k$  类的第  $i$  个分量,  $o_{nk}$  是矢量  $\bar{O}_n$  的第  $k$  个分量。不难看出, (8) 式是以仙农熵的观点给出了每种类别的证据, 当输入模式越靠近某一类别的中心, 交叉熵越小, 模式类别的说明就越可信。由于  $H_k$  是  $\Theta$  的基本假设 (简单命题), 根据 (3) 式可得  $H_k$  的支持函数

$$\text{Spt}_n(H_k) = m_n(H_k) \quad (9)$$

那么,  $\neg H_k$  的支持函数为

$$\text{Spt}_n(\neg H_k) = \text{Spt}_n \left[ \bigcup_{\substack{i=1 \\ i \neq k}}^K H_i \right]$$

$$= \sum_{\substack{i=1 \\ i \neq k}}^K \text{Spt}_n(H_i) - \sum_{\substack{1 \leq i < j \leq K \\ i, j \neq k}} \text{Spt}_n(H_i) \text{Spt}_n(H_j) + \dots + (-1)^{K-1} \prod_{\substack{i=1 \\ i \neq k}}^K \text{Spt}_n(H_i) \quad (10)$$

由 (5) 式可得  $H_k$  的似信度函数

$$\text{Pls}_n(H_k) = 1 - \text{Spt}_n(\neg H_k) \quad (11)$$

这样, 对所有分类器组成假设  $H_k$  的一个证据区间集  $\{[\text{Spt}_n(H_k), \text{Pls}_n(H_k)] \mid n = 1, 2, \dots, N\}$ ,  $H_k$  的后验概率  $P(H_k | \bar{X}_n)$  满足下式

$$\text{Spt}_n(H_k) \leq P(H_k | \bar{X}_n) \leq \text{Pls}_n(H_k) \quad (12)$$

所以, 为了充分利用各个分类器的证据信息, 本文定义最佳证据区间为  $[\text{Spt}(H_k), \text{Pls}(H_k)]$ , 其中

$$\text{Spt}(H_k) = \sup_{1 \leq n \leq N} \{\text{Spt}_n(H_k)\}, \quad \text{Pls}(H_k) = \inf_{1 \leq n \leq N} \{\text{Pls}_n(H_k)\} \quad (13)$$

实际情况中, 分类器的数目有限, 上确界和下确界的计算分别对应求最大值和最小值, 再根据第 2 节中的有关讨论, 不难得到  $\neg H_k$  的最佳证据区间  $[\text{Spt}(\neg H_k), \text{Pls}(\neg H_k)]$ 。有了上面的讨论, 运用 D-S 组合规则 (7) 式可得修正的证据  $c_k$

$$c_k = \frac{\text{Spt}(H_k) \text{Pls}(H_k)}{1 - \text{Spt}(H_k) \text{Spt}(\neg H_k)} \quad (14)$$

最后的判定逻辑很简单, 只需考虑: 如果  $c_p = \max_{1 \leq k \leq K} c_k$ , 那么输入模式就是第  $p$  种调制类型 (预先对每一类都编了号)。

## 4 模拟结果

本文提出的通信信号调制类型分类识别的分类性能由计算机模拟获得。在模拟过程中考虑未调载波 CW 和已调信号 ASK, FSK, PSK, QASK, QFSK, QPSK 共 7 种调制类型。本文单个分类器采用多层感知神经网络分类器, 每个分类器的输入节点由特征矢量的维数决定, 隐层数和隐层节点数在实验的基础上随机确定。通信信号的特征向量由 14 种常用特征组成<sup>[6]</sup>, 它们是: (1) AM 调幅度。(2) 瞬时频率标准偏。(3) 中心化绝对值瞬时频率标准偏。(4) 分段谱峰标准偏。(5) 平均频率。(6) 分段两谱峰间距标准偏。(7) -6dB 带宽估计。(8) -26dB 带宽估计。(9) FSK 频率间隔。(10) 主峰功率。(11) 次峰功率。(12) 归一化幅度平方的方差。(13) 绝对值幅度平方的方差。(14) 相位跳变点数目。根据每类特征间的差异重新组合为 4 个低维的特征向量:  $\bar{X}_1$  由特征 1, 2, 3, 5, 13 组成,  $\bar{X}_2$  由特征 3, 4, 5, 6, 14 组成,  $\bar{X}_3$  由特征 1, 5, 8, 9, 10 组成,  $\bar{X}_4$  由 2, 5, 7, 11, 12 组成。那么 4 个神经网络分类器的结构分别为: (1) 5-10-7; (2) 5-18-7; (3) 5-8-8-7; (4) 5-8-16-7。

首先, 对单个 BP 分类器进行训练, 训练过程互相独立, 每个分类器训练次数为 2000 次, 达到规定的次数后结束训练。所加噪声为高斯型, 监督信号为 0-1 型, 实际取当前类型所对应的输出层神经元的期望值为 0.9, 其余为 0.1。每一个分类器的每一类别的输出均值由 400 个样本平均得到。本文模拟了信噪比为 20dB, 15dB, 10dB, 5dB 条件下单个分类器和本文方法的分类性能, 表 1 和表 2 给出信噪比为 10dB, 5dB 时的识别率, 每一类测试 200 次。

从表中可以看出分类器 2 的性能最差, 训练时极易陷入局部极值点而无法自拔, 这是 BP 神经网络的通病。本文方法充分利用单个分类器的信息, 基于 D-S 理论对模式进行精细刻画, 使通信信号调制类型的分类性能得到较大改善, 最后每一类别的分类结果均趋近于单个分类器中同一类别的最好结论。

表 1 10dB 时单个分类器的识别率

	CW(%)	ASK(%)	FSK(%)	PSK(%)	QASK(%)	QFSK(%)	QPSK(%)
分类器 1	97.5	100.0	98.0	100.0	99.0	100.0	100.0
分类器 2	100.0	0.0	0.0	12.0	100.0	100.0	20.5
分类器 3	99.5	100.0	99.0	99.5	100.0	100.0	98.0
分类器 4	100.0	100.0	100.0	100.0	98.5	99.5	100.0
本文方法	100.0	100.0	99.5	100.0	100.0	100.0	99.0

表 2 5dB 时单个分类器的识别率

	CW(%)	ASK(%)	FSK(%)	PSK(%)	QASK(%)	QFSK(%)	QPSK(%)
分类器 1	95.5	99.5	100.0	88.0	100.0	100.0	100.0
分类器 2	0.0	0.0	100.0	0.0	0.0	0.0	0.0
分类器 3	100.0	96.5	98.0	100.0	99.0	100.0	97.0
分类器 4	100.0	100.0	93.5	100.0	100.0	99.5	100.0
本文方法	100.0	99.5	99.5	100.0	100.0	99.0	100.0

## 5 结 论

本文基于 D-S 证据理论, 提出了一种证据组合的方法对通信信号调制类型进行分类识别, 证据的分配是从交叉熵的观点来阐述的, 它很好的描述了特征向量之间的相似度。组合各个分类器的证据区间得到最佳证据区间, 为判定类别提供了准确的测度。特征矢量的分集降低了维

数, 简化单个分类器的设计。因此本文方法具有很高的分类能力和良好的稳健性。计算机模拟结果充分证实了这种新方法的良好性能。

### 参 考 文 献

- [1] A.K. Nand, E. E. Azzouz, Algorithms for automatic modulation recognition of communication signals, IEEE Trans. on Comm., 1998, 46(4), 434-436.
- [2] E. J. Mandler, J. Schurmann, Combining the classification result of independent classifiers based on the Dempster/Shافر theory of evidence, Pattern Recognition and Artificial Intelligence, North-Holland, Elsevier Science Publishers B. V., 1988, 381-393.
- [3] S. C. A. Thomopoulos, Theories in distributed decision fusion: comparison and generalization, Sensor fusion III:3-D perception and recognition, SPIE, 1383, 1990, 623-634.
- [4] S. C. A. Thomopoulos, Sensor integration and data fusion, Journal of Robotic Systems, 1990, 7(3), 337-372.
- [5] S. Haykin, Neural Networks, A Comprehensive Foundation, New York, MacMillan, 1994, Ch.6.
- [6] 通信信号特征分析研究, 研究报告, 成都, 电子科技大学, 1998.

## RECOGNITION OF COMMUNICATION SIGNALS BASED ON EVIDENCE COMBINATION

Lu Tiejun    Wang He    Xiao Xianci

(Dept. Electronic Eng., UEST of China, Chengdu 610054, China)

**Abstract** In this paper, several methods of evidence assignment and combination of optimum interval with Dempster-Shafer theory are proposed to identify communication signals. Under low SNR circumstance, the identifiability is highly promoted. Moreover, the design of classifier is simplified. The availabilities of these methods are verified by computer simulation.

**Key words** Modulation recognition, Dempster-Shafer theory, Evidence combination, Classifier

吕铁军: 男, 1969年生, 博士生, 现主要从事信号处理, 模式识别, 人工神经网络和模糊信息处理的研究。

王 河: 男, 1972年生, 博士生, 研究领域为谱估计, 阵列信号处理算法, 空间自适应技术研究。

肖先赐: 男, 1933年生, 教授, 博士生导师, 现主要从事信号处理及其在雷达、通信、电子对抗等方面应用的教学和研究工作。