

引用格式:周颖,唐永川,赵晓哲. 基于加权信度熵的传感器数据冲突度量与融合[J]. 电光与控制,2018,25(6):48-51. ZHOU Y, TANG Y C, ZHAO X Z. Weighted belief entropy based conflict measure and fusion of sensor data[J]. Electronics Optics & Control, 2018, 25(6):48-51.

基于加权信度熵的传感器数据冲突度量与融合

周颖, 唐永川, 赵晓哲
(西北工业大学电子信息学院, 西安 710072)

摘要: 目标识别中,来自多传感器的数据通常包含诸多不确定性。在 D-S 证据理论框架下,提出一种基于加权信度熵的传感器冲突数据融合与目标识别方法。首先,将辨识框架(FOD)中包含的不确定信息融入新近提出的 Deng 熵模型;随后,采用加权 Deng 熵量化不同传感器数据源中的不确定性;最后,实现传感器冲突数据融合与目标识别决策。数值仿真及不同方法的比较分析结果验证了所提方法的合理性与有效性。

关键词: 传感器数据融合; 目标识别; D-S 证据理论; 信度熵; Deng 熵

中图分类号: V271.4 **文献标志码:** A **doi:**10.3969/j.issn.1671-637X.2018.06.011

Weighted Belief Entropy Based Conflict Measure and Fusion of Sensor Data

ZHOU Ying, TANG Yong-chuan, ZHAO Xiao-zhe
(School of Electronics and Information, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: In target recognition, the sensor data is full of uncertainty. This paper proposes a sensor data fusion approach for target recognition based on weighted belief entropy in Dempster-Shafer evidence theory framework. Firstly, the uncertain information in the Frame of Discernment (FOD) is integrated into the Deng entropy model. Then, the weighted Deng entropy is applied to measure the uncertainty of the sensor data from different sources. Finally, the fusion of the conflicting data is implemented, based on which the decision-making on target recognition is realized. The rationality and effectiveness of the proposed method are validated by numerical simulations as well as the comparative experiments.

Key words: sensor data fusion; target recognition; Dempster-Shafer evidence theory; belief entropy; Deng entropy

0 引言

多传感器数据融合与智能决策作为一类共性问题是当前研究的热点之一^[1-2]。在目标识别中,如何对带有冲突的多传感器数据实现不确定信息度量,进而实现冲突数据融合与智能决策,仍然是一个难题^[3-4]。不确定信息处理是当前数据融合领域的研究热点,引起了相关学者的广泛关注。D-S 证据理论^[5-6]在不确定信息处理中应用广泛,但是如何在 D-S 证据理论框架下度量信息的不确定性程度仍然是一个值得深入研究的问题^[7-8]。

香农熵是概率框架下不确定度测量的典型方法,在信息量度量中被广泛采用,但香农熵并不能直接应

用于 D-S 证据理论框架下的 mass 函数中。因此,文献[9]提出了一种名为 Deng 熵的不确定性度量方法,在一些情况下,Deng 熵的不确定性度量效果要优于文献[9]中提及的其他度量方法。但是,类似其他信度熵,Deng 熵并没有考虑到辨识框架(FOD)这种不确定信息源的因素,这就意味着在信息处理过程中损失了一部分可用且有价值的信息。考虑到 Deng 熵的不足,本文提出了加权信度熵,新的度量方法采用了关于 FOD 的命题相对标度,即命题元素的势和 FOD 中的元素个数都成为构建加权信度熵的权重因子。

随后,基于新的信度熵度量方法,为了融合多传感器冲突数据,本文提出了一种多传感器冲突数据融合方法,并以目标识别与智能决策为应用对象。新方法采用加权信度熵建模了多传感器数据不确定性后,采用具有诸多优势的经典 Dempster 组合规则进行数据融合,最后,基于数据融合结果进行目标识别决策。新

收稿日期:2018-04-25

修回日期:2018-05-10

作者简介:周颖(1991—),女,浙江义乌人,博士生,研究方向为智能信息处理。

方法能有效克服依赖单个传感器决策的风险。算例实验和对比分析验证了本文方法的有效性和比较优势。

1 基础理论

1.1 D-S 证据理论

D-S 证据理论假定了一组固定且完备的互斥事件集 $\Theta = \{\theta_1, \theta_2, \dots, \theta_n\}$, 命题与集合 Θ 的所有子集相关, $2^{|\Theta|}$ 称为 FOD, 表示为

$$\Omega = \{\emptyset, \{\theta_1\}, \{\theta_2\}, \dots, \{\theta_n\}, \{\theta_1, \theta_2\}, \dots, \{\theta_1, \theta_2, \dots, \theta_n\}\} \quad (1)$$

数学意义上, 基本概率指派 (BPA) 或 mass 函数是从 Θ 幂集 (所有子集的集合) 到 $[0, 1]$ 的函数, 并满足文献 [1-2] 中的约束, 即

$$\begin{cases} m(\emptyset) = 0 \\ 0 \leq m(A) \leq 1 \\ \sum_{A \in \Theta} m(A) = 1 \end{cases} \quad (2)$$

非零 mass 值对应 $m(A)$ 函数中元素 A , 称作焦点, 焦点与相应的 mass 值构成证据体 (BOE)。

对于两组 BPA, m_1 和 m_2 , Dempster 组合规则定义为

$$m(A) = \frac{\sum_{B \cap C = A} m_1(B) \cdot m_2(C)}{1 - K} \quad K = \sum_{B \cap C = \emptyset} m_1(B) \cdot m_2(C) \quad (3)$$

式中, $A \neq \emptyset$ 。若 $A = \emptyset$, 则 $m(A) = 0$, 即空集与空集的 Dempster 组合规则结果为 0。

1.2 D-S 证据理论框架下不确定性度量

香农熵表明每条信息的信息量与其不确定度直接相关, 香农熵不能被直接应用于 D-S 证据理论框架, 因此, 近似香农熵, 文献 [9] 总结了几种 D-S 证据理论框架下典型的不确定性度量方法后, 提出了 Deng 熵, 为

$$E_d(m) = - \sum_{A \in X} m(A) \text{lb} \frac{m(A)}{2^{|A|} - 1} \quad (4)$$

式中: X 即为式 (1) 中定义的 FOD; A 是 mass 函数的焦点, $|A|$ 表示命题 A 的基数。

2 加权信度熵

文献 [9] 中新近提出的 Deng 熵, 具有其他信度熵所不具备的一些优点。如兼容香农熵, 能在其他不确定性度量失效的情况下有效度量不确定性变化程度。在 D-S 证据理论中, 不确定信息不仅由 mass 函数表示, FOD 也是不确定性的来源, 例如, 即使每个命题的 mass 值保持不变, FOD 中的元素数量也会发生改变。然而, Deng 熵与文献 [9] 中提及的典型信度熵一样, 只考虑了 mass 函数, 忽略了命题的基数和 FOD 的标度, 这将导

致信息处理过程中信息丢失。因此, 选用 Deng 熵进行改进。

通过处理证据中更多可用的信息, 包括 FOD 的标度 $|X|$ 以及焦点相对于 FOD 的相对标度 $|A|/|X|$, 新的信度熵命名为加权 Deng 熵, 定义为

$$E_{wa}(m) = - \sum_{A \in X} \frac{|A| m(A)}{|X|} \text{lb} \frac{m(A)}{2^{|A|} - 1} \quad (5)$$

式中, X 是 FOD, $|X|$ 是 FOD 中元素的数量。

为了检验改进信度熵的效果和优越性, 采用文献 [9] 中的算例验证新的加权信度熵的合理性和有效性。取 mass 函数: $m(\{6\}) = 0.05$, $m(\{3, 4, 5\}) = 0.05$, $m(T) = 0.8$, $m(X) = 0.1$, 在 FOD $X = \{1, 2, \dots, 14, 15\}$ 中有 15 个元素, 分别表示元素 1, 元素 2, ..., 元素 15, T 表示元素变化数量从 1 到 14 的变量子集。

通过不同的命题计算 Deng 熵 $E_d^{[9]}$ 和式 (5) 中定义的加权 Deng 熵 E_{wa} , 结果如表 1 所示。表 1 还给出了文献 [9] 中提及的加权 Hartley 熵、Hohle 混沌度等方法的度量结果。

表 1 加权信度熵与多种不确定性度量方法计算结果比较

Table 1 Calculation results of the weighted belief entropy and other uncertainty measurement methods

命题元素变化	加权 Deng 熵	Deng 熵	加权 Hartley 熵	Hohle 混沌度
$T=1$	1.935 1	2.662 3	0.469 9	1.021 9
$T=1, 2$	2.121 3	3.930 3	1.269 9	1.021 9
$T=1, 2, 3$	2.418 6	4.908 2	1.737 9	1.021 9
$T=1, 2, 3, 4$	2.820 0	5.787 8	2.069 9	1.021 9
$T=1, 2, \dots, 5$	3.324 9	6.625 6	2.327 4	1.021 9
$T=1, 2, \dots, 6$	3.933 6	7.444 1	2.537 9	1.021 9
$T=1, 2, \dots, 7$	4.647 2	8.253 2	2.715 8	1.021 9
$T=1, 2, \dots, 8$	5.466 2	9.057 8	2.869 9	1.021 9
$T=1, 2, \dots, 9$	6.391 1	9.860 0	3.005 9	1.021 9
$T=1, 2, \dots, 10$	7.422 2	10.661 2	3.127 5	1.021 9
$T=1, 2, \dots, 11$	8.559 7	11.461 7	3.237 4	1.021 9
$T=1, 2, \dots, 12$	9.803 7	12.262 0	3.337 9	1.021 9
$T=1, 2, \dots, 13$	11.154 3	13.062 2	3.430 2	1.021 9
$T=1, 2, \dots, 14$	12.611 5	13.862 2	3.515 8	1.021 9

从表 1 可以看出, 加权 Deng 熵的值小于 Deng 熵值。这是因为在加权信度熵中考虑了证据体 (BOE) 的更多信息, 这意味着加权 Deng 熵比 Deng 熵损失的信息更少, 因此不确定信息的不确定程度降低。Hohle 混沌度所量化的不确定度不会随着命题 T 中元素数的变化而变化, 因此, 在这种情况下不能度量不确定度的方差。利用加权 Hartley 熵、Deng 熵和加权 Deng 熵, 不确定度会随着命题 T 元素数的增加而显著增加, 但加权 Hartley 熵和 Deng 熵因未考虑 FOD 信息, 与加权 Deng 熵相比信息损失更大。

3 基于加权信度熵的数据融合与目标识别方法

基于加权 Deng 熵的不确定信息度量能力,提出了一种传感器冲突数据融合方法。在这种方法中,证据的不确定程度由所提出的加权信度熵度量,新方法流程如图 1 所示。

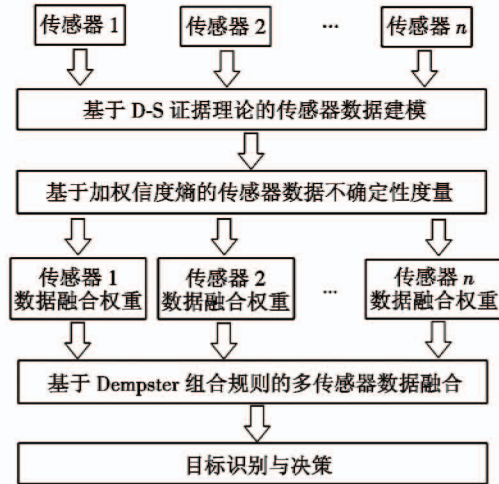


图 1 基于加权 Deng 熵的传感器数据融合流程图

Fig. 1 The flow chart of the weighted Deng entropy-based sensor data fusion approach

图 1 所设计的基于加权 Deng 熵的传感器冲突数据融合与目标识别方法主要包括如下 5 个步骤。

1) 基于 D-S 证据理论中 BPA 函数,将来自不同传感器的数据进行建模。

2) 基于加权信度熵,即式(5)所述加权 Deng 熵,对各组 BPA 开展不确定性度量。

3) 基于步骤 2) 的不确定性度量结果,计算每个传感器数据源的权重。一般而言,每组传感器数据的权重与每个 BPA 的不确定性测量值呈正相关。对于 n 个传感器数据源,第 i 个传感器数据权重为

$$w_i = \frac{E_{wd}(m_i)}{\sum_{i=1}^n E_{wd}(m_i)} \quad (6)$$

4) 使用 Dempster 证据组合规则进行数据融合。

5) 基于传感器数据融合结果进行目标识别与决策。

4 算例示例与分析

为了简化,直接采用文献[10]中的算例数据验证所提方法的有效性。假设在目标识别问题中,3 个潜在目标可能是 A, B 或者 C ,由 5 个传感器所报告的证据被建模为 BPA,如表 2 所示。根据常识判断,来自第 2 个传感器的报告与其他 4 个传感器截然相反,其他 4

个传感器均侧重认为 A 将是最终识别的目标。

表 2 来自传感器报告的数据所建模生成的 BPA

Table 2 BPAs obtained by modeling the data from sensor reports

传感器	BPA			
	$m(A)$	$m(B)$	$m(C)$	$m(A, C)$
传感器 1 $m_1(\cdot)$	0.41	0.29	0.3	0
传感器 2 $m_2(\cdot)$	0	0.9	0.1	0
传感器 3 $m_3(\cdot)$	0.58	0.07	0	0.35
传感器 4 $m_4(\cdot)$	0.55	0.1	0	0.35
传感器 5 $m_5(\cdot)$	0.6	0.1	0	0.3

根据前文提出的冲突数据融合方法,表 2 完成了基于 BPA 的不确定性数据建模。对于步骤 2),采用式(5)计算每个传感器数据的加权信度熵为 $E_{wd}(m_1) = -\sum_{A \in X} \frac{|A| m_1(A)}{|X|} \lg \frac{m_1(A)}{2^{|A|-1}} = 0.522 1$ 。同理可得, $E_{wd}(m_2) = 0.156 3, E_{wd}(m_3) = 0.964 7, E_{wd}(m_4) = 0.992 1, E_{wd}(m_5) = 0.922 5$ 。

对于步骤 3),基于式(6),则每个传感器相对权重的算式为

$$w_i = \frac{E_{wd}(m_i)}{\sum_{i=1}^5 E_{wd}(m_i)} \quad (7)$$

计算结果为 $w_1 = 0.146 8, w_2 = 0.043 9, w_3 = 0.271 2, w_4 = 0.278 9, w_5 = 0.259 3$ 。则表 2 中每个传感器数据源的加权 mass 函数计算如下: $m_w(A) = \sum_{i=1}^5 w_i m_i(A) = 0.526 4$ 。同理可得, $m_w(B) = 0.154 9, m_w(C) = 0.048 4, m_w(A, C) = 0.270 3$ 。

针对步骤 4),利用 Dempster 证据组合规则,每个新的加权 mass 函数都融合了 4 次。融合结果为 $m(A) = (((m_w \oplus m_w) \oplus m_w) \oplus m_w) \oplus m_w(A) = 0.989 5$ 。同理可得, $m(B) = 0.000 3, m(C) = 0.005 7, m(A, C) = 0.004 5$ 。

表 3 列出了本文方法和基于经典 Dempster 组合规则以及文献[11]中 Murphy 组合规则等不同方法的数据融合结果。如果仅采用 Dempster 组合规则,则不能成功识别出目标,甚至得到错误的识别结果。基于本文方法所识别出的目标 A ,其置信度为 98.95%,且本文所提出的方法对识别目标 A 的支持度最高,高于仅采用 Murphy 组合规则的识别结果 2.75%。步骤 5)中所述的目标识别与决策得以完成。

表 3 不同方法的算例数据融合结果

Table 3 Fusion results of the example data of different methods

不同融合方法	融合结果			
	$m(A)$	$m(B)$	$m(C)$	$m(A, C)$
直接用 Dempster 组合规则	0	0.144 2	0.857 8	0
直接用文献[11]组合规则	0.962 0	0.021 0	0.013 8	0.003 2
本文加权信度熵的方法	0.989 5	0.000 3	0.005 7	0.004 5

5 结论

本文在 D-S 证据理论框架下,提出了基于 Deng 熵理论的加权信度熵以度量信息不确定度。新的信度熵不仅包含了传统信度熵中 mass 函数所涉及的不确定信息,还建模了辨识框架的规模信息。据此,通过处理信息源中的更多信息,使得信息处理过程中的信息损失减少。随后,基于新的加权信度熵,提出了一种传感器冲突数据融合与目标识别方法。通过算例分析与实验结果比较,验证了本文方法的合理性和有效性。

参考文献

- [1] 张堃,周德云,王谦,等. 基于模糊决策树的机载多传感器智能管理方法[J]. 计算机应用,2011,31(12):3255-3257.
- [2] 王越,周德云,杨维,等. 多种异类传感器联合跟踪的异步航迹融合算法[J]. 弹箭与制导学报,2014,34(2):153-156.
- [3] 柳毅,高晓光,卢广山,等. 基于加权证据组合的多传感器目标识别[J]. 系统工程与电子技术,2003,25(12):1475-1477.
- [4] 宋建辉,张俊,刘砚菊,等. 基于 LBP-PCA 的多传感器目标识别算法[J]. 火力与指挥控制,2017,42(2):60-63.
- [5] DEMPSTER A P. Upper and lower probabilities induced by a multivalued mapping [J]. *Annals of Mathematical Statistics*, 1967, 38(2):325-339.
- [6] SHAFER G. A mathematical theory of evidence [M]. Princeton: Princeton University Press, 1976.
- [7] YANG Y, HAN D. A new distance-based total uncertainty measure in the theory of belief functions [J]. *Knowledge-Based Systems*, 2016, 94:114-123.
- [8] SONG Y, WANG X, LEI L, et al. Uncertainty measure for interval-valued belief structures [J]. *Measurement*, 2016, 80:241-250.
- [9] DENG Y. Deng entropy [J]. *Chaos Solitons & Fractals*, 2016, 91:549-553.
- [10] DENG Y, SHI W, ZHU Z, et al. Combining belief functions based on distance of evidence [J]. *Decision Support Systems*, 2004, 38(3):489-493.
- [11] MURPHY C K. Combining belief functions when evidence conflicts [J]. *Decision Support Systems*, 2000, 29(1):1-9.
- (上接第 10 页)
- based on joint TDOA and DOA estimation using 2-D matrix pencil algorithms and IEEE 802.11ac [J]. *IEEE Transactions on Wireless Communications*, 2015, 14(5):2440-2454.
- [6] WANG H, WANG J, ZHONG L, et al. Mismatched filter for analogue TV-based passive bistatic radar [J]. *IET Radar, Sonar & Navigation*, 2011, 5(5):573-581.
- [7] 孙鹏,熊伟. 测向交叉定位系统中的 K-means 聚类融合算法[J]. 电光与控制,2016,23(10):36-40.
- [8] 张杰,蒋建中,郭军利. 基于两步最小二乘定位的偏差改进算法[J]. 航空学报,2016,37(2):695-705.
- [9] 关欣,陶李,衣晓. 滑窗式无偏多平台无源定位算法[J]. 系统工程与电子技术,2016,38(9):1981-1986.
- [10] 莫成坤,陈树新,吴昊,等. 基于抗差估计的三维测向无源定位算法[J]. 电光与控制,2015,22(2):22-26.
- [11] 宗军君,崔逊学. 多站测向交叉定位的加权最大似然估计算法及其精度分析[J]. 电光与控制,2015,22(11):11-13.
- [12] WERTHMANN J. A step-by-step description of a computational efficient version of multiple hypothesis tracking [C]//*SPIE Conference on Signal and Data Processing of Small Targets*, 1992:288-300.
- [13] BLACKMAN S, POPOLI R. Design and analysis of modern tracking systems [M]. London: Artech House Publishers, 1999.
- (上接第 38 页)
- [6] CHOI I H, PAK J M, AHN C K, et al. New preceding vehicle tracking algorithm based on optimal unbiased finite memory filter [J]. *Measurement*, 2015, 73:262-274.
- [7] PAK J M, AHN C K, SHMALIY Y S, et al. Switching extensible FIR filter bank for adaptive horizon state estimation with applications [J]. *IEEE Transactions on Control Systems Technology*, 2016, 24(3):1052-1058.
- [8] SHMALIY Y S, SIMON D. Iterative unbiased FIR state estimation: a review of algorithms [J]. *EURASIP Journal on Advances in Signal Processing*, 2013, 113(1):1-16.
- [9] SHMALIY Y S. An iterative Kalman-like algorithm ignoring noise and initial conditions [J]. *IEEE Transactions on Signal Processing*, 2011, 59(6):2465-2473.
- [10] KIM P S, LEE M E. A new FIR filter for state estimation and its applications [J]. *Journal of Computer Science and Technology*, 2007, 22(5):779-784.
- [11] SHMALIY Y S, KHAN S, ZHAO S Y. Ultimate iterative UFIR filtering algorithm [J]. *Measurement*, 2016, 92:236-242.