

基于 P-B-P 最优准则的网络检测算法

文成林¹, 方正¹, 崔永超², 李秀娟²

(1. 杭州电子科技大学信息与控制研究所, 浙江杭州 310018;
2. 河南工业大学电气工程学院, 河南郑州 450001)

摘要: 本文以有向拓扑结构的传感器网络为背景, 通过分析在全局贝叶斯风险最小准则下已建立的集中式和近似分散式两种决策方法各自优势与不足, 并考虑到现有的队决策方法求解决策过程中存在着局限性, 结合贝叶斯公式和相关图模型理论等, 建立了在 P-B-P 最优准则下针对此类网络的新决策方法. 该方法分为在线计算和离线计算两部分, 前者主要任务是基于在线测量值获得类条件概率密度; 后者主要任务是如何求取用于计算阈值所需的参数, 参数的计算过程分别是由正序传递似然函数消息和逆序接收代价函数消息两部分组成. 同时, 还分析了新方法在调节集中式和近似分散式两种决策方法的计算量和能耗之间矛盾的能力, 而其优点也通过计算机仿真结果进行了验证.

关键词: 贝叶斯风险; 集中式决策; 近似分散式决策; 消息传递算法

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2013)01-0056-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2013.01.011

A Detection Algorithm of Sensor Network Based on Person-By-Person Optimal Rule

WEN Cheng-lin¹, FANG Zheng¹, CUI Yong-chao², LI Xiu-juan²

(1. Institute of Information and Control, Hangzhou Dianzi University, Hangzhou, Zhejiang 310018, China;
2. College of Electrical Engineering, Henan University of Technology, Zhengzhou, Henan 450001, China)

Abstract: Considered the directed topology structure of the sensor network, on the basis of introducing the optimal centralized strategy and myopic decentralized strategy established by the rule of the minimum global Bayesian risk, and analyzing their merits and demerits, and considering the limitation of the team-theory solution, and combining the belief propagation with some algorithms in graphical models, a new strategy method to this sensor network is proposed by the rule of person-by-person optimality. It consists of online computation and offline computation, the former task is to obtain one class-conditional-probability density based on the online measurements, the later task is get some parameters which are used to calculate one threshold, parameter calculation procedure comprises one forward transmitting process of likelihood function message and another backward receiving process of cost-to-go function message. The new method capability, to trade off the conflict between calculated complexity and energy consumption from the optimal centralized strategy and myopic decentralized strategy, is analyzed, other advantage is also validated by computer simulation.

Key words: Bayesian risk; centralized strategy; myopic decentralized strategy; message-passing algorithm

1 引言

作为微型化设备和无线通信相结合的产物, 新兴的自组织无线传感器网络已在多个科学领域和工程应用中得到了广泛的应用^[1,2]. 该网络的每一个节点不但记录目标信息, 还接收和传递决策有关的信息. 应用图模型的相关理论(如 BP 算法)可以较好地解决了检测过程中所遇到的一些概率推论问题^[3]. 考虑到能量受限的

传感器网络, BP 算法的效果通常就不甚理想了^[4].

二元无线网络的分散式检测问题, 相当于寻找每个节点最小风险函数的解. 具体求解可视为一个多目标设计问题, 常结合图模型和队理论(Team Theory)进行分析. 但一般来说, 队决策(Team Decision)是一个 NP-hard 问题^[5], 而在特定的模型假设下, 队决策问题就能转化为可离线执行的迭代算法^[6]. 本文将一定假设条件下, 先把队决策问题转化为一个不动点方程组求解问题, 然

后再采用一种有效的消息传递算法进行迭代求解. 该算法是由重复整个网络的正序-逆序扫描后构成的, 即用基于父亲节点定义的“似然函数”为前序消息, 用基于孩子节点定义的“代价函数”为后序消息. 在每一步迭代中, 每个节点都要先根据来自最近邻的消息调整它自身的局部决策规则, 然后再将调整后的消息传递给它的邻居节点^[7,8].

本文余下内容安排如下: 第二节介绍图模型及相关的概念; 集中式和近似分散式两种决策方法的变分表达式及相关问题分析在第三节进行; 第四节是在考虑信道带宽有限的情形下, 按照贝叶斯公式和相关的图模型算法, 建立相应的队决策方法, 并用消息传递算法对该类决策的离线部分进行迭代求解; 对比几种检测方法的计算复杂度和能耗在第五节呈现; 第六节将通过计算机仿真结果分析验证新算法有效性.

2 图模型的基本概念

图模型(Graphical models)是统计学中一个崭新的研究领域^[9,10], 图中的每个结点处的状态可看作为随机变量, 图中的边视为概率依赖关系; 在相互连接的结点子集上定义相关函数, 并通过联合概率分布来表示的.

记 $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$, n 为传感器个数, $x_i \in \{+1, -1\}$ 为传感器 i 对被检测目标可能呈现的情况, 其中若用 $x_i = +1$ 表示目标发生了机动, 那么 $x_i = -1$ 就表示目标未发生机动. 记随机向量 $\mathbf{Y} = \{Y_1, Y_2, \dots, Y_n\}$, 且 $\mathbf{y} = \{y_1, y_2, \dots, y_n\}$, $y_i \in \mathbf{R}$ 是随机变量 Y_i 的一个取值, 它表示传感器 i 对目标状态的测量. $\mathbf{u} = \gamma(\mathbf{y})$ 为基于测量 \mathbf{y} 的决策函数, 决策结果为 $\mathbf{u} \in \{+1, -1\}^n$.

假设给定如图 1 所示包含四个节点的对等网络, 即每个节点的功能和结构都是一样的.




图1 网络结构及其有向拓扑结构

标准贝叶斯网是目

前最常用的有向概率图模型, 其定义为: 记图为 $\mathbf{G} = (\mathbf{V}, \mathbf{A})$, 其中 $\mathbf{V} = \{v_1, v_2, \dots, v_n\}$ 为图中全体结点组成的集合, n 为节点个数, $\mathbf{A} = \{a_1, a_2, \dots, a_m\}$ 为图中有向边全体组成的集合. 若记 a 是从节点 j 出发至节点 i 的有向边, 那么就称节点 j 为节点 i 的父亲节点, 节点 i 为节点 j 的孩子节点, 记节点 i 的父亲节点的全体为 $pa(i)$, 记节点 j 的孩子节点全体为 $ch(j)$, 对应的状态为 $\mathbf{x}_{pa(i)}$ 和 $\mathbf{x}_{ch(j)}$. 则 \mathbf{x} 的分布满足

$$p(\mathbf{x}) = \prod_{i=1}^n p(x_i | \mathbf{x}_{pa(i)})$$

其中, 当节点 i 没有父亲节点时, 有 $p(x_i | \mathbf{x}_{pa(i)}) = p(x_i)$.

3 贝叶斯风险及决策

基于贝叶斯决策理论处理二元决策问题是最基本的方法之一^[11].

3.1 单传感器情形

当 $n = 1$ 时, 为了能根据惩罚 $c(u, x)$ 的期望来衡量决策的性能, 引入贝叶斯风险函数为

$$J(\gamma) = E[c(u, x)]$$

对应的测量值 y 的条件期望风险为

$$J(\gamma(y)) = E[c(u, x) | y] = \sum_{x \in \{+1, -1\}} c(\gamma(y), x) p(x | y)$$

用期望风险表示决策 $\gamma(Y)$ 平均风险,

$$J(\gamma(Y)) = E\left[\sum_{x \in \{+1, -1\}} c(\gamma(Y), x) p(x | Y)\right] \quad (1)$$

由此可得到用变分公式表示的最优决策为

$$\bar{\gamma}(Y) = \arg \min_{u \in \{+1, -1\}} \sum_{x \in \{+1, -1\}} c(u, x) p(x) p(Y | x) \quad (2)$$

记 $\bar{\theta}(u, x) = c(u, x) p(x)$, 它可以先通过离线计算得到. 为此将式(2)展开后得:

$$\bar{\gamma}(Y) = \arg \min_{u \in \{+1, -1\}} (\bar{\theta}(u, +1) p(Y | +1) + \bar{\theta}(u, -1) p(Y | -1))$$

$$\text{不妨设 } p(u | Y; \bar{\gamma}) = \begin{cases} 1, & u = \bar{\gamma}(Y) \\ 0, & \text{其他} \end{cases}$$

那么就有

$$p(u | x; \bar{\gamma}) = \int p(Y | x) p(u | Y; \bar{\gamma}) dY$$

并且, 在决策 $\bar{\gamma}$ 下的风险函数式(1)可以写成如下形式

$$J(\bar{\gamma}) = \int \sum_{x \in \{+1, -1\}} c(\bar{\gamma}(Y), x) p(Y | x) p(x) dY$$

进一步求解积分后, 得到决策 $\bar{\gamma}$ 下的风险函数为

$$J(\bar{\gamma}) = \sum_{x \in \{+1, -1\}} p(x) \sum_{u \in \{+1, -1\}} c(u, x) p(u | x; \bar{\gamma})$$

3.2 多传感器情形

在多传感器网络环境中, 为了得到较小的全局风险, 全局检测通常采用集中式和分散式两类方法.

(1)集中式最优决策: 在不考虑在线通信约束且假设信道有足够带宽的情况下, 用变分公式表示的集中式最优决策为

$$\bar{\gamma}(Y) = \arg \min_{u \in \{+1, -1\}^n} \sum_{x \in \{+1, -1\}^n} c(u, x) p(x) p(Y | x)$$

相对应的风险函数为

$$J(\bar{\gamma}) = \sum_{x \in \{+1, -1\}^n} p(x) \sum_{u \in \{+1, -1\}^n} c(u, x) p(u | x; \bar{\gamma}) \quad (3)$$

(2)近似分散式决策: 在严格要求在线通信为零, 即各个节点间不传递任何消息的情况下, 针对每个节点的决策为

$$\bar{\delta}_i(Y_i) = \arg \min_{u_i \in \{+1, -1\}} \sum_{x_i \in \{+1, -1\}} c(u_i, x_i) p(x_i) p(Y_i | x_i)$$

相应的风险函数为

$$J(\delta_i) = \sum_{x_i \in \{+1, -1\}} p(x_i) \sum_{u_i \in \{+1, -1\}} c(u_i, x_i) p(u_i | x_i; \delta_i) \quad (4)$$

对应的集中式和近似分散式决策方法的示意图分别如图 2 和图 3 所示。




图2 集中式决策方法流程图




图3 近似分散式决策流程图




图4 分散式决策方法流程图

上述各图中,集中式时节点 4 被看作为融合中心,虚线表示网络拓扑结构。在图 4 中,

$$u_i = \gamma_i(y_i, u_{pa(i)}), i = 1, 2, 3, 4$$

通常情况下,集中式决策方法(图 2 所示)虽然效果很好,但不适用于能量约束的网络。近似分散式决策方法(图 3 所示)效果则不甚理想。因此,考虑图 4 描述的分散式决策情形,当加入信道模型且信道带宽是有限时,每个信道只能传递一个符号决策,这便又会使问题变得很复杂。

4 队决策方法

若决策 $\gamma^* = (\gamma_1^*, \gamma_2^*, \dots, \gamma_n^*)$ 对应的风险为 $J(\gamma^*)$ ^[12],如果改变任意一个节点 i 决策 γ_i ,且设 $\gamma_{\setminus i}^* = \{\gamma_j^* \in \Gamma_j | j \neq i\}$ 是已知确定的,都不能进一步减小全局风险 $J(\gamma^*)$,这样就称决策 γ^* 是 P-B-P 最优的。

假如分散式决策 $\gamma^* = \{\gamma_1^*, \gamma_2^*, \dots, \gamma_n^*\}$ 是基于决策空间 $\Gamma = \Gamma_1 \times \Gamma_2 \times \dots \times \Gamma_n$ 的 P-B-P 最优决策,其中 Γ_i 表示由针对节点 i 的所有可行决策 γ_i 组成的子空间,那么就称 γ_i^* 是关于 Γ_i 最优的

$$\gamma_i^* = \arg \min_{\gamma_i \in \Gamma_i} J(\gamma_{\setminus i}^*, \gamma_i) \quad (5)$$

命题 1 (P-B-P 最优决策):假定

(1) 测量消息 Y_i 与父亲节点 $pa(i)$ 形式的决策 $u_{pa(i)}$ 是无关的,节点间的测量 Y_i 是互相独立。

(2) 节点 i 处的观测值仅与该节点状态的分类相关 $p(Y_i | \mathbf{x}) = p(Y_i | x_i)$ 。

(3) 任意两个节点之间只有一条路连接,即不存在环型连接,且贝叶斯代价函数可以写成加和的形式

$$c(\mathbf{u}, \mathbf{x}) = \sum_{i=1}^n c(u_i, x_i)$$

(4) 它们又分别独立于其它所有节点的测量信息 $\mathbf{Y}_{\setminus i} = \{Y_1, \dots, Y_{i-1}, Y_{i+1}, \dots, Y_n\}$ 和决策 $\mathbf{u}_{\setminus j} = \{u_1, \dots, u_{j-1}, u_{j+1}, \dots, u_n\}$,那么,式(5)就可写成^[11,12]

$$\gamma_i^*(Y_i, \mathbf{u}_{pa(i)}) = \arg \min_{u_i \in \{+1, -1\}} \sum_{x_i \in \{+1, -1\}} \varphi_i^*(u_i, x_i; \mathbf{u}_{pa(i)}) p(Y_i | i)$$

这里,可执行离线计算的 $\varphi_i^*(u_i, x_i; \mathbf{u}_{pa(i)})$ 为

$$\varphi_i^*(u_i, x_i; \mathbf{u}_{pa(i)}) = \sum_{\mathbf{x}} p(\mathbf{x}, \mathbf{u}_{pa(i)}) \times \sum_{u_{\setminus i}} c(\mathbf{u}, \mathbf{x}) \prod_{d \neq i} p(u_d | x_d, \mathbf{u}_{pa(d)}; \gamma_d^*)$$

即

$$\varphi_i^*(u_i, x_i; \mathbf{u}_{pa(i)}) \propto p(x_i) P_i^*(\mathbf{u}_{pa(i)} | x_i) \times [c(u_i, x_i) + C_i^*(u_i, x_i)] \quad (6)$$

上式中似然函数消息 $P_i^*(\mathbf{u}_{pa(i)} | x_i)$ 的具体形式

$$P_i^*(\mathbf{u}_{pa(i)} | x_i) = \begin{cases} 1, & pa(i) \text{ 为空集} \\ \sum_{x_{pa(i)}} p(x_{pa(i)} | x_i) \prod_{j \in pa(i)} P_{j \rightarrow i}^*(u_j | x_j), & \text{其他} \end{cases}$$

$$P_{j \rightarrow i}^*(u_j | x_j) = \sum_{\mathbf{u}_{pa(j)}} P_j^*(\mathbf{u}_{pa(j)} | x_j) \times p(u_j | x_j, \mathbf{u}_{pa(j)}; \gamma_j^*) \quad (7)$$

其中, $P_{j \rightarrow i}^*(u_j | x_j)$ 表示父亲节点 j 传给节点 i 的似然函数消息。

式(6)中的代价函数消息 $C_i^*(u_i, x_i)$ 为

$$C_i^*(u_i, x_i) = \begin{cases} 0, & ch(i) \text{ 为空集} \\ \sum_{l \in ch(i)} C_{l \rightarrow i}^*(u_l, x_l), & \text{其他} \end{cases} \quad (8)$$

$$C_{l \rightarrow i}^*(u_l, x_l) = \sum_{x_i} \sum_{u_i} (c(u_l, x_l) + C_l^*(u_l, x_l)) \times Q_{l \rightarrow i}^*(u_l, x_l | u_i, x_i) \quad (9)$$

$$Q_{l \rightarrow i}^*(u_l, x_l | u_i, x_i) = \sum_{x_{pa(l)}} p(x_{pa(l)}, x_l | x_i) \times \sum_{\mathbf{u}_{pa(l) \setminus i}} p(u_l | x_l, \mathbf{u}_{pa(l)}; \gamma_l^*) \times \prod_{m \in pa(l) \setminus i} P_{m \rightarrow l}^*(u_m | x_m) \quad (10)$$

其中, $C_{l \rightarrow i}^*(u_l, x_l)$ 表示孩子节点 l 传递给节点 i 的代价

函数消息.

联立式(6)~(10),可建立方程组如下

$$\begin{cases} \varphi_i = f_i(P_{pa(i) \rightarrow i}, C_{ch(i) \rightarrow i}) \\ P_{i \rightarrow ch(i)} = g_i(\varphi_i, P_{pa(i) \rightarrow i}) \\ C_{i \rightarrow pa(i)} = h_i(\varphi_i, P_{pa(i) \rightarrow i}, C_{ch(i) \rightarrow i}) \end{cases} \quad i = 1, 2, 3, 4 \quad (11)$$

若令

$$\Theta = [\varphi_1, \dots, \varphi_n, P_{1 \rightarrow ch(1)}, \dots,$$

$$P_{n \rightarrow ch(n)}, C_{1 \rightarrow pa(1)}, \dots, C_{n \rightarrow pa(n)}]^T$$

$$F = [f_1, \dots, f_n, g_1, \dots, g_n, h_1, \dots, h_n]^T$$

那么,就可将式(11)写成具有不动点形式的方程组 $\Theta = F(\Theta)$. 类似于命题 1 的求解方法, Θ 也可以用迭代法求出 $\Theta^{k+1} = F(\Theta^k)$, 具体的步骤如下

$$P_{i \rightarrow ch(i)}^k := g_i(\varphi_i^{k-1}, P_{pa(i) \rightarrow i}^k), i = 1, 2, \dots, n \quad (12)$$

$$\varphi_i^k := f_i(P_{pa(i) \rightarrow i}^k, C_{ch(i) \rightarrow i}^k), i = n, \dots, 1 \quad (13)$$

$$C_{i \rightarrow pa(i)}^k := h_i(\varphi_i^k, P_{pa(i) \rightarrow i}^k, C_{ch(i) \rightarrow i}^k) \quad (14)$$

给出针对图 1 拓扑结构的
消息传递示意图如图 5 所示,其中,①表示似然函数消息的传递;②表示局部决策的更新;③表示代价函数消息的传递.




图5 离线计算中,第k步迭代的分散式消息传递算法示意图

具体过程为:

(1)首先根据初始参数 $\varphi^0 = (\varphi_1^0, \dots, \varphi_n^0)$, 计算得到节点 1 和节点 2 各自到节点 3 的似然函数消息①,再结合求得的似然函数消息①求出到节点 4 的似然函数消息①. 然后节点 4 根据得到的似然函数消息①更新其局部决策②,并计算出传递代价函数消息③给节点 3,进而更新父 3 的局部决策②,依次完成第一次迭代.

(2)进行第二次迭代,首先正序进行①直到节点 4;

(3)更新节点 4 的局部决策②,再得出节点 4 对节点 3 的代价函数消息③;

(4)再更新节点 3 的局部决策规则②. 依次传递,更新了所有节点的局部决策. 这样一次完整的迭代结束;

(5)计算系统的贝叶斯风险 J^k , 如果 $J^{k-1} - J^k < \zeta$, 则令 $k = k + 1$ 并转至第 1)步继续循环, 否则终止循环.

给定初始准则参数 $\varphi^0 = (\varphi_1^0, \dots, \varphi_n^0)$, 可以通过式(12)~(14)迭代得到收敛数列 $\{\varphi^k\}$ 和全局风险数列

$$J(\mathcal{Y}^k) = \sum_i \sum_{x_i} \sum_{u_{pa(i)}} p(x_i, \mathbf{u}_{pa(i)}) \sum_{u_i} c(u_i, x_i) \times P_i^{k+1}(\mathbf{u}_{pa(i)} | x_i) p(u_i | x_i, \mathbf{u}_{pa(i)}; \varphi_i^k) \quad (15)$$

由式(6)可知,节点 i 的似然函数 P_i^{k+1} 仅依赖节点 i 的全体父亲节点 $pa(i)$, 是可局部计算得到的.

5 计算量分析

本节将对三种决策方法的计算复杂度进行分析.

(1)集中式最优决策. 考虑 n 个节点的所有状态的分类情况和决策的组合, 参考风险函数式(3), 则有 2^n 种可能的组合, 可知该类型网络的计算复杂度为 $O(2^n)$. 而且需要将每个节点的测量都传至融合中心, 这样要求很大的信道带宽, 消耗很多的能量.

(2)离散式近似决策. 只需要分别计算每个节点的决策和风险(4), 那么有 $2n$ 种可能的组合, 可知该类型的网络的计算复杂度为 $O(2 \times n)$. 不需要传递任何符号.

(3)本文的分散式决策. 根据风险函数(15), 以及消息迭代过程可知, 计算复杂度为 $O(2 \times k \times n)$. 只需要传递自身决策给最近邻, 每个信道只传了一个决策值.

考虑图 1 的网络, 假设传感器传输消息的能耗与传输的距离的平方成正比, 同时假设传递一个测量值的能耗为 a , 传递一个决策值的能耗为 b , 通常 $a > b$, 节点间的距离均为 d .

表 1 给出了满二叉树结构的能耗(t)在不同类型情况下的对比情况, 其中 t 表示子叶节点数目, m 表示树的高度. 通过对比可以明显看出, 队决策方法比集中式决策传递过程中的耗能更少. 由于近似分散式决策中, 每个节点都可以看作为单独的系统, 且互不通信, 所以其传递的能量消耗为零.

表 1 不同类型下的能耗对比

类型	集中式	近似分散式	队决策
传递能耗(4)	$10ad^2$	0	$6bd^2$
传递能耗(8)	$34ad^2$	0	$14bd^2$
传递能耗(t)	$(t^m + (t/2)^{m-1} + \dots + 2)ad^2$	0	$(2t - 2)bd^2$

6 仿真实验

考虑拓扑结构为图 1 形式的网络. 对任意节点 i , $x_i = +1$ 表示目标以概率为 $p(x_i = +1) = 0.7$ 发生了机动; 当 $x_i = -1$ 时表示目标以概率为 $p(x_i = -1) = 0.3$ 未发生机动. 设 \mathbf{x} 的分布为

$$p(\mathbf{x}) \propto \prod_{(i,j) \in A} \psi(x_i, x_j) \quad (16)$$

其中

$$\psi(x_i, x_j) = \begin{cases} w, & x_i = x_j \\ 1 - w, & x_i \neq x_j \end{cases}$$

上式中, w 表示节点状态之间的相关性.

通过边缘化式(16), 可得到 $p(\mathbf{x}_{pa(i)}, x_i)$. 例如, 针对模型图 1 中, 有

$$p(x_1, x_2, x_3) \propto \psi(x_1, x_3) \psi(x_2, x_3)$$

定义代价函数为

$$c(u_i, x_i) = \begin{cases} 1, & u_i \neq x_i \\ 0, & u_i = x_i \end{cases}$$

测量模型为

$$Y_i = \mu^{x_i} + v_i$$

其中, μ^{+1} 表示目标发生机动的信号, 其均值为 $r/2$, μ^{-1} 表示目标未发生机动的信号, 其均值为 $-r/2$, $r \in (0, \infty)$ 为信噪比, 与噪声 v_i 成反比关系. v_i 是均值为零的、方差为 1 的高斯白噪声. 各节点的测量值是统计独立且符合高斯分布

$$p(Y_i | x_i) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(Y_i - \frac{rx_i}{2}\right)^2\right) \quad (17)$$

$(x_i, Y_i) \in \{+1, -1\} \times \mathbf{R}$

参考 3.1 节, 近似策略可变成门限值测试, 参数 $\bar{\varphi}(u_i, x_i) = p(x_i) c(u_i, x_i)$ 决定的门限取值为

$$p(Y_i | +1)/p(Y_i | -1) = \exp(rY_i) = \Lambda_i(Y_i) \begin{cases} > \bar{\eta}_i, u_i = +1 \\ < \bar{\eta}_i, u_i = -1 \end{cases} \quad (18)$$

其中, $\bar{\eta}_i \equiv \frac{\bar{\varphi}_i(+1, -1) - \bar{\varphi}_i(-1, -1)}{\bar{\varphi}_i(-1, +1) - \bar{\varphi}_i(+1, +1)}$

将式(17)带入式(18)中, 可以得到测量值的阈值

$$Y_i \begin{cases} > \log(\bar{\eta}_i)/r, & u_i = +1 \\ < \log(\bar{\eta}_i)/r, & u_i = -1 \end{cases}$$

所以, $p_{u_i|x_i}(+1|x_i) = \int_{\log(\bar{\eta}_i)/r}^{\infty} p(Y_i | x_i) dY_i$

上式中, 当 $x_i = 1$, 表示检测概率 P_d ; 当 $x_i = -1$ 表示虚警概率 P_f .

仿真结果如表 2、表 3、图 6、图 7 所示. 表 2 是通过 100 次蒙特卡罗仿真实验的得到的, 当全局风险 $J^{k-1} - J^k < 10^{-3}$ 时, 迭代停止. 第 2 行表示节点 4 只根据自身的信息得到的检测概率; 第 3 行表示根据自身和邻居节点的信息, 按照队决策方法运算后得到的检测概率. 比较第 2 行和第 3 行可知, 该算法可以有效地提高检测概率. 由第 4 行和第 5 行可知, 该算法可以有效的减小全局风险, 在具体仿真中发现该算法在经过有限次数(这里平均 3 次左右)的迭代以后就可达到稳定值. 对比 2、3 列可知, 随着节点间相关性的减小, 迭代次数减少, 而风险却逐渐增大. 对比 3、4 列可知, 随着信噪比的增加, 风险在逐渐减少, 而迭代次数却逐渐增加.

表 2 不同条件下的检测概率和风险的比较

	$(w, r) = (0.9, 1)$	$(w, r) = (0.8, 1)$	$(w, r) = (0.9, 1.5)$
节点 4 的初始检测概率	0.9111	0.9111	0.9057
运算后节点 4 的检测概率	0.9701	0.9649	0.9556
初始全局风险	0.7446	0.7446	0.7127
运算后的全局风险	0.3833	0.3871	0.3155
平均迭代次数	2.95	2.89	3.04

表 3 不同相关性下检测概率和每步迭代的全局风险的比较

w	0.55	0.60	0.65	0.7	0.75	0.80	0.85	0.90	0.95
R_0	0.7446	0.7446	0.7446	0.7446	0.7446	0.7446	0.7446	0.7446	0.7446
R_1	0.6268	0.6866	0.6865	0.6861	0.6856	0.6851	0.6844	0.6835	0.6821
R_2	0.5091	0.5090	0.4998	0.4995	0.4991	0.4985	0.4979	0.4968	0.4957
R_3	0.3911	0.3909	0.3904	0.3895	0.3884	0.3869	0.3853	0.3833	0.3811
P_{d4}	0.9139	0.9217	0.9374	0.9499	0.9590	0.9650	0.9686	0.9707	0.9728

为了更清晰的分析参数 w 对全局风险以及运算后节点 4 的检测概率 P_{d4} 的影响, 这里设置 $r = 1$ 进行了一次仿真. 表 3 中 $R_i (i = 0, 1, 2, 3)$ 表示第 i 次迭代后的全局风险. 通过对比每行中的 R_i , 可以明显发现随着迭代次数 i 的增加, 全局风险逐渐减小; 对比每列, 明显看出随着相关性的增加, 全局风险在逐渐减小, 但是检测概率却逐渐的增大.

图 6 和图 7 详细描述了参数 r 对全局风险和平均检测概率的影响, 并与近似分散式进行了对比. 图 6 中, 队决策方法和近似分散式方法进行比较, 尽管各自的全局风险都随着信噪比的增加而减小, 但始终是队决策方法的风险较小. 图 7 可以看出对于不同的信噪比, 队决策方法的平均检测概率始终比近似分散式方法的平均检测概率大. 队决策方法的风险较小.




图 6 不同决策方法的全局风险比较示意图




图 7 不同决策方法的平均检测概率比较示意图

总之, 通过仿真分析了参数 w 和 r 对队决策方法检测性能的影响. 而且, 通过与近似分散式决策方法进行比较, 说明队决策方法可以有效地进行检测, 并且验证了队决策方法的优越性.

7 结论

本文参考信念传递算法,在一定假设下,按照贝叶斯公式和图模型的一些算法进行推导,得到具有线性复杂度的队决策方法.这种算法可以分为离线计算和在线计算两部分,在离线计算的每步迭代中只接收最近邻的消息,并根据这些消息调整局部决策准则.通过了简单结构网络的仿真,逐个分析了相关性、信噪比等参数对决策结果和全局风险的影响,并通过与近似分散式决策进行对比,说明了该算法的优越性.

本文考虑的决策范围是在假设每个节点都做决策的前提下得到的,仍存在着不足和待进一步研究的内容:

(1) 本文并没有给出不动点方程 $\theta = f(\theta)$ 的解存在性及其唯一性的理论证明,以及全局风险数列 $\{J(\gamma^k)\}$ 收敛的公式推导,只是通过仿真进行了说明.

(2) 考虑存在节点不做决策的情形,即节点 i 做出的决策范围为 $u_i = \{+1, 0, -1\}$, 或者多元决策情形,同时增加信道模型,对能量消耗、节点利用率以及决策性能进行权衡.进一步根据 $u_i = 0$ 考虑对等网络的自组织和自适应进行探索.

参考文献

- [1] C Y Chong and S P Kumar. Sensor networks: Evolution, opportunities, and challenges[J]. Proceedings of IEEE, 2003, 91(8): 1247 - 1256.
- [2] R R Tenny, N R Sandell Jr. Detection with distributed sensors [J]. IEEE Transactions on Aerospace and Electronic Systems, 1981, 17(4): 689 - 692.
- [3] J Pearl. Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference[M]. San Francisco: Morgan Kaufmann Publishers, inc, 1988. 277 - 306.
- [4] Dr. Dmitry Malioutov. Walk-sums and belief propagation in gaussian graphical models [J]. Journal of Machine Learning Research, 2006, 7(10): 2031 - 2064.
- [5] J N Tsitsiklis. Decentralized detection[J]. Advances in Statistical Signal Processing, 1993, 2(4): 297 - 344.
- [6] Z B Tang, K R Pattipati and D L Kleinman. An algorithm for determining the decision thresholds in a distributed detection problem[J]. IEEE Transactions on Systems, Man and Cybernetics, 1991, 21(1): 231 - 237.

- [7] A S Willsky. Multiresolution markov models for signal and image processing[J]. Proceedings of IEEE, 2002, 90(8): 1396 - 1458.
- [8] Martin J Wainwright, Michael I Jordan. Graphical models, exponential families, and variational inference [J]. Foundations and Trends in Machine Learning, 2008, 1(1-2): 37 - 74.
- [9] M I Jordan, et al. Learning in Graphical Models[M]. Cambridge, Massachusetts: MIT Press, 1999. 105 - 161.
- [10] Miguel, Antonio, Ortega, Alfonso, Buera, Luis, Lleida, Eduardo. Graphical models for discrete hidden Markov models in speech recognition[A]. Proceedings of the 10th Annual Conference of international Speech Communication Association [C]. Brighton, U K: INTERSPEECH, 2009. 1411 - 1414.
- [11] R Rander. Team decision problem[J]. The Annals of Mathematical Statistics, 1962, 33(3): 857 - 881.
- [12] O Patrick Kreidl, Alan S Willsky. An efficient message passing algorithm for optimizing decentralized detection network [A]. Proceedings of the 45th IEEE Conference on Decision and Control[C]. Piscataway, N J: IEEE Control Systems Society, 2010. 563 - 578.

作者简介



文成林 男, 1963 年出生于河南开封, 博士(后), 教授, 博士生导师. 1999 年于西北工业大学获得博士学位. 主要研究方向为: 多源信息融合与目标技术, 系统安全检测、监控与故障诊断技术.

E-mail: wencil@hdu.edu.cn



方正 男, 1986 年出生于河南新乡, 杭州电子科技大学自动化学院硕士研究生, 感兴趣的研究方向为: 多源信息融合及信息处理、无线传传感器网络检测.

E-mail: fangzheng939@163.com