

联合信度推理证据网参数学习

李 贤¹, 陈志刚¹, 徐世友², 井沛良²

(1. 中南大学 信息科学与工程学院, 长沙 410083; 2. 国防科技大学 ATR重点实验室, 长沙 410073)

摘 要: 证据网络是证据理论的层次化推广, 联合信任测度是证据网络中的一种推理方法, 推理参数一般由专家经验给出. 为了更准确地获得参数, 提出一种将冲突大小作为评价函数, 利用格雷编码遗传算法, 通过评价输入来自动获取优化参数的方法. 以机载多传感器平台为例的仿真实验表明, 所提出方法的融合识别性能优于专家知识设定参数的方法, 而且初始种群数量越大, 越能获得好的识别结果.

关键词: 证据网; 联合信任测度; 格雷编码; 遗传算法

中图分类号: TP391

文献标志码: A

Parameters learning in evidential network deducing using unite-believe value

LI Xian¹, CHEN Zhi-gang¹, XU Shi-you², JING Pei-liang²

(1. School of Information Science and Engineering, Central South University, Changsha 410083, China; 2. ATR Key Laboratory, National University of Defense Technology, Changsha 410073, China. Correspondent: LI Xian, E-mail: lx20010@gmail.com)

Abstract: Evidential network is a reasoning model extend from Demspter-Shafer(DS) theory. Unite-believe value(UBV) is a way of deducing in evidential network. In a general way, the parameters in the deduction are given by expert knowledge. A method of getting optimized parameters automatically is presented. In which the value of conflict is used as adjudge function and the genetic algorithm based on gray code is used. The simulation experiment shows that the result of the proposed method is more accurate than the result of the method using the parameters given by expert knowledge in emulation, and the more population at beginning, the better accuracy of the recognition result.

Key words: evidential network; unite believe value; gray code; genetic algorithm

0 引 言

证据网(EN)^[1-3]是一种证据理论与图论相结合的有向无环图模型^[4], 由变量节点、连接节点的有向边和节点间关系3部分组成, 在满意度评估^[5]、目标威胁评估^[6]、智能控制^[7]以及诊断护理^[8]等方面得到了大量应用.

目前, 实现证据网推理的手段主要包括条件信任证据网推理、联合信任证据网推理和信度规则证据网推理^[9-10]. 对于推理中所需的参数, 条件信任证据网推理、联合信任证据网推理方法均是通过专家经验给出^[9], 因此融合推理的性能依赖于专家知识; 信度规则证据网推理虽然是通过参数学习获取相关参数^[10], 但是这种学习是基于训练样本的学习, 而现实中很多情况下并不能提供足够数量的样本数据, 因此, 如何

在不利用训练样本的情况下实现参数的在线学习, 无疑具有重要的现实意义.

本文以机载平台的多传感器目标综合识别问题为例, 提出一种将冲突大小作为评价函数, 利用格雷编码遗传算法实现参数在线学习的方法.

1 证据网联合推理及构建

1.1 证据网络的联合信任推理

联合信任证据网推理方法中信息的传递操作主要包括两类.

1) 扩张操作, 即由低维变量的信任测度推知高维变量的信任测度, 包括 M 扩展和 B 扩展.

定义 1 (M 扩展) 设有两个辨识框架, 分别为

$$X = \{x_1, x_2, \dots, x_M\}, Y = \{y_1, y_2, \dots, y_N\},$$

收稿日期: 2013-06-19; 修回日期: 2013-10-04.

基金项目: 国家自然科学基金项目(61073186, 61379057); 教育部博士点基金优先发展领域课题(20120162130008).

作者简介: 李贤(1982-), 男, 博士生, 从事数据挖掘、目标识别、信息融合的研究; 陈志刚(1964-), 男, 教授, 博士生导师, 从事传感器分布式网络、智能信息处理等研究.

其中 M 和 N 均为大于等于 2 的正整数, 在这两个辨识框架上的基本信任分配记为 m_X 和 m_Y , 它们的乘积空间为 $X \times Y$, 其上的信任分配记为 $m_{X \times Y}$. 从 m_X 到 $m_{X \times Y}$ 的 M 扩张是一个定义在 $X \times Y$ 上的基本信任函数, 即

$$m_X^{\uparrow\{X,Y\}}(B) = \begin{cases} m_X(A) & B = AY, A \subseteq X; \\ 0, & \text{其他.} \end{cases} \quad (1)$$

定义 2 (B 扩展) 设 $\text{Bel}_X(x)$ 是给定 $x \subseteq X$ 时, X 上的信任函数, 则 $\text{Bel}_X(x)$ 在 $X \times Y$ 上 B 扩展得到信任函数, 定义为

$$\begin{aligned} \text{Bel}_X(x)^{\uparrow X \times Y} &= \left[\sum_{B \subset x} m(B) \right]^{\uparrow X \times Y} = \\ & \left[\sum_{(B,y) \subset (x,Y)} m(B,y) \right]^{\uparrow X \times Y} = \\ & \text{Bel}_{X \times Y}(x, Y). \end{aligned} \quad (2)$$

2) 边缘化操作, 即由高维度辨识框架下的信任测度推知低维度辨识框架下的信任测度, 包括 M 边缘化和 B 边缘化.

定义 3 (M 边缘化) 设 m_X 是 X 上的基本信任分配, $Y \subseteq X, Y \neq \varphi, m$ 在 Y 上边缘化操作表示成 $m_X^{\downarrow Y}$, 即

$$m_X^{\downarrow Y}(y) = \sum_{x \in X, X^{\downarrow Y} = y} m_X(x), y \in Y. \quad (3)$$

定义 4 (B 边缘化) 设信任函数 $\text{Bel}_{X \times Y}^{\downarrow X}(x)$ 是 $\text{Bel}_{X \times Y}$ 在 X 上的边缘信任函数, 则有

$$\text{Bel}_{X \times Y}^{\downarrow X}(x) = \text{Bel}_{X \times Y}(x, Y). \quad (4)$$

联合信任测度是证据网络实现不同辨识框架间信息传递、转换的关键, 直接影响着证据合成的合理性、正确性. 联合信任测度由两个不同的辨识框架中的焦元值共同决定, 显然联合信任测度是一种离散分布.

1.2 机载平台下目标类型识别证据网络构建

现代先进战机具有强大的信息处理能力, 特别是多源信息的综合处理能力, 能够通过多种传感器对目标进行综合识别. 利用证据网进行多源识别信息融合具有以下优点: 1) 信度分配不是点函数而是一种集合函数; 2) 不需要进行先验概率的设置, 便于建模, 可以有效利用合成规则组合多个证据; 3) 对知识缺乏产生的无知可以准确表达; 4) 随着证据信息的不断增加, 不断收敛可行解空间, 从而得出一致的结果. 因此, 利用证据网进行机载多传感器识别信息融合具有较好效果.

目标信息可通过具备获取目标速度、形状、电磁辐射源特性等的传感器获取, 机载传感器可获取的典型目标信息如表 1 所示. 采用中心-辐射的构造方式,

以目标类型为中心构建证据网络, 针对具体情况调整边的方向. 所构建的机载平台下的证据网络模型如图 1 所示.

表 1 传感器识别信息

传感器	识别信息
HRRP	目标类型: J10、SU27、F16、F15、HY2000、A320、737 目标机动速度: 高、中、低
Maneuver	高速目标速度范围 ≥ 1200 km/h 中速目标速度范围 [400, 1200] km/h 低速目标速度范围 [0, 400] km/h
IR	目标类型: J10、SU27、F16、F15、HY2000、A320、737
ESM	辐射源类型: 1473、N001、AGP68、AGP63、RDY2、WXR700X




图 1 机载平台下的证据网络模型

1.3 模型中参数设定

证据网模型的联合信任测度一般根据专家知识以一种离散方式给出, 例如 Maneuver 和 Target type 节点的联合信任测度可以表示为表 2 的形式.

表 2 Maneuver 和 Target type 节点的联合信任测度

指标	J10	SU27	F16	F15	HY2000	A320	737
高	0.6	0.8	0.6	0.8	0.6	0	0
中	0.4	0.2	0.4	0.2	0.4	0.2	0.2
低	0	0	0	0	0	0.8	0.8

对于一些不确定的测度, 可通过未知参数表达, 如 $m(\text{J10, 高}) = x_1$ 和 $m(\text{J10, 高}) = 1 - x_1$, 如何确定这样的参数是本文要研究的问题. 解决这一问题主要有两种思路: 一是借鉴贝叶斯网的参数学习, 利用最大似然估计、贝叶斯估计方法, 但这种方法需要大量的样板数据进行训练, 而在实际的机载目标识别中, 识别样本数据本身是很难得到的, 其实用性受到很大的限制; 另一种思路是基于某种不包含结果样本的评价准则来计算最优参数值.

因为冲突的大小可以被视为对融合结果优劣的一个评判, 所以将冲突大小作为评价标准是一个合理的选择, 避免了融合结果的直接参与, 从而避免了对训练样本的要求. 在选定评价标准后, 如何通过评价标准来选择合适的参数是所面临的主要问题. 基于输入来选择参数显然是一个 NP 问题, 同样也是一个多参数优化问题, 解决这类问题的典型方法有爬山法、退火模型、遗传算法等. 其中遗传算法具有对可行解表示的广泛性、群体搜索特性、不易陷入局部最优和可并行计算等优势, 尤其是群体搜索的特点, 可

使整个搜索不容易收敛到单峰极值点. 采用遗传算法对证据网进行参数优化, 相比专家经验给出参数的方法, 能在全局根据输入情况自动优化选择参数. 下面将详细介绍此方法以及对比实验和结果分析.

2 参数的格雷码遗传算法优化

遗传算法是一类借鉴生物界的进化规律演化而来的随机化搜索方法^[11-12]. 本文采用遗传算法解决可靠性优化问题, 算法实现流程如图 2 所示.

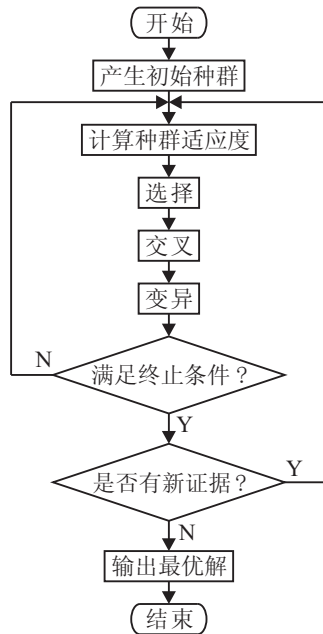


图 2 算法流程

2.1 格雷编码

编码主要是针对染色体的编码. 本文中一条染色体由多个基因组成, 一个基因代表一个参数, 设 c 表示一条染色体, α_i^j 为传感器 i 中的第 j 个参数, α_i^j 就是一个基因. 一共有 h 个传感器, 即 $i \leq h$, 则染色体表示为 $c = \alpha_1^1 \cdots \alpha_1^j \alpha_2^1 \cdots \alpha_2^j \cdots \alpha_h^1 \cdots \alpha_h^j$.

为了提高算法的局部搜索能力, 便于交叉、距离度量的实现, 基因 α_i^j 的编码采用格雷编码^[13-14]. 格雷编码是二进制编码的一种变形, 二进制编码以及相对应的格雷编码分别表示如下:

$$\begin{cases} g_l = a_l, \\ g_i = a_{i+1} \oplus a_i, \quad i = l-1, l-2, \dots, 1; \end{cases} \quad (5)$$

$$\begin{cases} a_l = g_l, \\ a_i = a_{i+1} \oplus g_i, \quad i = l-1, l-2, \dots, 1. \end{cases} \quad (6)$$

格雷编码的精度与二进制编码一致, 即

$$\delta = \frac{U_{\max} - U_{\min}}{2^l - 1}. \quad (7)$$

格雷编码的解码公式为

$$x = U_{\min} + \left[g_l 2^{l-1} + \right.$$

$$\left. \sum_{i=1}^{l-1} (g_l \oplus g_{l-1} \oplus \cdots \oplus g_i) \right] 2^{i-1} \frac{U_{\max} - U_{\min}}{2^l - 1}. \quad (8)$$

2.2 初始种群选择

初始种群的设定会最终影响遗传算法的执行效率及执行的效果. 如果规模太小, 则优化性能可能不好; 如果规模太大, 则虽然可以减少陷入局部最小的可能性, 但计算的复杂度会增高. 一般而言, 种群规模最优范围为 [20, 100].

2.3 适应度函数设计

设 l 为融合节点, n 为在此融合节点处融合的子节点个数. 不妨将这 n 个节点从 1 到 n 进行编号, a 和 b 表示这 n 个子节点中两个不相等的节点, K_{ab} 为 a 与 b 两节点融合时所产生的冲突, $f_l(n)$ 表示 l 节点处所产生的冲突, 可表示为

$$f_l(n) = \sum_{a,b \in \{1,2,\dots,n\}, a \neq b} K_{ab}. \quad (9)$$

设 θ 为识别的框架, φ 表示焦点为空的集合. a 节点的焦点为 $A_1, \dots, A_k, A_i \in \{A_1, \dots, A_k\}$, $m(A_i)$ 为 A_i 的基本概率分配, $m(A_i)|_{m_{a-l}}$ 表示 $m(A_i)$ 在 m_{a-l} 联合信任测度下向节点 l 映射的信度; b 节点的焦点为 $B_1 \cdots B_r, B_j \in \{B_1, \dots, B_r\}$, $m(B_j)$ 为 B_j 的基本概率分配, $m(B_j)|_{m_{b-l}}$ 表示 $m(B_j)$ 在 m_{b-l} 联合信任测度下向节点 l 映射的信度. α_a 表示节点 a 的可靠性, α_b 表示节点 b 的可靠性, 根据式 (9), $f_l(n)$ 可展开表示为

$$f_l(n) = \sum_{a,b \in \{1,2,\dots,n\}, a \neq b} K_{ab} = \sum_{a,b \in \{1,2,\dots,n\}, a \neq b} \left\{ \sum_{A_i \cap B_j = \varphi, A_i, B_j! = \theta} \alpha_a \times m_a(A_i)|_{m_{a-l}} \alpha_b m_b(B_j)|_{m_{b-l}} + \alpha_a m_a(A_i)|_{m_{a-l}} [(1 - \alpha_b) + \alpha_b m_b(\theta)|_{m_{b-l}}] + \alpha_b m_b(B_j)|_{m_{b-l}} [(1 - \alpha_a) + \alpha_a m_a(\theta)|_{m_{a-l}}] + [(1 - \alpha_b) + \alpha_b m_b(\theta)|_{m_{b-l}}] [(1 - \alpha_a) + \alpha_a m_a(\theta)|_{m_{a-l}}] \right\}. \quad (10)$$

设 L 为融合节点集合, 即 $l \in L$, $F_{\text{conflict}}(l, n)$ 表示整个证据网络的冲突, 可表示为

$$F_{\text{conflict}}(l, n), \quad (11)$$

则可通过评价一条染色体在融合节点处产生冲突的大小来评价这个染色体的好坏, 即

$$F_{\text{fitness}}(c) = \frac{1}{F_{\text{conflict}}(l, n)}. \quad (12)$$

2.4 选择

若 m 表示种群的大小, F_i 表示第 i 个染色体的适应度, 则第 i 个染色体被选中的概率为

$$P_i = \frac{F_i}{\sum_{i=1}^M F_i}, \quad i = 1, 2, \dots, M. \quad (13)$$

2.5 交 叉

设两个染色体中同位置的两个基因为 g_l 和 h_l , 其格雷码海明距离为 $U_h = |g_l - h_l|$, 基因的最大格雷码海明距离为 U_{max} , 则这个位置的交叉概率为

$$P_{cross} = \frac{U_h}{U_{max}} = \frac{|g_l - h_l|}{U_{max}}, \quad (14)$$

$$F_{fitness}(c) = \frac{1}{F_{conflict}(l, n)}. \quad (15)$$

2.6 变 异

本文采用均匀变异. 所谓均匀变异是指用某个范围的数来代替被选中的基因, 这个数是随机产生的均匀分布的数. 若范围为 $[U_{min}^k, U_{max}^k]$, 则替代基因为

$$g_k = U_{min}^k + r(U_{max}^k - U_{min}^k), \quad (16)$$

其中 r 均匀分布于 $[0, 1]$.

2.7 结 束

当一批证据来到后, 训练结束条件为

$$\begin{cases} |C| > K; \\ f_{fitness}(c) > P, \forall c \in C. \end{cases} \quad (17)$$

其中: $P = 4$ 为适应度阈值, 表示融合节点产生的冲突要小于 0.25; C 为染色体集合, $|C|$ 表示 C 的基, c 为 C 中的一个元素; K 为染色体个数阈值, 其取值为种群数的一半, 即达到适应度的种群个数为起始种群的一半即可. 当不满足式 (17) 时, 则应满足

$$m > M. \quad (18)$$

其中: m 为迭代次数; M 为迭代次数阈值, 其取值为 1 000.

3 实验及结果分析

设定 HRRP 对 J 10、F 16、HY 2000 的识别存在混淆, 期望通过设定参数并进行训练得出合理值. HRRP 参数化后联合测度设定如表 3 所示.

表 3 HRRP 参数化后联合测度

型号	J 10	SU 27	F 16	F 15	HY 2000	A 320	737
J10	x_1	0	x_2	0	$(1 - x_3)/2$	0	0
SU27	0	0.65	0	0.4	0	0	0
F16	x_1	0	x_2	0	$(1 - x_3)/2$	0	0
F15	0	0.4	0	0.65	0	0	0
HY2000	$1 - x_1 - x_2$	0	$1 - x_1 - x_2$	0	x_3	0	0
A320	0	0	0	0	0	0.5	0.5
737	0	0	0	0	0	0.5	0.5

表 4 IR 参数化后联合测度

型号	J 10	SU 27	F 16	F 15	HY 2000	A 320	737
J10	x_4	0	x_5	0	0.2	0	0
SU27	0	0.65	0	0.35	0	0	0
F16	$1 - x_4$	0	$1 - x_5$	0	0.2	0	0
F15	0	0.35	0	0.65	0	0	0
HY2000	0	0	0	0	0.6	0	0
A320	0	0	0	0	0	0.5	0.5
737	0	0	0	0	0	0.5	0.5

设定 IR 对 J 10、HY 2000 的识别存在混淆, 但不是对等混淆, 期望通过设定参数并进行训练得出合理值. IR 参数化后联合测度设定如表 4 所示.

设定 Maneuver 对 J 10 识别是参数化的, Maneuver 参数化后联合测度专家设定如表 5 所示.

表 5 Maneuver 参数化后联合测度

指标	J 10	SU 27	F 16	F 15	HY 2000	A 320	737
高	x_6	0.8	0.6	0.8	0.6	0	0
中	$1 - x_6$	0.2	0.4	0.2	0.4	0.2	0.2
低	0	0	0	0	0	0.8	0.8

设定 ESM 没有未知参数, 其联合测度全由专家给定, 如表 6 所示.

表 6 ESM 联合测度

型号	J 10	SU 27	F 16	F 15	HY 2000	A 320	737
1473	1	0	0	0	0	0	0
N001	0	1	0	0	0	0	0
AGP68	0	0	1	0	0	0	0
AGP63	0	0	0	1	0	0	0
RDY2	0	0	0	0	0	1	0
WXR700X	0	0	0	0	0	0.5	0.5

实验 1 在根据专家先验知识设定参数的方法 M1 下, 认为 HRRP 对 J 10、F 16、HY 2000 的识别存在对等混淆, 即这 3 类目标中任何一个目标被识别正确或识别成其他目标的概率都是相等的, 则 $x_1 = x_2 = x_3 = 0.33$; IR 对 J 10、HY 2000 的识别存在对等混淆, 即 $x_4 = x_5 = 0.5$; Maneuver 中 $x_6 = 0.5$, 起始种群数设为 20、40、60 训练出来的识别结果与 M1 方法进行对比, 结果如图 3 所示.




图 3 种群数与识别率关系

从图 3 可以看出, 通过实验后的识别率都普遍好于 M1. 这是因为专家经验在 HRRP 的设置下认为对目标 J 10、F 16、HY 2000 没有识别能力. 实际上, 对于目标 J 10, HRRP 的识别基本上都是正确的, 与专家经验不符, 从而训练参数的融合结果必然好于专家经验指定参数的融合结果.

初始种群数越多, 意味着搜索越能在全局进行, 得到最优结果的可能性越大, 从图 3 也能得出这样的结论.

实验 2 设定种群数量为 50, 通过本文方法 (UBV-Learning) 训练后融合与根据专家知识设定参数融合方法 M1 融合的时间对比如图 4 所示。




图 4 种群数与识别率的关系

从图 4 可以看出, UBV-Learning 由于有训练参数过程, 在时间上远远大于 M1。但是, 一旦参数训练完毕, 则模型即确定下来, 此时 UBV-Learning 与 M1 的时间相差不大, 只有通过证据合成规则进行计算的时间, 不再有训练模型的时间, 而且从实验 1 也可以看出, 这时 UBV-Learning 的融合结果好于 M1。

4 结 论

联合信任推理证据网络中的参数一般是由专家经验给出。本文引入了一种自适应、自学习的方法获得参数, 将冲突最小化作为评价函数, 通过格雷编码的遗传算法进行网络参数优化, 可以得到比专家经验更优的参数值。最后, 在车载多传感器平台下, 通过将不同种群数目下得到的参数对应的识别率与专家设定参数对应的识别率进行对比, 验证了本文方法的优越性。

参考文献(References)

[1] Dempster A P. Upper and lower probabilities induced by a multi-valued mapping[J]. *Annals of Mathematical Statistics*, 1967, 38(2): 325-339.

[2] Smets P. The combination of evidence in the transferable belief model[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1990, 12(5): 447-458.

[3] Xu H, Smets P. Reasoning in evidential networks with conditional belief functions[J]. *Int J of Approximate Reasoning*, 1996, 14(2/3): 155-185.

[4] Attoh-Okine N O. Aggregating evidence in pavement management decision-making using belief functions and qualitative Markov tree[J]. *IEEE Trans on Systems, Man and Cybernetics, Part C—Applications and Reviews*, 2002, 32(3): 243-251.

[5] Narayanan V K, Armstrong D J. Causal mapping for information systems and technology research: Approaches, advances and illustrations[M]. Hershey: Idea Group, Inc, 2005: 109-141.

[6] Benavoli A, Ristic B, Farina A, et al. An application of evidential networks to threat assessment[J]. *IEEE Trans on Aerospace and Electronic Systems* 2009, 45(2): 620-639.

[7] Hong X, Nugent C, Mulvenna M, et al. Evidential fusion of sensor data for activity recognition in smart homes[J]. *Pervasive and Mobile Computing*, 2009, 5(3): 236-252.

[8] Lee H, Choi J S, Elmasri R. A static evidential network for context reasoning in home-based care[J]. *IEEE Trans on Systems, Man and Cybernetics, Part A—Systems and Humans*, 2010, 40(6): 1232-1243.

[9] Cano J, Delgado M, Moral S. An axiomatic framework for propagation uncertainty in directed acyclic networks[J]. *Int J of Approximate Reasoning*, 1993, 8(4): 253-280.

[10] 姜江. 证据网络建模、推理及学习方法研究[D]. 长沙: 国防科学技术大学信息系统与管理学院, 2011: 47-60. (Jiang J. Modeling, reasoning and learning approach to evidential network[D]. Changsha: School of Information System and Management, National University of Defense Technology, 2011: 47-60.)

[11] 汪春峰, 张永红. 基于无约束优化和遗传算法的贝叶斯网络结构学习方法[J]. *控制与决策*, 2013, 28(4): 618-622. (Wang C F, Zhang Y H. Bayesian network structure learning based on unconstrained optimization and genetic algorithm[J]. *Control and Decision*, 2013, 28(4):618-622.)

[12] Chien H, Shu Fan-wang. Precast production scheduling using multi-objective genetic algorithms[J]. *Expert Systems with Applications*, 2011, 38(7): 8293-8302.

[13] 林焕, 马志锋, 姚春海, 等. 基于格雷码-相移的双目三维测量方法研究[J]. *电子学报*, 2013, 41(1): 24-28. (Lin H, Ma Z F, Yao C H, et al. 3D measurement technology based on binocular vision using a combination of gray code and phase-shift structured light[J]. *Chinese J of Electronics*, 2013, 41(1): 24-28.)

[14] 孙海珺, 王宣明, 卢晓博, 等. 一种基于格雷码的电路自测试序列分配算法[J]. *计算机学报*, 2011, 34(9): 1697-1704. (Sun H J, Wang X M, Lu X B, et al. Algorithm of test pattern assignment of circuit BIST based on gray code[J]. *Chinese J of Computers*, 2011, 34(9): 1697-1704.)

(责任编辑: 曹洪武)