

## 多传感器数据融合的多准则决策模型

周杰, 蔡世清, 朱伟娜

(南京信息工程大学 电子与信息工程学院, 南京 210044)

**摘要:** 在多准则下考察传感器的融合权重, 提出一种新的多传感器数据融合方法. 通过多个性能指标折中估计传感器权重, 以降低决策的主观性和偶然性; 提出从不同融合级别来定义多个准则, 定性地提高了多准则的信息量; 在没有决策者对各准则偏好信息的情况下, 以最小化准则冗余度和最大化评价差异度为原则建立多目标优化模型对准则权重向量优化求解. 仿真实验结果表明, 相比于单准则和单层次的融合方法, 所提出方法具有更低的决策风险和更高的稳定性.

**关键词:** 多传感器数据融合; 目标识别; 多准则; 直觉模糊集

**中图分类号:** TP391

**文献标志码:** A

### Multi-criteria decision model of multi-sensor data fusion

ZHOU Jie, CAI Shi-qing, ZHU Wei-na

(College of Electronic & Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China. Correspondent: CAI Shi-qing, E-mail: 1349053218@qq.com)

**Abstract:** A new multi-sensor data fusion method using multi-criteria decision aid is proposed, which considers several indicators to reduce the decision subjectivity and contingency. Different fusion levels in the multi-sensor target recognition system is proposed to define multiple criteria, hence to gain more information of multi-criteria qualitatively. With no information about the preference of the decision maker for each criteria, the criteria weights vector can be obtained by solving a multi-objective optimization which intends to minimize the criteria redundancy and maximize the diversity factor of every criteria. The simulation results show that the proposed method performs better in anti-risk capability and stability than the mono-criteria and decision-making level method.

**Keywords:** multi-sensor data fusion; target recognition; multi-criteria; vague set

### 0 引言

多传感器数据融合<sup>[1-3]</sup>的结构按信息表征方式可分为数据层、特征层和决策层融合, 对来自多个传感器的数据进行多级、多方面、多层次的处理, 可以产生新的有意义的信息. 在多传感器目标识别系统中, 有效的数据融合算法可以提高识别精度, 降低决策风险. 然而, 在多传感器目标识别的数据融合中, 以往大量的研究都是在决策层的属性融合<sup>[4-12]</sup>, 其基本原理是根据统计数据建立各种类型目标的各特征参数的概率密度函数, 或将其转化为模糊隶属度, 从而建立特征参数与目标类型的模糊关系, 通过模糊推理对对象集进行基本信度分配. 这些方法都是基于单准则的决策, 因为没有一个是被广泛接受的标准能够

确定何时信息已经足以支持给定的任务, 必须依靠经验的性能度量来评估单个信源的有效性, 所以单准则的处理方式是主观和片面的. 文献[13]提出将层次分析法(AHP)应用于多传感器在多准则下的数据融合, 其层次结构模型对不同类型的传感器属性权(可信度)的估计是在各种环境模式下的一个折中值, 不能随环境的变化而改变. 文献[14]提出了一种将层次分析法应用于同质传感器的数据融合算法, 基于证据理论以各传感器对目标的属性描述为基础定义不同准则, 以此得到各传感器的融合权重. 然而, 从测量数据到特征提取再到属性的判决传递过程经历了大量的整合与提炼, 低层数据的细节在决策层被过滤掉而无法体现出来, 所以单独用决策层的信息无法完整得

**收稿日期:** 2015-07-22; **修回日期:** 2015-11-02.

**基金项目:** 江苏省高校自然科学研究重大项目(14KJA510001); 国家自然科学基金项目(61471153, 61372128); 江苏省信息与通信工程优势学科建设项目.

**作者简介:** 周杰(1964—), 男, 教授, 博士, 从事移动通信理论、无线传感器、接入技术等研究; 蔡世清(1991—), 男, 硕士生, 从事无线传感器网络数据处理的研究.

到各传感器的多种状态准则. 基于此, 本文从不同级别的信息描述传感器的状态, 充分保证各准则的全面性, 从不同角度考察传感器的数据质量.

本文以传感器自身状态和与系统中其他传感器的一致性关系为两大准则, 又将两大准则分别分解为3个子准则, 建立融合层次结构. 子准则分别反映数据层、特征层和决策层的信息质量, 通过最小化准则冗余度和最大化准则信息熵对准则权重优化求解, 得到能够最大化传感器状态信息的多准则决策模型, 大大降低了决策的主观性和风险性. 仿真实验结果表明, 相比于单准则和单层次的融合方法, 所提出方法具有更低的决策风险和更高的稳定性.

## 1 多准则融合系统框架

### 1.1 属性识别的 Vague 集表示

**定义 1** 在全域  $X$  上的 Vague 集  $A$  是指, 对于任意元素  $x \in X$ , 都能找到一对隶属度函数  $t_A(x)$  和  $f_A(x)$ , 满足

$$t_A(x) \in [0, 1], f_A(x) \in [0, 1], \\ 0 \leq t_A(x) + f_A(x) \leq 1.$$

其中:  $t_A(x)$  为  $x$  属于 Vague 集  $A$  的真隶属函数, 表示支持  $x \in A$  的证据隶属度下界;  $f_A(x)$  为 Vague 集  $A$  的假隶属度或非隶属度, 表示反对  $x \in A$  的证据隶属度下界;  $\pi_A(x) = 1 - t_A(x) - f_A(x)$  为  $x$  对于 Vague 集  $A$  的犹豫度, 其值刻画了  $x$  相对于 Vague 集的犹豫程度, 是  $x$  相对于  $A$  的未知信息的一种度量, 满足  $0 \leq \pi_A(x) \leq 1$ , 其值越大反映  $x$  对于判断是否属于  $A$  的未知信息越多.

**定义 2** 设  $x \in X$ , 称闭区间  $[t_A(x), 1 - f_A(x)]$  为 Vague 集  $A$  在点  $x$  上的 Vague 值.

以一维特征参数  $x$  作属性判别为例, 设  $U(x)$  是特征参数  $x$  对于目标  $O$  的模糊隶属度, 在统计数据下该类型对应参数  $x$  的期望值为

$$E(x) = \frac{\int U(x) x dx}{\int U(x) dx}$$

其中分母为归一项. 为了建立 Vague 集数学模型, 构造如下投票模型: 设定4个阈值  $x_{fl} < x_{tl} < x_{th} < x_{fh}$ , 当被测参数  $x$  满足  $x \in [x_{tl}, x_{th}]$  时, 判断目标为类型  $O$ , 若  $x \in [x_{fl}, x_{tl}] \cup [x_{th}, x_{fh}]$ , 则无法判断目标是否属于类型  $O$ ; 若  $x \leq x_{fl}$  或  $x \geq x_{fh}$ , 则判定目标不属于类型  $O$ . 例如观测100次, 有60次  $x$  在  $[x_{tl}, x_{th}]$  区间, 30次落在  $[x_{fl}, x_{tl}] \cup [x_{th}, x_{fh}]$  区间, 有10次  $x \leq x_{fl}$  或  $x \geq x_{fh}$ , 相当于有60票赞成, 10票反对和30票弃权, 那么目标的类型属性可以描述为  $[0.6, 0.9]$ , 有0.3的犹豫度. 由此可见, 采用 Vague 集来描述目标的属性, 不但能够知道证据对  $x$  属于  $O$  的支持程度,

还能知道反对程度和不确定程度, 其内涵比 Fuzzy 集要丰富得多<sup>[5]</sup>. 本文以 Vague 集为模型对目标属性识别, 准则度的计算一部分来自 Vague 集的3个基本参数, 另一部分来自传感器的原始测量数据和提取的特征参数.

### 1.2 决策函数

$x$  相对于  $A$  的隶属情况由三维表示  $(t_A(x), f_A(x), \pi_A(x))$ , 即用一个决策模型将数据从特征空间映射到三维决策空间. 当给出对于目标的 Vague 集属性描述后, 将要面临最终的决策. 上述合成结果仍然是一个直觉模糊数, 无法直接判定目标类型, 因此, 通常根据直觉模糊集理论中的记分函数进行最终决策. 设  $n$  个传感器  $S_i (i = 1, 2, \dots, n)$  对对象集  $O_1, O_2, \dots, O_m$  的辨识结果描述为  $(S_i, [t_{ij}, 1 - f_{ij}]) (i = 1, 2, \dots, n, j = 1, 2, \dots, m)$ , 常用计分函数为<sup>[15]</sup>

$$S_i(O_j) = t_{ij} + \pi_{ij} \frac{t_{ij}}{t_{ij} + f_{ij}}. \quad (1)$$

其中:  $[t_{ij}, 1 - f_{ij}]$  为第  $i$  个传感器对于 Vague 集  $O_j$  的 Vague 值;  $S_i(O_j)$  为传感器  $S_i$  对将目标辨认为  $O_j$  的满意程度. 当系统得到每个传感器的权重  $(w_1^*, w_2^*, \dots, w_n^*)$  后, 最终对  $O_j$  的加权辨识度为

$$u(j) = \sum_{i=1}^n w_i^* S_i(O_j), \quad \sum_{i=1}^n w_i^* = 1. \quad (2)$$

最后将辨识度最高的对象类型作为目标识别的最佳结果.

### 1.3 多准则、多级别融合框架

一个多传感器目标识别系统过程可以总结为, 对目标相关物理量的测量  $\rightarrow$  特征值提取  $\rightarrow$  目标属性的识别  $\rightarrow$  融合算法  $\rightarrow$  最终决策. 本文从不同层次的信息中提取传感器多种状态准则, 以多个指标综合评价传感器的重要性, 然后以最小化准则冗余度和最大化准则评价差异度为原则量化准则权重. 图1为基于最大化多准则熵的多传感器数据融合系统框图.

以车辆类型识别为例, 利用振动传感器、超声传感器与红外成像传感器等测量目标的振动幅度、频率和接收时间间隔等, 获得测量数据以及其统计特性, 提取出目标的重量、速度和大小等特征参数, 构成特征矢量  $(g, v, s)^T$ . 通过隶属度函数构造判决区间, 得到目标的区间隶属度 Vague 值表示, 并通过这3个层次的数据计算传感器关于各个准则的满意程度.

### 2 多评价准则

每个传感器可以通过自身数据的统计特征和与系统其他传感器数据的关系得到状态估计, 多传感器目标识别系统不同层次的数据可以反映传感器不同的状态信息. 系统以各传感器状态为准则为其分配权重. 以往大部分的文献都以单个准则的满足程度估计

传感器的可靠度,如优属度<sup>[9]</sup>、不确定度<sup>[18]</sup>、数据的冲突<sup>[19]</sup>和相异性<sup>[20]</sup>.以单一准则不能完整地反映传感器的可靠度,因为一个传感器的某个指标很差,但是另一个指标却可能很好,此时其融合权重便要折中

计算.为了方便表示,本文所有准则都为效用性准则,即准则的满足程度与传感器权重正相关.图2为多准则下的多传感器数据融合层次结构模型.

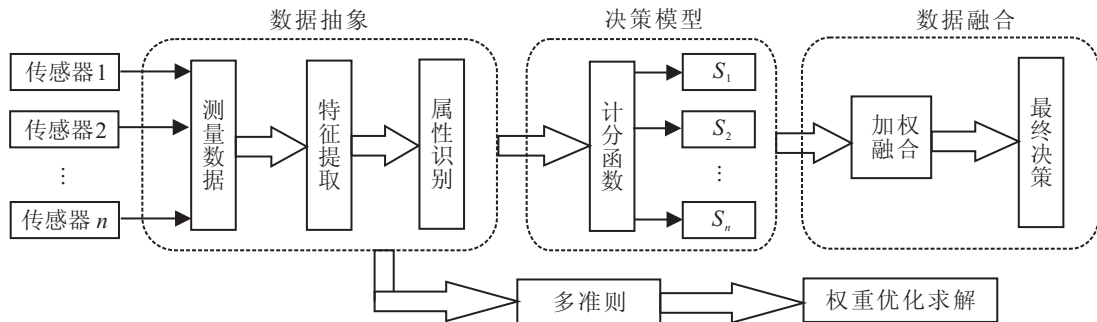


图1 多准则多级别的多传感器数据融合框架

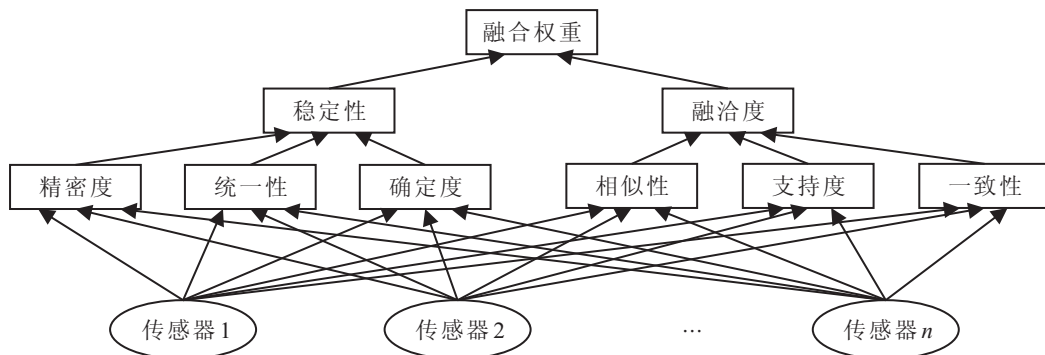


图2 多传感器数据融合层次结构

2.1 稳定性

稳定性反映了传感器对自身数据的信心程度,其稳定性越高,传感器获得的融合权重越大.一个传感器的自身稳定性体现在精密度、统一性和确定度上,分别从数据层、特征层和属性层反映传感器的信息质量.

2.1.1 精密度

精密度体现了一个传感器测量数据在时间上的一致性,反映了传感器在一段时间内的稳定程度,属于数据层范畴.为了实现测量数据的无量纲化,需要先将测量量线性映射到[0,1]区间.设一传感器的测量向量为 $(v_1, v_2, \dots, v_p)^T$ ,其测量方差向量为 $(\sigma_1^2, \sigma_2^2, \dots, \sigma_p^2)^T$ ,将测量数据线性映射到[0,1]区间,得到第 $i$  ( $i = 1, 2, \dots, p$ )个测量参数的归一化方差为

$$\begin{aligned} \varepsilon_i = & \frac{1}{k} \sum_{n=1}^k \left( \frac{v_{i,n} - v_{i,\min}}{v_{i,\max} - v_{i,\min}} - \frac{\bar{v}_i - v_{i,\min}}{v_{i,\max} - v_{i,\min}} \right)^2 = \\ & \frac{1}{(v_{i,\max} - v_{i,\min})^2} \frac{1}{k} \sum_{n=1}^k (v_{i,n} - \bar{v}_i)^2 = \\ & \frac{\sigma_i^2}{(v_{i,\max} - v_{i,\min})^2}. \end{aligned} \tag{3}$$

其中:  $k$ 为总测量次数,  $\bar{v}_i$ 为第 $i$ 个参数的平均值,  $v_{i,n}$ 为第 $i$ 个参数的第 $n$ 次测量值,  $v_{i,\max}$ 、 $v_{i,\min}$ 分别为此参数在经验下的最大可能取值和最小可能取值.以 $p$ 个测量参数的平均值作为传感器标准化方差的度量,此传感器的精密度可以表示为

$$\Pr(\varepsilon) = \exp(-K\bar{\varepsilon}), \quad \bar{\varepsilon} = \frac{1}{p} \sum_{i=1}^p \varepsilon_i. \tag{4}$$

其中:  $\Pr$ 为与传感器测量方差有关的测度,它将传感器的精密度映射到[0,1]之间,值越大表示此传感器精密度越高;调节 $K$ 可以加大精密度的对比度.

2.1.2 统一性

设目标的特征向量为 $x = (x_1, x_2, \dots, x_q)^T$ ,若传感器对目标的多个特征描述产生矛盾,即 $x_i$ 支持目标 $O_s$ ,而 $x_j$ 反对目标 $O_s$ ,则传感器将产生自我矛盾,其识别结果的可信度较低.因此,在多传感器目标识别系统的特征层设定统一性准则,其度量意义为传感器测量的内在统一性.如图3所示的特征空间内有3种目标类型 $O_1$ 、 $O_2$ 、 $O_3$ ,若传感器所得关于目标的各个特征参数指向一致,则特征点 $x$ 应靠近其中一个类型的特征中心,其与3个特征中心的距离乘积 $d_1 d_2 d_3$ 应较小;若特征点不靠近任何一类型中心,则距离乘积较大,表现为此时特征参数内部矛盾大.

基于此,在特征空间  $x \in R^q$  中,定义传感器  $S_i$  的特征统一性度量为

$$Un(i) = \frac{1}{k} \sum_{t=1}^k \exp \left( - \prod_{j=1}^m \|x_{it} - \bar{x}_j\| \right). \quad (5)$$

其中:  $k$  为测量次数,  $m$  为类型数,  $\bar{x}_j$  为第  $j$  个类型的特征中心. 式(5)将传感器  $S_i$  的特征统一性度量映射到  $[0,1]$  上,其值越接近 1 统一性越高.




图 3 特征空间

### 2.1.3 确定度

确定度是传感器对自身所做决策的确定程度. 由于信息熵本身蕴含着不确定度的大小,此处用 Vague 集的模糊熵来表示传感器对目标识别的不确定程度.

设辨识对象集为  $\{O_1, O_2, \dots, O_m\}$ , 定义  $S_i$  对  $O_j$  的辨识 Vague 值为  $[t_{ij}, 1 - f_{ij}]$ , 将 Vague 值转化为模糊集的单值隶属度<sup>[5]</sup>

$$u_{ij} = t_{ij} + \pi_{ij} \frac{t_{ij}}{t_{ij} + f_{ij}}. \quad (6)$$

其中:  $i = 1, 2, \dots, n, j = 1, 2, \dots, m$ ; 等式右边第 2 项用支持和反对者的比例来表示中立者的态度;  $(t_{ij}, f_{ij}, \pi_{ij})$  为  $S_i$  对  $O_j$  的 Vague 集识别表示. 则传感器  $S_i$  模糊熵为

$$H_i(O) = \frac{1}{m} \sum_{j=1}^m I(u_{ij}), \quad (7)$$

其中  $I(u_{ij}) = -u_{ij} \ln(u_{ij}) - (1 - u_{ij}) \ln(1 - u_{ij})$  为  $S_i$  对目标为  $O_j$  这一命题的不确定度. 若  $t_{ij} = 1$ , 则  $f_{ij} = \pi_{ij} = 0$  (传感器百分之百认为目标是  $O_j$ ) 或  $f_{ij} = 1, t_{ij} = \pi_{ij} = 0$  (传感器百分之百认为目标不是  $O_j$ ), 完全确定的情况下  $I(u_{ij}) = 0$ ; 若  $t_{ij} = f_{ij} = 0.5$ , 则  $\pi_{ij} = 0$  (模棱两可) 或  $t_{ij} = f_{ij} = 0, \pi_{ij} = 1$  (完全不确定),  $I(u_{ij}) = 1$ . 模糊熵反映传感器对目标识别结果的平均不确定度, 由余的概念可知  $S_i$  识别结果的确定度为

$$Cer(i) = 1 - H_i(O). \quad (8)$$

## 2.2 融洽度

为了获得一个传感器在空间上的可靠性, 引入融洽度准则来表示一个传感器与其他传感器和整个系统的关系. 一个传感器系统中的融洽度体现在 3 个方面:

- 1) 其特征参数与其他传感器的相似度;
- 2) 其识别结论被其他传感器的支持程度;

3) 其与系统整体决策的一致程度.

前一个是特征层准则, 后两个是决策层面的准则.

### 2.2.1 相似性

为了比较一个传感器与系统内其他传感器观测差异, 在特征层定义相似性准则. 设传感器  $S_i$  关于目标的特征向量的平均度量为

$$\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{iq})^T,$$

$\mathbf{x}_i$  长度为  $q$ . 定义两个传感器  $S_i$  和  $S_j$  之间特征向量的相似度为

$$l_{ij} = \exp \left( - \frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2} \right). \quad (9)$$

式(9)采用径向基函数将两传感器的特征向量的相似度映射到  $[0,1]$  上, 其中  $\|\mathbf{x}_i - \mathbf{x}_j\|$  为两特征向量的欧氏距离,  $\sigma$  为基宽度, 调节  $\sigma$  可以改变两传感器相似度的对比度. 当  $\mathbf{x}_i = \mathbf{x}_j$  时, 两传感器的特征度量完全相同, 相似度  $l_{ij} = 1$ . 由此可以得到多传感器的相似矩阵  $L = (l_{ij})_{n \times n}$ , 定义  $S_i$  与其他传感器的归一化平均相似度为

$$\text{Sim}(i) = \frac{\sum_{j=1}^n l_{ij}}{\sum_{i=1}^n \sum_{j=1}^n l_{ij}}. \quad (10)$$

### 2.2.2 支持度

设传感器  $S_i$  对目标的刻画程度用 Vague 集表示为  $O_1: [t_{i1}, 1 - f_{i1}], O_2: [t_{i2}, 1 - f_{i2}], \dots, O_m: [t_{im}, 1 - f_{im}]$ , 定义  $S_i$  和  $S_j$  对目标识别结果的距离为

$$d_{ij} = \frac{1}{3m} \sum_{k=1}^m ((t_{ik} - t_{jk})^2 + (f_{ik} - f_{jk})^2 + (\pi_{ik} - \pi_{jk})^2), \quad (11)$$

其中  $D = (d_{ij})_{n \times n}$  是对角为 1 的方阵, 其元素  $d_{ij}$  越大表示  $S_i$  和  $S_j$  的识别结果相差越大. 定义支持度矩阵

$$B = (b_{ij})_{n \times n} = (1 - d_{ij})_{n \times n},$$

其元素  $b_{ij}$  表示  $S_i$  与  $S_j$  互相支持的程度. 关系矩阵为非负矩阵, 由 Perron-Frobenius 定理可知, 存在最大模特征值  $\lambda > 0$ , 对应特征向量  $(a_1, a_2, \dots, a_n)^T$ . 由特征向量可得到传感器  $S_i$  其余传感器的综合支持度为

$$\text{Sup}(i) = a_i / (a_1 + a_2 + \dots + a_n). \quad (12)$$

综合支持度越大,  $S_i$  的可信度越高.

### 2.2.3 一致性

多传感器系统的优势是可以综合利用多个传感器的局部不完整信息, 使其相互补充、相互修正, 得到

较完整、较精确的对象描述. 多个传感器的综合信息一定比单个传感器可信度高, 通过比较单个传感器与总体评价的一致性, 可以得到该传感器的可信度预估, 排除异常数据. 设传感器  $S_i$  对目标的刻画为

$$\{O_1 : [t_{i1}, f_{i1}, \pi_{i1}], O_2 : [t_{i2}, f_{i2}, \pi_{i2}], \dots, O_j : [t_{ij}, f_{ij}, \pi_{ij}]\},$$

定义优矢量和次矢量<sup>[9]</sup>分别为

$$S^+ = \{O_1 : [t_1^+, f_1^-, \pi_1^-], O_2 : [t_2^+, f_2^-, \pi_2^-], \dots, O_m : [t_m^+, f_m^-, \pi_m^-]\},$$

$$S^- = \{O_1 : [t_1^-, f_1^+, \pi_1^+], O_2 : [t_2^-, f_2^+, \pi_2^+], \dots, O_m : [t_m^-, f_m^+, \pi_m^+]\}.$$

其意义为多传感器系统对目标各类型的最优描述和最保守描述, 其中

$$t_j^+ = \max(t_{ij}), t_j^- = \min(t_{ij}), i = 1, 2, \dots, n.$$

同理可得  $f_j^+, f_j^-, \pi_j^+, \pi_j^-$ . 定义传感器的优异度和次异度为

$$d(S_i, S^+) = \sqrt{\frac{1}{3m} \sum_{j=1}^m ((t_{ij} - t_j^+)^2 + (f_{ij} - f_j^-)^2 + (\pi_{ij} - \pi_j^-)^2)},$$

$$d(S_i, S^-) = \sqrt{\frac{1}{3m} \sum_{j=1}^m ((t_{ij} - t_j^-)^2 + (f_{ij} - f_j^+)^2 + (\pi_{ij} - \pi_j^+)^2)}.$$

(13)

传感器与系统整体决策的一致性应表现为: 与最优描述距离越小或与保守描述距离越远, 一致性越高, 即与优异度负相关, 与次异度正相关. 传感器一致性表示为

$$\text{Cor}(i) = \alpha d(S_i, S^-) - \beta d(S_i, S^+), \quad (14)$$

其中折中系数  $\alpha, \beta$  分别为对次矢量和优矢量的考虑偏重,  $0 \leq \alpha, \beta \leq 1, \alpha + \beta = 1$ .

### 2.3 传感器状态分类

以上从不同方面和不同层次定义了 6 个子准则: 精密度准则是测量数据在时间域上的稳定性考察, 统一性表现了数据表征在特征空间中的模糊程度, 确定度是传感器对自身决策含糊性的度量, 三者都是传感器本地状态在时间域、特征空间和决策空间的考察; 相似性准则表征的是各传感器在特征空间中的距离, 支持度准则表征的是各传感器在决策空间中的距离, 一致性准则表征的是传感器在决策空间中与整体决策的一致性, 三者都是各传感器在不同表征空间中的关系. 6 个子准则分别考察了传感器在不同维度和不同方面的性能, 具有相互补充的关系. 例如, 统一性和

相似性准则将特征在时间上的差异性用取平均值的手段弱化了, 精确度补充了传感器在时间域的统计特性, 支持度和一致性只考虑与其他传感器和整体的关系, 用这种关系来估计自身数据的可靠性, 确定度准则补充了其在决策空间中分布的可靠性. 第 1 个母准则考察的是传感器自身状态的稳定性, 其值主要受环境和目标辨识度的影响; 第 2 个母准则考察的是传感器数据的准确性, 主要受自身工艺的影响. 所以, 建立多准则的决策模型在一定程度上加强了决策的可靠性.

已知各传感器 6 个子准则的度量为 (Pr, Un, Cer, Sup, Sim, Cor), 表示为  $(c_1, c_2, \dots, c_6)^T$ , 准则向量构




图 4 3 种类型的准则分布

成的空间称为准则空间,本文提出根据传感器准则测度在准则空间中的不同分布将状态分为如下 3 类:

- 1) 故障型. 传感器的稳定性较高,但融洽度较低,即传感器数据虽然稳定,但与系统中其他传感器数据相悖,不可信,认为该传感器结构可能出现故障,如图 4(a) 所示.
- 2) 干扰型. 传感器融洽度高但稳定性低,即该传感器可能受到较大干扰,如图 4(b) 所示.
- 3) 混合型. 传感器在两个大准则下的 3 个子准则评价值各有高低,状态不确定,如图 4(c) 所示.

图 4 给出了 3 种类型的准则值分布图. 对传感器状态的分类有助于在不同环境下对传感器准则的管理与分析,进一步提高数据融合效率.

### 3 融合权重的求取

在没有决策者偏好的先验信息的情况下,很难给出准则的权系数或很难对准则的重要性进行两两比较,所以传统的主观确定方法如层次分析法(AHP)、网络分析法(ANP)和统计分析法(SAM)在此无用武之地. 在客观赋权法中,采用较多的是熵权法和主成分分析法. 对于准则权重的求取,本节以最小化准则冗余度和最大化评价对比度两个原则,建立准则权重优化模型求解最优权重向量.

#### 3.1 最小化准则冗余度

虽然上述 6 种子准则取自不同层次的不同方面,但是由于准则的约定存在主观性,各准则之间仍然存在相关性. 例如传感器对某个指标表现较好时,另一个指标值也总是很高,两个指标便具有很高的冗余度,有必要对冗余度较高的准则进行权重限制,尽量获取传感器在不同方面的满足程度信息. 由此建立准则冗余度与其权重的联系,在归一化约束下求解最优权重.

设  $n$  个传感器的标准化评价值矩阵为

$$E = (e_{ij})_{n \times m},$$

其中元素  $e$  经过了列归一化处理,即  $\sum_{i=0}^n e_{ij} = 1, \forall j$ . 矩阵的行向量  $e_i$  为每个传感器的准则测度矢量,通过对各准则的统计可以得到准则测度协方差矩阵为

$$C_{ee} = \begin{bmatrix} \sigma_1^2 & \rho_{12}\sigma_1\sigma_2 & \cdots & \rho_{1m}\sigma_1\sigma_m \\ \rho_{21}\sigma_2\sigma_1 & \sigma_2^2 & \cdots & \rho_{2m}\sigma_2\sigma_m \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{m1}\sigma_m\sigma_1 & \rho_{m2}\sigma_m\sigma_2 & \cdots & \sigma_m^2 \end{bmatrix}. \quad (15)$$

其中:  $\rho_{ij}$  为  $c_i$  与  $c_j$  的相关系数,  $\sigma_j$  为  $c_j$  的标准差. 非对角元素代表各准则之间的相关性,非对角元素的平

方和可以表示对准则总体冗余度的度量. 以冗余度为依据对各准则赋权,冗余度小的准则赋予较大的权值,最终目标为最小化总体准则冗余度. 设准则权重向量为

$$w = (w_1, w_2, \dots, w_m)^T,$$

加权后的评价矩阵为

$$R = E \times W,$$

其中  $W = \text{diag}(w)$  为对角化矩阵,相应的协方差矩阵变为

$$C_{rr} = W^T C_{ee} W = WC_{ee}W = (w_i w_j \rho_{ij} \sigma_i \sigma_j)_{m \times m}.$$

冗余度最小化目标函数为

$$\text{Re} = \|\text{offdiag}(C_{rr})\|_F^2, \quad (16)$$

其中  $\text{offdiag}(\cdot)$  为去对角操作符. 将其展开,对准则权重向量的求解转化为如下带约束优化问题:

$$\begin{aligned} \min \text{Re} &= \sum_{i \neq j} \sum_{j=1}^m (\rho_{ij} \sigma_i \sigma_j w_i w_j)^2; \\ \text{s.t.} \quad &\sum_{j=1}^m w_j = 1. \end{aligned} \quad (17)$$

其中  $\text{Re}(w)$  为凸函数,存在最优解  $w$ . 引入拉格朗日乘子将式(17)带约束优化模型转变为无约束规划问题

$$\arg \min_w J(w) = \sum_{i \neq j} \sum_{j=1}^m (\rho_{ij} \sigma_i \sigma_j w_i w_j)^2 + \lambda \left( 1 - \sum_{j=1}^m w_j \right). \quad (18)$$

将  $J(w)$  对  $w_j$  求偏导得

$$\begin{aligned} \frac{\partial J(w)}{\partial w_j} &= \sum_{k=0, k \neq j}^m (\rho_{jk} \sigma_j \sigma_k w_j w_k) \rho_{jk} \sigma_j \sigma_k w_k - \lambda = \\ &\sum_{k=0, k \neq j}^m (\rho_{jk}^2 \sigma_j^2 \sigma_k^2 w_j) - \lambda. \end{aligned} \quad (19)$$

非线性规划问题的求解相对复杂,但是由于目标函数为严格凸函数,求解过程具有较快的收敛速度,易获得全局最优解.

#### 3.2 最大化评价差异度

最大化评价差异度是以每个准则所具备的信息量为依据确定其权系数. 用熵权法确定准则权重的基本思想是利用各传感器指标的对比差异度确定准则的权重. 各传感器对某个准则的满足程度差异性越大,该准则的权重越大,反之则越小. 根据信息熵的定义,赋权后平均信息熵度量为

$$H = -\frac{1}{\ln(n)} \sum_{i=1}^n p_i \ln(p_i), \quad (20)$$

其中  $p_i = \sum_{j=1}^m w_j e_{ij}$ . 容易证明其满足归一化

$$\begin{aligned} \sum_{i=1}^n p_i &= \sum_{i=1}^n \sum_{j=1}^m w_j e_{ij} = \\ \sum_{j=1}^m \left( w_j \sum_{i=1}^n e_{ij} \right) &= \sum_{j=1}^m w_j = 1. \end{aligned}$$

以各准则的信息量为依据对其赋权值, 保证加权后的平均信息熵最大化, 即最小化目标函数  $IH = 1 - H$ , 将熵权法转化为带约束的线性规划问题

$$\begin{aligned} \min IH &= \\ 1 + \frac{1}{\ln(n)} \sum_{i=1}^n \sum_{j=1}^m w_j e_{ij} \ln \left( \sum_{j=1}^m w_j e_{ij} \right); \\ \text{s.t. } \sum_{j=1}^m w_j &= 1. \end{aligned} \quad (21)$$

引入拉格朗日乘子项将其转化为无约束规划

$$\begin{aligned} \arg \min_w J(\mathbf{w}) &= \\ 1 + \frac{1}{\ln(n)} \sum_{i=1}^n \sum_{j=1}^m w_j e_{ij} \ln \left( \sum_{j=1}^m w_j e_{ij} \right) + \\ \lambda \left( 1 - \sum_{j=1}^m w_j \right). \end{aligned} \quad (22)$$

目标函数对  $w$  求导得

$$\frac{\partial J(\mathbf{w})}{\partial w_j} = \frac{1}{\ln(n)} \sum_{i=1}^n e_{ij} \left( 1 + \sum_{j=1}^m w_j e_{ij} \right) - \lambda. \quad (23)$$

线性规划问题相对易求解, 权重向量  $w$  可以通过求解线性方程组得到.

### 3.3 传感器融合权重的综合求取

信源的质量受各种因素的影响, 而多传感器系统可以表示为一个有限集合, 所以必然存在一种权重分配可以使融合结果最佳地逼近真实结果, 投票型决策的目标是求解这种真实的权重分配, 分配必须避免主观性、片面性和偶然性. 利用多准则评价针对决策的片面性, 从不同方面和角度定义不同准则针对的是决策的偶然性, 以评价信息量衡量准则权重针对的是决策的主观性.

为了定量地提高多准则信息量, 同时考虑最小化准则冗余度和最大化评价差异度, 将准则权重的求取转化为如下多目标优化问题:

$$\begin{aligned} \min J(\mathbf{w}) &= Re(\mathbf{w}) + uIH(\mathbf{w}); \\ \text{s.t. } \sum_{j=1}^m w_j &= 1. \end{aligned} \quad (24)$$

其中  $u$  为控制比例参数, 在没有决策者偏好信息的情况下可取  $u = 1$ . 将其转化为无约束规划为

$$\arg \min_w J(\mathbf{w}) =$$

$$Re(\mathbf{w}) + uIH(\mathbf{w}) + \lambda \left( 1 - \sum_{j=1}^m w_j \right). \quad (25)$$

目标函数仍然是凸函数, 所以本文选择随机梯度下降法对其进行优化. 解出最优准则权重向量后, 各传感器的融合权重为在该准则权重下的加权平均评价, 即

$$w_i^* = \sum_{j=1}^m w_j e_{ij}, \quad i = 1, 2, \dots, n. \quad (26)$$

## 4 仿真实验结果与分析

为了体现本文所提出算法的融合性能, 以一个简化的目标识别剧本作为仿真算例. 假设有 5 个传感器参与感知, 其探测数据可以被记录. 目标集为  $\Omega = O_1, O_2, O_3$ , 真实目标为  $O_2$ , 5 个传感器归一化均方差  $\varepsilon$  分别为 0.012、0.017、0.023、0.015、0.008. 以此方差做 100 次测量对特征参数做统计, 得到 Vague 集属性测度如表 1 所示, 6 个子准则的标准化评价如表 2 所示, 各项参数选取为  $K = 0.01$ ,  $\sigma = 0.5$ ,  $\alpha = 0.8$ ,  $\beta = 0.2$ .

表 1 目标识别 Vague 集数据

	$S_1$	$S_2$	$S_3$	$S_4$	$S_5$
$O_1$	[0.12,0.35]	[0.13,0.33]	[0.12,0.24]	[0.08,0.29]	[0.16,0.52]
$O_2$	[0.74,0.96]	[0.56,0.76]	[0.48,0.67]	[0.55,0.79]	[0.94,0.98]
$O_3$	[0.14,0.42]	[0.18,0.37]	[0.18,0.36]	[0.13,0.46]	[0.15,0.69]

表 2 标准化准则评价

	$e_{i1}$	$e_{i2}$	$e_{i3}$	$e_{i4}$	$e_{i5}$	$e_{i6}$
$S_1$	0.2238	0.1547	0.1772	0.2124	0.1718	0.1924
$S_2$	0.1718	0.2615	0.2195	0.1432	0.1915	0.1731
$S_3$	0.1275	0.1083	0.2116	0.1672	0.2124	0.1823
$S_4$	0.1827	0.1842	0.2281	0.2263	0.1956	0.1953
$S_5$	0.2942	0.2913	0.1636	0.2509	0.2287	0.2569

由表 1 和表 2 可见, 传感器  $S_5$  对目标的识别度最高, 要想得到对目标的高度识别必须给  $S_5$  赋予较高的权重. 但由表 2 可见, 对于每个指标传感器,  $S_5$  表现出不同程度的优势, 而对确定度准则  $c_3$  的满足度却是最差的, 这是由于  $S_5$  对目标为  $O_1$  和  $O_3$  的识别非常含糊, 导致其整体确定度较低, 所以以单准则的融合有很大可能性存在偏差, 这是因为单准则的选取过于片面.

将表 2 中的数据代入式 (25) 的优化模型中求解准则的权重, 得到 6 个准则的权重向量为

$$\mathbf{w} = (0.2633, 0.2515, 0.1091, 0.1568, 0.0697, 0.1496)^T.$$

再由式 (26) 可得 5 个传感器的综合权重向量为

$$\mathbf{w}^* = (0.1912, 0.1967, 0.1522, 0.1977, 0.2623)^T,$$

由此得到系统最终融合结果如表 3 所示. 其对 3 个目标类型的识别度均为归一化后的识别度,  $O_2$  的归一化融合识别度 0.7360 为最高, 所以目标识别结果为  $O_2$ . 与文献 [5,10] 的归一化识别度作对比, 虽然 3 种方法的识别结果都为  $O_2$ , 但本文识别度较后两者均有提高, 在一定程度上降低了决策风险. 文献 [9] 采用决策层单一准则 (优属度), 具有片面性. 文献 [14] 的 6 个子准则全部取自决策层, 从准则权重向量中可以看出, 决策层的准则权重较低, 这反映决策层的信息量相对较少, 所以单纯用决策层的准则无法得到最佳决策.

表 3 归一化识别度

目标类型	$O_1$	$O_2$	$O_3$
$S_1$	0.0889	0.8022	0.1090
$S_2$	0.1337	0.6810	0.1854
$S_3$	0.1348	0.6481	0.2171
$S_4$	0.0877	0.7524	0.1600
$S_5$	0.1120	0.7678	0.1202
融合结果	0.1105	0.7360	0.1535
文献 [9]	0.0658	0.5683	0.3659
文献 [14]	0.1327	0.6814	0.1859

改变环境和传感器状态进行多次实验, 结果如图 5 所示. 不同准则具有不同程度的优势, 单准则的融合结果受环境和传感器状态影响较大. 文献 [9] 的结果波动性很大, 存在偶然性, 若选取的准则对识别度高的传感器有利, 则会得到很高的识别度; 如果选取准则不利, 则融合后的识别结果较差. 多准则下的融合结果较稳定, 而本文对准则冗余度和评价差异度多目标优化的结果具有最平稳的识别度.




图 5 决策稳定性对比

为了显示本文方法的融合性能, 将其与传统的多准则决策方法作对比, 使用同一目标观测其在相同环境参数下的目标识别准确率, 依次增加准则数量考察决策的全面性带来的影响. 以 100 次实验的平均识别错误率为观察指标, 且所有方法的准则测度都是一致的, 只有权重求解算法的区别, 结果如图 6 所示. 仿真实验结果显示, 随着准则数量的增加, 多传感器目标

识别融合的错误率降低, 本文提出的方法具有最低的错误率和最高的鲁棒性.




图 6 多准则决策抗风险示意图

## 5 结 论

针对多传感器目标识别的数据融合, 在决策层采用 Vague 集 的表示方式能得到更多的决策信息. 单一准则的选取具有主观片面性, 若选取的准则恰好不利于识别度高的传感器, 则融合结果较差, 存在一定的风险. 相比而言, 多准则、多层次的数据融合方法具有更强的客观性、全面性和必然性, 能够建立更真实的多准则决策模型. 对各准则进行相关性分析和评价差异度分析, 以最小化准则冗余度和最大化评价差异度为目标, 建立多目标优化模型, 求解准则权重向量, 以获取最真实的准则权系数分配. 仿真实验对所提出算法性能的稳定性和识别度作了评估, 结果显示, 融合后的决策结果偏向识别度高的传感器, 并且相比于单准则和单层次的融合方法在稳定性和识别度上均有所提高, 这是因为后两者使用的恰巧是不利于识别度较高的传感器准则和信息量相对较少的决策层, 所以所提出方法能够降低决策风险, 具有更高的鲁棒性.

## 参考文献(References)

- [1] Guo D, Wang X D. Dynamic sensor collaboration via sequential montecarlo[J]. IEEE J on Selected Areas in Communications, 2004, 22(6): 1037-1047.
- [2] Hall D L, Llinas J. An introduction to multisensor data fusion[J]. Proc of the IEEE, 1997, 85(1): 6-23.
- [3] Wen C L. Multiscale datafusion for multi-sensor single model dynamic systems[J]. Acta Electronica Sinica, 2001, 29(3): 341-345.
- [4] Shuping Wan. Applying interval-value vague set for multi-sensor target recognition[J]. Int J of Innovative Computing, Information and Control, 2011, 7(2): 955-964.
- [5] 万树平. 基于 Vague 集的多传感器目标识别方法[J]. 控制与决策, 2009, 24(7): 1097-1100.  
(Wan S P. Method based on Vague set for multi-sensor object recognition[J]. Control and Decision, 2009, 24(7): 1097-1100.)

- [6] Shuping Wan. Triangular fuzzy number method for robot non-vision multi-sensor fusion[J]. *Innovative Computing Information and Control-Express Letters*, 2010, 4(3): 857-862.
- [7] 万树平. 不确定多传感器目标识别的区间相离度法[J]. *控制与决策*, 2009, 24(9): 1036-1039.  
(Wan S P. Method of interval deviation degree for uncertain multi-sensor target recognition[J]. *Control and Decision*, 2009, 24(9): 1036-1039.)
- [8] 黄瑛, 陶云刚, 周洁敏, 等. D-S 证据理论在多传感器数据融合中的应用[J]. *南京航空航天大学学报*, 1999, 31(2): 172-178.  
(Huang Y, Tao Y G, Zhou J M, et al. Implementation of D-S evidential theory in multisensor data fusion system[J]. 1999, 31(2): 172-178.)
- [9] 万树平. 不确定多传感器目标识别的 Vague 集法[J]. *兵工学报*, 2010, 31(6): 802-806.  
(Wan S P. Vague set method for uncertain multi-sensor object recognition[J]. *Acta Armamentar II*, 2010, 31(6): 802-806.)
- [10] 刘同明. 基于证据理论模糊推理的多传感器信息融合海上目标识别[J]. *模式识别与人工智能*, 1999, 12(1): 25-31.  
(Liu T M. Surface target recognition based on evidence theory, fuzzy inference and multisensor information fusion[J]. *Pattern Recognition and Artificial Intelligence*, 1993, 12(1): 25-31.)
- [11] 耿涛, 卢广山, 张安. 基于直觉模糊证据合成的多传感器目标识别[J]. *控制与决策*, 2012, 27(11): 1725-1734.  
(Geng T, Lu G S, Zhang A. Intuitionistic fuzzy evidence combination algorithm for multi-sensor target recognition[J]. *Control and Decision*, 2012, 27(11): 1725-1734.)
- [12] 蒲书缙, 杨莘元, 赵忠凯, 等. 一种复杂环境下的多传感器目标识别系统[J]. *兵工学报*, 2006, 27(3): 418-421.  
(Pu S J, Yang S Y, Zhao Z K, et al. A multi-sensor target recognition system in the complex interference environment[J]. *Acta Armamentar II*, 2006, 27(3): 418-421.)
- [13] 蓝金辉, 马宝华, 李有文, 等. 层次分析法用于多传感器数据融合中属性权的求取[J]. *兵工学报*, 2001, 22(1): 74-77.  
(Lan J H, Ma B H, Li Y W, et al. Acquiring attribute weight of multisensor data fusion by ahp[J]. *Acta Armamentar II*, 2001, 22(1): 74-77.)
- [14] Ahmed Frikha, Hela Moalla. Analytic hierarchy process for multi-sensor data fusion based on belief function theory[J]. *European J of Operational Research*, 2015(241): 133-147.
- [15] Chen L H, Tu C C. Dominance-based ranking functions for interval-valued intuitionistic fuzzy sets[J]. *IEEE Trans on System, Man, and Cybern*, 2014, 44(8): 1269-1282.
- [16] Gau W L, Buehrer D J. Vague sets[J]. *IEEE Trans on System, Man, and Cybern*, 1993, 23(2): 610-614.
- [17] Zhang L, Lu Y, Chen Y, et al. Robust uniformly ultimate boundedness control for uncertain switched linear systems[J]. *Computers and Mathematics with Applications*, 2008, 56(7): 1709-1714.
- [18] Lin Sun, Jiucheng Xu. Feature selection using mutual information based uncertainty measures for tumor classification[J]. *Bio-Medical Materials and Engineering*, 2014, 24(1): 763-770.
- [19] Liu W. Analyzing the degree of conflict among belief functions[J]. *Artificial Intelligence*, 2006, 170(11): 909-924.
- [20] Liu Z, Dezert J, Pan Q. et al. Combination of sources of evidence with different discounting factors based on a new dissimilarity measure[J]. *Decision Support System*, 2011, 52(1): 133-141.
- [21] 姬东朝, 宋笔锋, 喻天翔. 基于模糊层次分析法的决策方法及其应用[J]. *火力与指挥控制*, 2007, 32(11): 107-113.  
(Ji D C, Song B F, Yu T X. The method of decision-making based on fahp and its application[J]. *Fire Control and Command Control*, 2007, 32(11): 107-113.)
- [22] 李凡, 吕泽华, 蔡立晶. 基于 Fuzzy 集的 Vague 集的模糊熵[J]. *华中科技大学学报: 自然科学版*, 2003, 31(1): 30-31.  
(Li F, Lü Z H, Cai L J. The entropy of Vague sets based on Fuzzy sets[J]. *J of Huazhong University of Science & Technology: Nature Science Edition*, 2003, 31(1): 30-31.)

(责任编辑: 郑晓蕾)