

基于信息熵的一种传感器管理算法

刘先省^{1,2}, 申石磊², 潘泉¹, 张洪才¹

(1. 西北工业大学自动控制系统, 西安 710072; 2. 河南大学计算机系, 开封 475001)

摘要: 通过对目标搜索区域不确定性定量描述的信息熵及信息熵变化而产生的信息增量, 本文提出了一种多传感器对多目标进行检测与分类的优化算法, 即针对每一检测单元计算该时刻的信息熵及预测下一时刻的信息熵, 产生信息增量最大的检测单元就是下一次要搜索的单元. 仿真结果证明了该算法的有效性.

关键词: 信息融合; 传感器管理; 信息熵; 信息增量

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2000) 09-0039-03

An Algorithm of Sensor Management Based on Information Entropy

LIU Xian-xing^{1,2}, SHEN Shi-lei², PAN Quan¹, ZHANG Hong-cai¹

(1. Dept. of Automatic Control, Northwestern Polytechnical University, Xi'an 710072, China; 2. Dept. of Computer, Henan University, Kaifeng 475001, China)

Abstract: With information gain obtained by information entropy and evolution of information entropy which characterize uncertainty of target search location, an optimizing algorithm of detection and classification used in multisensors and multitargets is put forward. Namely, information entropy of current sampling time is computed and information entropy of next sampling time is predicted for each detection cell. The detection cell of maximum information gain is the next one to search. The effectiveness of algorithm is testified by simulation results.

Key words: information fusion; sensor management; information entropy; information gain

1 引言

根据信息论的观点, 传感器的目的就是与目标环境发生相互作用以减少目标环境的不确定性, 这些不确定性可用信息熵来度量. 通过检测目标是否存在以及对目标所属类型的分类, 可以得到一个信息增量; 通过提高已被跟踪目标的跟踪精度, 也可获得一个信息增量.

多传感器信息融合技术能最大限度减少目标环境的不确定性, 其显著特点是: 提高信息的可信度和可探测性, 扩大空间搜索范围和瞬时的搜索范围, 降低推理模糊程度, 改进探测性能, 增加目标特征矢量的维数, 提高空间分辨率, 相对减少获得信息的代价和时间, 增强系统的容错能力和自适应性, 从而提高整个系统的性能.

在多传感器信息融合技术中, 传感器管理越来越受到人们的重视, 传感器管理作为一个反馈环节, 使多传感器信息融合系统构成一个闭环控制系统, 从而提高了系统的实时性和整体优化性.

传感器管理核心问题就是决定如何选择传感器、传感器工作模式和传感器搜索策略以优化其系统整体性能. 文献[1]提出了基于最大检测概率的传感器搜索策略, 这种策略对于搜索单目标成功率较高, 但对于多目标则错误率较高; 文献

[2,3]基于分辨力分别给出了单传感器和多传感器对多目标的资源分配方法, 但在定义分辨力时需要先验概率分布; 文献[4]基于效能函数提出的一种传感器管理方法, 虽简单可行、使用面广, 但某些因素的合理量化尚待进一步研究. 本文在此方法^[2,3]的基础上以信息论中最基本的信息熵为基础, 给出一种基于信息增量的多目标检测与分类的多传感器资源分配方法. 这种方法的性能要比顺序搜索方法的性能有很大程度的改善, 适合应用于低信噪比环境中.

2 信息熵、信息增量与传感器管理关系

假设 T 为一离散有限集合, 其状态 $t (t = 0, \dots, T)$ 互斥. 若 $q(t)$ 为尚未获得一个量测之前而关于状态 t 的一个概率密度分布函数 (先验分布), 则该状态下信息熵为:

$$H(q(t)) = - \sum_{t=0}^T q(t) \log q(t) \quad (1)$$

若为连续情况, 则信息熵为 $H(q(t)) = - \int q(t) \log q(t) dt$.

设 $p(t)$ 为获得一个量测后状态 t 的估计概率密度分布 (后验分布), 则信息熵为:

$$H(p(t)) = - \sum_{t=0}^T p(t) \log p(t)$$

和信息增量则定义为先验信息熵减去后验信息熵,即

$$I[q(t); p(t)] = - \int_{t=0}^T q(t) \log q(t) + \int_{t=0}^T p(t) \log p(t) \quad (2)$$

若 $p(t) = q(t)$, 则 $I[q(t); p(t)] = 0$, 表示本次量测没有提供任何新息; 若 $p(t) < q(t)$, 则 $I[q(t); p(t)] > 0$, 说明本次量测带来了新息. 一般而言, 后验概率不应小于先验概率, 因此 $I[q(t); p(t)] \geq 0$. 在传感器管理中, 通过计算目标状态在第 k 次量测后的熵 H_k 和第 $k+1$ 次量测前熵的数学期望值 $E[H_{k+1/k}]$, 然后计算 $I_k = H_k - E[H_{k+1/k}]$, I_k 越大对应的目标则更需要传感器对它做进一步的量测; 反之, 这次测量将为系统增加最大的信息量, 这就是传感器用于检测与分类的资源分配的优化原则.

计算中还可以看出, I_k 大的目标, 通常其 H_k 值较大(不确定性大). 通俗地讲, 越是“不了解”的目标越需要进一步努力去“了解”.

3 信息增量计算与传感器管理算法实现

设一监视域由 C 个离散的检测单元组成, 每个检测单元记为 $c(c=1, \dots, C)$, 每个单元至多包含一个目标(假设目标静止): 为空或为类型 $t(t=0, \dots, T)$ 的目标, 其中 $t=0$ 意味着没目标, 则目标的检测和分类问题就是决定每一个检测单元 c 的状态 t 的问题.

设有 S 个能在一定时间内任意指向无误的传感器, 分别记为 $s=1, \dots, S$, 在离散时刻 k 仅使用一个传感器 s 采样某一个检测单元 c . $p(z|t, s)$ 表示使用给定传感器 s 、检测单元 c 中包含目标类型 t 已知时, 得到量测结果 z 的概率密度, 该概率密度是已知的且与采样时刻 k 和检测单元 c 无关. 设每一次量测 z 是离散向量, $f(z)$ 表示对所有可能的量测结果求和. 设 N^k 为时刻 k 某一个检测单元 c 的量测次数, 那么在检测单元 c 中的全部量测集合为 $Z = \{z_1, \dots, z_{N^k}\}$. 一般来说, Z 应包含一些来自不同传感器的量测, 各量测结果相互独立. 在检测单元 c 中产生状态 t 的先验概率 $p(t|c)$ 是已知的, 并由起始时该类目标发生的相对几率决定, 或由地理信息决定(需要重点检测的区域).

$$\begin{aligned} E[H_{k+1/k}(Z, c, s)] &= \int_z p(z|Z, c, s) H_{k+1}[p(t|Z, c)] = - \left\{ \int_z \int_{t=0}^T p(z|t, s) p(t|Z, c) \int_{t=0}^T p(t|Z, c) \log[p(t|Z, c)] \right\} \\ &= - \int_z \left\{ \int_{t=0}^T p(z|t, s) p(t|Z, c) \frac{\int_{t=0}^T p(z|t, s) p(t|Z, c) \log[p(t|Z, c)]}{\int_{t=0}^T p(z|t, s) p(t|Z, c)} \right\} \\ &= - \int_z \left\{ \int_{t=0}^T p(z|t, s) p(t|Z, c) \frac{\int_{t=0}^T p(z|t, s) p(t|Z, c) \log[p(t|Z, c)]}{\int_{t=0}^T p(z|t, s) p(t|Z, c)} \right\} \\ &= - \int_z \left\{ \int_{t=0}^T p(z|t, s) p(t|Z, c) \log[p(t|Z, c)] \right\} \end{aligned}$$

k 时刻的期望信息增量为

$$I_k(Z, c, s) = H_k(Z, c) - E[H_{k+1/k}(Z, c)], \text{ 即}$$

$$I_k(Z, c, s) = \int_z \left\{ \int_{t=0}^T p(z|t, s) p(t|Z, c) \log[p(t|Z, c)] \right\}$$

假设使用传感器 s 测量单元 c , 产生量测结果为 z , 则新的观测集合 $Z = \{z\} \cup Z$, 下面求目标新概率 $p(t|Z, c)$ 的递推形式. 因为

$$p(Z) = \int_{t=0}^T p(Z|t) p(t)$$

由于各量测相互独立, 而 $Z = \{z\} \cup Z$, 所以 $p(Z|t) = p(z|t) p(Z|t)$. 而

$$p(t|Z) = \frac{p(Z|t) p(t)}{p(Z)} = \frac{p(z|t) p(Z|t) p(t)}{\int_{t=0}^T p(z|t) p(Z|t) p(t)}$$

将 $p(Z|t) p(t) = p(t|Z) p(Z)$ 代入上式, 得

$$p(t|Z) = \frac{p(z|t) p(t|Z)}{\int_{t=0}^T p(z|t) p(t|Z)}$$

在上述推导过程中, 为简单起见, 没有提及所用的传感器 s 和针对的检测单元 c , 这里特作一说明. 由于 $p(t|Z)$ 是在获得量测集合 Z 基础上而估计的后验概率, 这个后验概率当然是针对某一检测单元 c (目标)的, 且 c 又是非随机变量, 因此 $p(t|Z)$ 可直接写成 $p(t|Z, c)$ (同理 $p(z|t)$ 可写成 $p(z|t, c)$); $p(z|t)$ 是对一定类型目标 t 进行检测时的检测概率, 当然这个检测是由传感器 s 执行的, 其值为已知且与检测单元 c 、采样时刻 k 无关(见前面假设), 而 s 也是非随机变量, 因此 $p(z|t)$ 可直接写成 $p(z|t, s)$. 所以, 上面递推形式为:

$$p(t|Z, c) = \frac{p(z|t, s) p(t|Z, c)}{\int_{t=0}^T p(z|t, s) p(t|Z, c)} \quad (3)$$

在 t 时刻单元 c 的后验概率为 $p(t|Z, c)$, 则第 k 时刻信息熵为

$$H_k(Z, c) = - \int_{t=0}^T p(t|Z, c) \log[p(t|Z, c)] \quad (4)$$

在当前量测集合 Z 的基础上, 预测一个输出量测 z 的概率密度为^[3]

$$p(z|Z, c, s) = \int_{t=0}^T p(z|t, s) p(t|Z, c) \quad (5)$$

若单元 c 增加一个量测时, 可使用概率密度 $p(z|Z, c, s)$ 计算 $k+1$ 的期望信息熵:

$$\begin{aligned} & - \int_{t=0}^T p(t|Z, c) \log[p(t|Z, c)] \quad (6) \\ & \text{将式(3)代入式(6), 得信息增量 } I_k(Z, c, s) \text{ 的递推公式:} \\ & I_k(Z, c, s) = \int_z \left\{ \int_{t=0}^T p(z|t, s) p(t|Z, c) \log \frac{p(z|t, s) p(t|Z, c)}{\int_{t=0}^T p(z|t, s) p(t|Z, c)} \right\} \end{aligned}$$

$$- \sum_{t=0}^T p(t|Z, c) \log[p(t|Z, c)] \quad (7)$$

k 时刻的信息增量 $I_k(Z, c, s)$ 等于检测单元 c 在 k 时刻的熵减去 $k+1$ 时刻的熵,只不过是 $k+1$ 时刻的熵是在 k 时刻概率分布 $p(t|Z, c)$ 和量测概率 $p(z|t, s)$ 的基础上,对 $k+1$ 时刻熵的预测。

基于信息增量的传感器管理策略就是选择检测单元 c 和传感器 s 使 $I_k(Z, c, s)$ 最大,这里 Z 是检测单元 c 在第 k 次量测结束时对应的当前观测集合,一般来说 $I_k(Z, c, s)$ 对不同的单元 c 、不同的传感器 s 其大小不同。有了 $I_k(Z, c, s)$ 后,搜索的准则就是选取使 $I_k(Z, c, s)$ 最大的传感器 s 对相应的检测单元 c 进行搜索。算法实现步骤如下:

- (1) 设定目标检测阈值门限 τ ;对所有检测单元 c 与其分别对应的传感器 s 的信息增量初始化排序,形成顺序链。
- (2) 若检测单元 $c(c=1, \dots, C)$ 的后验概率大于 τ ,表示该检测单元的目标检测或分类已完成,把该单元从顺序链中删除。
- (3) 若检测或分类完毕,则退出。否则继续。
- (4) 从当前顺序链中找出信息增量最大的检测单元 c^* 和与其对应的传感器 s^* ,命令传感器 s^* 对检测单元 c^* 搜索一次。

(5) 根据新的观测值,更新后验概率及其对应的信息增量。

(6) 根据更新后的信息增量,将该检测单元 c^* 放到顺序链中的正确位置,返回步骤 2。

4 性能比较分析

假设一监视域有 100 个离散检测单元组成,一高斯型目标分布在监视域检测单元中(信噪比 0dB),用一个在较短时间内可以指向任意检测单元的传感器(如 ESA)对目标进行检测。为了比较顺序搜索和信息增量搜索的检测结果,设 c_0 表示不包含目标的单元。定义一个错误概率^[2]

$$p_e(k) = \Pr\{\arg \max_c p(t=1|Z_k, c) = c_0\}$$

其中 k 是每个检测单元平均采样次数。每次仿真处理 1000 个量测(平均 10 次/每单元),共进行 500 次,求其平均。从表 1 中可以看出,在平均每检测单元采样次数相同时,信息增量方法要比顺序方法的错误率低的多。这种现象是可以理解的,因为如果目标数远少于检测单元数,顺序方法的大部分采样针对的却是没有包含目标的检测单元。而基于最大信息增量的方法却能最大限度保证所采样的检测单元是最可能包含目标的检测单元。当目标数与检测单元数相等时(一般不会),两种方法的性能是一样的。

表 1 顺序搜索方法与信息增量搜索方法的错误概率比较

方法 \ P_e	0	1	2	3	4	5	6	7	8	9	10
顺序搜索	0.990	0.972	0.918	0.756	0.673	0.558	0.483	0.332	0.306	0.251	0.171
信息增量搜索	0.990	0.621	0.293	0.149	0.099	0.051	0.023	0.018	0.010	0.009	0.02

基于最大信息增量的方法与基于最大检测概率的方法^[1]相比更适合于多目标环境。因为虽然后者对于单目标搜索要比前者收敛稍微快一些(性能稍好),但对于多目标的搜索后者的错误率极高,这是由于后者一旦发现某一个检测单元存在目标的概率最高就不再去搜索其它单元而造成的;而前者从信息量增加最大的角度出发刚好克服了这一缺点。因此,从整体上来说,前者的性能优于后者的性能。

5 结论与讨论

基于信息增量的传感器优化管理方法(检测与分类)是通过对不同的检测单元使用不同的传感器预测下一时刻的信息熵,从而计算出在该时刻的期望信息增量,选择期望信息增量最大的检测单元与相应的传感器,并命该传感器对该检测单元进行搜索,这里只考虑目标不运动的情况,因此该方法只适用于地面或海面上的非机动目标。

对空中机动目标,概率密度除了在量测时刻被更新(满足于贝叶斯规则)外,在量测之间也将发生转移,因此上述的递推算法就不能直接使用。这时,可根据实际情况设置量测之间的转移概率或直接利用 Fokker-plank 微分方程或 Kolmogorov 前向微分方程描述量测之间的概率密度变化,再利用贝叶斯规则更新量测时刻的概率密度。当目标的状态转移和量测方

程是线性时,上述微分方程可求得一闭合形式的解,这时量测之间和量测时刻的概率密度变化可分别由目标状态的均值和协方差的转移(时间)和更新(量测)来确定;当目标的状态转移或量测方程是非线性时,上述微分方程无闭合形式的解而只能求得一数字解,这时获得算法的实时性较差,这个问题有待于进一步研究。此外,将该方法同时应用于目标检测、跟踪和分类的优化也是目前研究的问题之一。

作者简介:

刘先省 1964 年生,副教授,博士生。主要研究领域为信息融合、智能控制等。

申石磊 1956 年生,副教授。主要研究领域为信号处理、计算机控制等。

潘泉 1961 年生,教授,博士生导师。主要研究领域为随机最优估计与控制、信息融合、多目标跟踪、智能信息处理、智能控制等。

张洪才 1938 年生,教授,博士生导师。主要研究领域为估计理论、多目标跟踪、系统辨识、随机控制等。

(下转第 22 页)

参考文献:

- [1] 周宏仁,等. 机动目标跟踪 [M]. 北京:国防工业出版社,1991.
- [2] J.J. Sudano. The tracking filter with a noisy jerk as the maneuver model [J]. IEEE Trans. AES,1993,29(4):578-580.
- [3] Kishore Mehrotra, et al. A jerk model for tracking highly maneuvering targets [J]. IEEE Trans. AES,1997,33(4):1094-1105.
- [4] Youji Iiguni, et al. A real-time learning algorithm for a multilayered neural network based on the extended Kalman filter [J]. IEEE Trans. Signal Processing,1992,40(4):959-966.
- [5] 杨大力,等. 多层前向神经网络中 BP 算法的误调分析及其改进的算法 [J]. 电子学报,1995,23(1):117-120.
- [6] Georg Thimm, et al. The interchangeability of learning rate and gain in backpropagation neural networks [J]. Neural Computation,1996,8:451-460.
- [7] D. Geroge, et al. Effective backpropagation training with variable step-size [J]. Neural Networks,1997,10(1):69-82.
- [8] Qinghua Zhang, Albert Benveniste. Wavelet networks [J]. IEEE Trans. Neural Networks,1992,3(6):889-898.
- [9] Y. C. Pati, et al. Analysis and synthesis of feedforward neural networks using discrete affine wavelet transformations [J]. IEEE Trans. Neural Networks,1993,4(1):73-85.
- [10] 徐晓霞,等. 基于正交最小二乘算法的小波神经网络 [J]. 电子学报,1992,26(10):115-117.
- [11] 黄凤岗,等. 一种自适应的小波神经网络 [J]. 电子学报,1998,26(8):143-145.

作者简介:



李永红 1988 年获大连海事大学工学硕士学位,现在该校攻读博士学位. 主要从事雷达数据处理和神经网络等方面的研究. 在国内外发表论文 20 余篇.



栾秀珍 1988 年获西安电子科技大学工学硕士学位,现在大连海事大学攻读博士学位. 主要从事微波技术、子波理论和神经网络等方面的研究.

(上接第 41 页)

参考文献:

- [1] David A. Castanon. Optimal search strategies in dynamic hypothesis testing [J]. IEEE Trans. on SMC,1995,25(7):1130-1138.
- [2] Kastella Keith. Discrimination gain to optimize detection and classification [J]. IEEE Transactions on SMC,1997,27(1):112-116.
- [3] Kastella Keith, Musick. Stan comparison of sensor management strategies for detection and classification [A]. 9th National Symposium on Sensor Fusion [M]. March 1996, Naval Postgraduate School, Monterey, CA.
- [4] Liu Xianxing, Pan Quan, Zhang Hongcai, Dai Guanzhong. Study of algorithm sensor management based on functions of efficiency and waste [J]. Chinese Journal of Aeronautics, 2000, 13(1).