

引用格式: 谌达, 胡波, 冯辉. 考虑切换损失的多目标搜索策略[J]. 微电子学与计算机, 2019, 36(11): 89-94. [CHEN D, HU B, FENG H. Multi-target search with switching cost [J]. Microelectronics & Computer, 2019, 36(11): 89-94]

考虑切换损失的多目标搜索策略

谌 达, 胡 波, 冯 辉

(复旦大学 信息科学与工程学院 智慧网络与系统研究中心, 上海 200433)

摘 要: 考虑在固定区域内进行多目标搜索的问题, 搜索策略的性能不仅与观测次数、判决正确率有关, 也会受切换观测区域时切换损失的影响. 对此提出一种基于主动假设检验模型的多目标搜索策略, 它能帮助决策者在很少的切换开销下快速找到所有目标. 理论证明了所提策略可渐进最小化搜索的贝叶斯风险, 且仿真表明在有限时间内, 其性能也优于其他的对比算法. 该策略可扩展至异常检测、欺诈扫描等多个应用领域.

关键词: 主动假设检验; 切换损失; 目标搜索

中图分类号: TN911. 23

文献标识码: A

文章编号: 1000—7180(2019)11—0089—06

Multi-target search with switching cost

CHEN Da, HU Bo, FENG Hui

(Research Center of Smart Networks and Systems, School of Information Science and Technology,
Fudan University, Shanghai 200433, China)

Abstract: The problem that detecting multiple targets among a finite number of regions is considered. The performance of the search strategy is not only related to the number of observations and the detection error, but also costs associated with switching across regions. We propose a multi-target search strategy based on the active hypothesis testing, which can help decision makers find all targets quickly with little switching cost. It's proved that the policy is asymptotically optimal. Meanwhile, which offers better performance in finite regime by simulations. Our policy can also be applied to anomaly detection, fraud detection and other read-world scenarios.

Key words: active hypothesis testing; switching cost; target search

1 引言

目标搜索^[1-3]在实际场景中应用广泛, 好的搜索策略能有效减少搜索时间和实施成本, 提高判决准确率. 本文考虑单个决策者在固定区域内搜索多个目标的问题. 决策者每次可以选择一个区域进行观测, 由于每次的观测结果不一定准确, 因此需要经过多次观测才能做出判决. 本文希望能找到一种目标搜索策略, 帮助决策者快速找出所有目标的位置.

一个目标搜索策略由选择规则、停止规则和判决规则三部分组成. 选择规则决定每次选择哪个区

域进行观测; 停止规则决定何时停止搜索; 判决规则给出最后的结论. 针对以上问题, 传统的搜索策略^[4-9]往往只考虑观测损失和误判概率, 却会忽略切换观测区域对搜索造成的影响, 但这在很多实际场景中并不适用. 例如, 在机器人搜索场景中, 不仅在单个区域内搜索会消耗电量与时间, 切换观测区域同样也会造成消耗, 因此过多的区域切换会影响搜索性能. 在医疗诊断领域, 频繁而快速的切换药物或治疗方法也会对病人带来更高的风险. 因此, 本文修改了搜索策略的性能指标, 它不仅包含了误判概率和观测损失, 同时也会考虑切换损失的影响, 在此基

础上提出算法以解决该问题。

本文所研究的问题可追溯至 Chernoff 在文献[4]中提出的主动假设检验(Active Hypothesis Testing)模型。Chernoff 针对一般性的两类假设检验问题提出了一种随机性的策略(称为 Chernoff 策略),并且证明了该策略随着观测代价 $c \rightarrow 0$ 是渐近最优的。许多学者对主动假设检验问题进行了研究和扩展。Bessler 将 Chernoff 的策略扩展到了有多个简单假设的情况^[5]。Naghshvar 和 Javidi 从最小化贝叶斯风险的角度研究了不同场景下的主动假设检验问题^[6-7]。近几年 Cohen 和 Zhao 将主动假设检验应用到了异常检测领域^[8-9],他们提出了一种渐进最优的搜索算法(称为 DGF 策略),DGF 策略计算复杂度低,在有限时间内表现更好。

然而,很少有算法考虑切换损失对于主动假设检验问题的影响,在文献[10]中作者对 Chernoff 策略进行了修正(称为 Sluggish 策略),它引入了切换参数 η 决定 Chernoff 策略的切换概率,并且证明了他们的算法在 $\eta \rightarrow 0$ 时是渐进最优的,但是 Sluggish 策略会造成较多的观测浪费。文献[11]提出了考虑切换损失的单异常检验算法,但是它没有办法解决多目标的场景。

本文针对考虑切换损失的多目标搜索问题提出了一种低复杂度的搜索算法,它被称为 DBS (Deterministic Bounded Switching) 策略。DBS 策略将该目标搜索问题划分为两种情况,在第一种情况下,它会不断搜索最可能有目标的区域,在找到所有目标区域时停止搜索;另一种情况下,DBS 策略使用排除法,它不断观测那些更可能没有目标的区域,在排除所有无目标区域后得到最终结论。本文不仅在理论上证明了该策略的渐近最优性,而且通过仿真说明了它在有限时间内的良好表现。

2 问题建模

考虑以下问题:决策者在 M 个区域内搜索 L ($1 \leq L \leq M$) 个目标, L 的大小已知。每次决策者可以任选一个区域进行观测,由于单次观测带有噪声,决策者需要在多次观测后才能做出判决。在一定的阈值下,希望能最小化搜索的贝叶斯风险。

因为在 M 个待检测区域中有 L 个区域存在目标,所以共有 $M = C_M^L$ 个假设,其中只有一个为真。用 H_i 表示所有可能假设中的第 i 个, π_i 表示 H_i 为真的先验概率。

在每个时刻,决策者可以从 M 个区域中任选一

个进行观测,定义 $y_m(n)$ 为时刻 n 观测区域 m 得到的结果。由于每次的观测带有噪声,我们假设不同区域的观测结果分别服从两类不同的分布:若区域 m 有目标, $y_m(n)$ 服从分布 $g(y)$; 否则 $y_m(n)$ 服从分布 $f(y)$ 。实际问题中两个分布可以通过样本统计得到。

让 $\Gamma = (\tau, \delta, \Phi)$ 表示目标搜索问题的一个可行策略,其中 τ 为搜索策略的停止时间; δ 是搜索策略的判决规则,若在搜索停止时判定 H_i 为真,则 δ 为 H_i 所对应的区域的集合; $\Phi = \{\varphi(n)\}_{n=1}^{\tau}$ 是选择规则,它告诉决策者每个时刻选择哪个区域进行观测。

用 P_i 表示 H_i 为真时某事件的条件概率,用 E_i 表示 H_i 为真时某变量的条件期望。定义 $P_e(\Gamma) = \sum_{i=1}^M \pi_i \alpha_i(\Gamma)$ 为策略 Γ 下的误判概率,其中 $\alpha_i(\Gamma) = P_i(\delta \neq H_i | \Gamma)$,它表示 H_i 为真时误判的概率。定义 $E(\tau | \Gamma) = \sum_{i=1}^M \pi_i E_i(\tau | \Gamma)$ 为策略 Γ 观测次数的期望,也就是该策略的平均搜索时间。定义 τ_s 为搜索过程的总切换次数, $E(\tau_s | \Gamma) = \sum_{i=1}^M \pi_i E_i(\tau_s | \Gamma)$ 为策略 Γ 所需切换次数的期望。

不失一般性,本文把错判损失看成 1,用 c 表示每次行动造成的观测损失, c 越小说明单次观测的损失越小,此时搜索策略可以通过更多的观测次数达到更高的准确率。定义 s 为每次切换观测区域造成的切换损失。在实际的物理场景中,切换损失与观测损失的比值一般是有限的,因此我们假设 c 和 s 满足 $s/c < \infty$ 。遵循文献[6-8]中的贝叶斯建模方式, H_i 为真时策略 Γ 的贝叶斯风险可以用如下形式表示:

$$R_i(\Gamma) = \alpha_i(\Gamma) + c E_i(\tau | \Gamma) + s E_i(\tau_s | \Gamma) \quad (1)$$

因此总的贝叶斯风险可以表示为:

$$\begin{aligned} R(\Gamma) &= \sum_{i=1}^M \pi_i R_m(\Gamma) \\ &= P_e(\Gamma) + c E(\tau | \Gamma) + s E(\tau_s | \Gamma) \end{aligned} \quad (2)$$

目标是找到一个最优策略 Γ 来最小化 $R(\Gamma)$ 。

3 搜索算法

针对该问题,本文提出了一种低复杂度的搜索策略,并称之为 DBS 策略(Deterministic Bounded Switching Policy)。

3.1 符号定义

由于每次只能观测一个区域,让 $1_m(n)$ 代表区域 m 在时刻 n 的观测情况,若区域 m 在时刻 n 被观

测,则 $1_m(n) = 1$; 否则 $1_m(n) = 0$. 定义区域 m 在时刻 n 的对数似然比(Log Likelihood Ratio, LLR) 为

$$l_m(n) = \log \frac{g(y_m(n))}{f(y_m(n))} \quad (3)$$

对数似然比能反映某个区域所属分布的特性,当区域 m 服从分布 $g(y)$ 时, $E_m(l_m(n)) = D(g || f) > 0$, 当区域 m 服从分布 $f(y)$ 时, $E_m(l_m(n)) = -D(f || g) < 0$, 其中 $D(\cdot || \cdot)$ 为两个分布的 KL 散度(Kullback-Leibler divergence). 同样定义区域 m 从时刻 1 到时刻 n 观测的总对数似然比(Sum Log Likelihood Ratios, LLRs) 为

$$S_m(n) = \sum_{t=1}^n l_m(t) 1_m(t) \quad (4)$$

若区域 m 有目标,则 $S_m(n)$ 会随着观测次数的增多而增大; 若区域 m 无目标,则 $S_m(n)$ 会随着观测次数的增多而减小. 因此可以把某个区域的 LLRs 看成是对该区域是否有目标的置信度的打分,分数越高说明越可能有目标; 分数越低,说明越可能没有目标. 我们用 $m^i(n)$ 表示 n 时刻 LLRs 排名第 i 大的区域.

3.2 DBS 策略

在每个时刻 n , DBS 策略会根据每个区域 LLRs 的大小对所有区域按照从大到小的顺序进行排序(若两个区域的 LLRs 相同,可以任意排列顺序),并根据排序情况选择对应区域进行观测. 在进行目标搜索的时候有两种方法,一种是直接选择法; 另一种是排除法. 与此类似, DBS 算法将根据 $\frac{D(f || g)}{M-L}$ 与 $\frac{D(g || f)}{L} + \Delta(M, L)$ 的大小关系将整个问题分成两种情况分别设计策略,其中

$$\Delta(M, L) = \frac{s(M-2L)D(g || f)D(f || g)}{-cL(M-L)\log c} \quad (5)$$

它是切换损失造成的偏置值,为了方便后续分析,我们定义两种情况如下:

$$\begin{aligned} \text{Case I: } & \frac{D(g || f)}{L} + \Delta(M, L) \geq \frac{D(f || g)}{M-L} \\ \text{Case II: } & \frac{D(g || f)}{L} + \Delta(M, L) < \frac{D(f || g)}{M-L} \end{aligned} \quad (6)$$

在 Case I, DBS 策略使用直接选择法,每次都会选择当前时刻最可能有目标的区域进行观测,依次找出所有目标. 我们让 $-\log c$ 作为有目标区域的判决门限,定义 $A(n) = \{m: S_m(n) > -\log c\}$ 为在时刻 n 有足够的确信度判定为目标的所有区域的集合.

此时选择规则、停止规则、判决规则分别如下:

$$\varphi(n) = \tilde{m}^1(n) \quad (7)$$

$$\tau = \min\{n: |A(n)| = L\} \quad (8)$$

$$\delta = A(\tau) \quad (9)$$

式中, $\tilde{m}^1(n) = \operatorname{argmax}_{m \notin A(n)} S_m(n)$ 为时刻 n 时所有尚未判定的区域中 LLRs 最大的区域,也就是未判决区域中最可能有目标的区域.

在 Case II 中, DBS 策略使用排除法,每次都选择当前时刻最不可能有目标的区域进行观测,逐渐排除无目标区域. 我们让 $\log c$ 作为无目标区域的判决门限,定义 $B(n) = \{m: S_m(n) < \log c\}$ 为在时刻 n 有足够的确信度判定为无目标的所有区域的集合. 此时的选择规则、停止规则、判决规则分别如下:

$$\varphi(n) = \tilde{m}^{-1}(n) \quad (10)$$

$$\tau = \inf\{n: |B(n)| = M-L\} \quad (11)$$

$$\delta = M(\tau) \quad (12)$$

式中, $\tilde{m}^{-1}(n) = \operatorname{argmin}_{m \notin B(n)} S_m(n)$ 为所有未判定区域中 LLRs 最小的区域,也就是未判决区域中最不可能有目标的区域. 而 $M = \{1, 2, \dots, M\}$ 为所有区域的集合. 接下来我们将结合图 1 直观的对 DBS 策略进行解释.




图 1 $M=5, L=2$ 时 DBS 策略流程示例

在 Case I 情况下, DBS 策略使用直接选择法进行搜索,它不断观测区域 $\tilde{m}^1(n)$ 区域. 假设真实情况是目标处于区域 m 内. 对于区域 m 来说,由于它的观测满足分布 $g(y)$,在观测该区域时 LLR 的期望为 $E_m(l_m(n)) = D(g || f) > 0$,所以随着观测次数增多,区域 m 的 LLRs 在期望上会逐渐增加;而对于其他无目标区域 j 来说情况则正好相反,它们 LLR 的期望为 $E_j(l_j(n)) = -D(f || g) < 0$,因此区域 j 的 LLRs 在期望上会逐渐减少. 在开始阶段,所有假

设的 LLRs 都为 0, DBS 策略会对所有区域进行排序, 选择 LLRs 最大的区域进行观测. 图 1 中先观测了区域 1, 因为这个区域没有目标, 被观测后它的 LLRs 减少, 排序后移, 此时观测区域 2, 同样区域 2 的排序也后移, 当检测到区域 3 时, 由于它的 LLRs 会增大, 所以它的排名会一直是第一, DBS 策略将会一直观测该区域, 直到能确定它存在目标为止, 此时第一阶段结束. 在图 1 中 $L = 2$, 所以共有两个阶段, 每个阶段都会有一个目标区域被识别出来, 当所有的目标区域都被找到, 即 $A(\tau)$ 的元素个数为 L 时, 搜索停止. 由于位置切换只会在每个阶段的初始几次观测时发生. 所以当 $c \rightarrow 0$ 时, 期望观测时间约为 $-L \log c / D(g || f)$, 切换次数至少为 $L - 1$ 次.

在 Case II 中, DBS 策略使用排除法搜索目标, 它不断观测区域 $\tilde{m}^{-1}(n)$. 一开始所有区域的 LLRs 都是 0, 随机选择区域 5 进行观测, 因为区域 5 没有目标, 它的 LLRs 在期望上会减少, 所以 DBS 策略会一直对区域 5 进行观测, 直到达到判定阈值, 阶段 1 结束; 接着观测区域 3 和区域 4, 因为这两个区域有目标, 所以它们 LLRs 的排序会快速前移, DBS 策略将切换到区域 2 进行观测, 直到第二阶段结束. 在图 1 中一共有 $M - L = 3$ 个无目标区域, 因此 Case II 在这里有三个阶段, 每个阶段都会排除一个无目标区域, 当所有的无目标区域都被排除, 即集合 $B(n)$ 的元素个数为 $M - L$ 时, 搜索停止, 剩下的即为目标. 同样位置切换只会在每个阶段的开始时间发生, 因此切换次数也是有限的. 在 $c \rightarrow 0$ 时, 期望观测时间约为 $-(M - L) \log c / D(f || g)$, 切换次数至少为 $M - L - 1$.

在不考虑切换损失的场景下, 选择直接选择法还是排除法可以通过比较 $-L \log c / D(g || f)$ 与 $-(M - L) \log c / D(f || g)$ 的大小, 即比较 $\frac{D(g || f)}{L}$ 与 $\frac{D(f || g)}{M - L}$ 来决定. 但是, 由于在每个阶段的初始时期都会有位置切换发生, 且切换次数的高低与 L 和 M 的大小有关. 考虑到切换损失对策略的影响, 我们引入了偏置值 $\Delta(M, L)$, 所以最终两种情况的划分如公式 (6) 所示. 由公式 (5) 可知 $c \rightarrow 0$ 时 $\Delta(M, L)$ 趋近于 0, 因此 $\Delta(M, L)$ 并不影响 DBS 策略在渐进范围内的表现. 但是 $\Delta(M, L)$ 的存在能让 DBS 策略在有限区间内的表现更好, 之后会通过仿真加以说明.

3.3 理论分析

在有限时间内, 每次的观测结果带有随机性, 很

难分析算法性能, 相关研究^[4-11] 都是采用渐进分析来评价算法在观测数据量非常大, 观测代价 c 很小时的表现. 因此本文将对 DBS 策略进行渐进分析. 下面的定理说明 DBS 策略在 $c \rightarrow 0$ 时可以取得最小的贝叶斯风险, 此时称为渐进最优.

定理 1 (DBS 策略的渐进最优性): 让 R^* 与 $R(\Gamma)$ 分别表示 DBS 策略和任何其他策略 Γ 的贝叶斯风险, 那么, 当 $c \rightarrow 0$, 且 $\limsup_{c \rightarrow 0} \frac{s}{c} < \infty$ 时

$$R^* \sim \frac{-c \log c}{I^*(M, L)} \sim \inf_{\Gamma} R(\Gamma)$$

式中, 符号 $f \sim g$ 表示 $\lim_{c \rightarrow 0} f/g = 1$. 符号 $I^*(M, L)$ 的定义如下:

$$I^*(M, L) \triangleq \begin{cases} \frac{D(g || f)}{L}, & \text{if Case I} \\ \frac{D(f || g)}{(M - L)}, & \text{if Case II} \end{cases} \quad (13)$$

4 仿真与分析

为了验证 DBS 算法在有限时间内的表现, 接下来将通过仿真说明 DBS 策略与 Chernoff 策略^[4]、DGF 策略^[8]、Sluggish 策略^[10] 的性能差别.

首先定义 $R_{LB} = -c \log c / I^*(M, L)$ 为 $c \rightarrow 0$ 时的贝叶斯风险渐进下界. 定义 $L(\Gamma) = (R(\Gamma) - R_{LB}) / R_{LB}$ 为在策略 Γ 下贝叶斯风险对于渐进下界的相对风险, 它提供了算法在有限时间内表现的度量.

4.1 实验设计

在视觉目标搜索的场景中, 识别算法的结果非 0 即 1, 因此可将单次观测结果抽象为服从二项分布. 假定区域存在目标时观测服从二项分布 $\text{Bino}(\lambda_g)$, 否则服从二项分布 $\text{Bino}(\lambda_f)$, 此时 KL 散度计算如下:

$$\begin{aligned} D(g || f) &= \lambda_g \log\left(\frac{\lambda_g}{\lambda_f}\right) + (1 - \lambda_g) \log\left(\frac{1 - \lambda_g}{1 - \lambda_f}\right) \\ D(f || g) &= \lambda_f \log\left(\frac{\lambda_f}{\lambda_g}\right) + (1 - \lambda_f) \log\left(\frac{1 - \lambda_f}{1 - \lambda_g}\right) \end{aligned} \quad (14)$$

假设总区域数目 $M = 7$, 目标数目 $L = 3$, 切换损失 $s = 3c$. 因为 c 的大小决定了搜索策略的判决门限, 我们针对 $-\log c$ 为 2 ~ 20 的不同取值, 各进行 1 000 次实验, 取误判概率、观测次数、切换概率以及贝叶斯相对风险的平均值来比较算法的性能. 在 Sluggish 策略中, 因为过低的切换概率会导致较高的观测损失, 设置 Sluggish 策略的切换因子 $\eta = 0.1$.

假设两个分布的参数分别为 $\lambda_f = 0.45, \lambda_g = 0.9$, 此时 $\frac{D(g||f)}{L} \approx 0.151, \frac{D(f||g)}{(M-L)} = 0.156$, 且 $\frac{D(f||g)}{(M-L)} > \frac{D(g||f)}{L}$. 所有算法的表现如图 2 所示.




图 2 $\lambda_f = 0.45, \lambda_g = 0.9$ 时四种算法的二项分布仿真结果

从图 2(a) 中可以看出, DGF 策略与 DBS 策略的观测次数非常贴近渐进下界, 而 Chernoff 策略和 Sluggish 策略的观测次数较多. 从图 2(b) 中可以看出 Chernoff 策略与 DGF 策略的切换概率较高, 而 Sluggish 策略的切换概率略低于 0.1, DBS 策略的切换概率逐渐减少, 且在 $-\log c = 13.4$ 处发生了突变. 这是因为 $-\log c \leq 13.4$ 时, $\frac{D(g||f)}{L} + \Delta(M, L) \geq \frac{D(f||g)}{M-L}$, DBS 策略为了减少切换损失, 此时会使用阶段数更少的直接选择法进行观测, 以降低贝叶斯风险; 在 $-\log c > 13.4$ 时, $\frac{D(g||f)}{L} + \Delta(M, L) < \frac{D(f||g)}{M-L}$, 此时因为判决所需的观测次数增多, DBS 策略会改用排除法进行搜索, 所以切换比例瞬间变大, 但随着 $-\log c$ 不断增大, 最后可达到渐进最优, 这也是在区分两类情况时引入偏置 $\Delta(M, L)$ 的原因, 它能在搜索时兼顾切换损失和观测次数的影响, 取得更好的效果. 从图 2(c) 中可以发现 $-\log c$ 较小时, DGF 策略和 DBS 策略的误判概率较高, 但随着 $-\log c$ 的增大, 误判概率迅速降低, 这是因为我们衡量搜索策略好坏的因素是贝叶斯风

险, 本文把误判损失看成 1, $-\log c$ 较小意味着单次观测损失 c 的值较大, 此时对搜索准确率的要求相对较低, 策略着重于减少观测次数以降低贝叶斯风险; 随着 c 的值减少, 观测次数对总贝叶斯风险的影响减小, 此时可进行多次观测以提高准确率. 在图 2(d) 中可以看出 DBS 策略的贝叶斯相对风险是最低的, 且趋近于 0, 明显优于其他算法.

4.2 各参数对算法性能的影响

4.2.1 观测分布对算法的影响

4.1 节对观测服从二项分布时, $\lambda_f = 0.45, \lambda_g = 0.9$ 时的表现进行了仿真. 实际上, 不同的分布类型和不同的分布参数只会改变 $D(g||f)$ 和 $D(f||g)$ 的大小, 从而对同样停止条件下的搜索时间造成影响, 但无论分布如何变化, DBS 策略的贝叶斯风险均会达到最低; 因此 DBS 策略的算法性能始终会是以上算法中最优的, 这与分布参数的形式和大小无关.

4.2.2 切换损失对算法的影响

在仿真中我们设置 $s = 3c$, 这是切换损失比较大的情况. 实际上, 若 s/c 的比值较小, 意味着切换次数对贝叶斯风险的总体影响不大, 此时 DBS 策略和 DGF 策略的表现较好, 而另外两个策略则会较差. 若 s/c 的比值较大, 意味着切换对搜索造成的影响大, 此时 DBS 策略和 Sluggish 策略会有更好的表现. 因此对于任意 s 值, DBS 策略均能取到很好的效果.

4.2.3 目标数目对算法的影响

目标数目 L 会影响 $\frac{D(g||f)}{L}$ 、 $\frac{D(f||g)}{M-L}$ 、 $\Delta(M, L)$ 的大小, L 越大时, $\frac{D(g||f)}{L}$ 越小, $\frac{D(f||g)}{M-L}$ 越大, $\Delta(M, L)$ 越有可能是负值, 此时 DBS 策略更有可能使用排除法来寻找目标; L 越小, $\frac{D(g||f)}{L}$ 越大, $\frac{D(f||g)}{M-L}$ 越小, $\Delta(M, L)$ 越有可能是正值, 此时 DBS 策略更有可能用直接选择法来寻找目标.

5 结束语

本文研究了考虑切换损失的多目标搜索问题, 提出了一种计算简单, 易于理解的主动目标搜索策略, 并证明了它的渐近最优性. 在有限时间内, DBS 策略的表现显著优于其他搜索方法. 该策略能为基于主动假设检验的目标搜索问题提供理论指导, 也

能广泛应用于目标搜索、异常检测、医疗诊断多个领域,后续能进一步扩展至目标数目未知的场景.

参考文献:

[1] CASTANON, DAVID A. Optimal search strategies in dynamic hypothesis testing [J]. IEEE transactions on systems, man, and cybernetics, 1995, 25 (7): 1130-1138.

[2] WANG C, ZHAO Q, COHEN K. Dynamic search on a tree with information-directed random walk [C]// IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC). Kalamata, Greece, 2018: 1-5.

[3] KASPI Y, SHAYEVITZ O, JAVIDI T. Searching with measurement dependent noise [J]. IEEE Transactions on Information Theory, 2018, 64 (4): 2690-2705.

[4] CHERNOFF H. Sequential design of experiments [J]. The Annals of Mathematical Statistics, 1959, 30(3): 755-770.

[5] BESSLER S A. Theory and applications of the sequential design of experiments, k-actions and infinitely many experiments. part i. theory [R]. Stanford University Center for Applied Mathematics and Statistics Labs, 1960.

[6] NAGHSHVAR M, JAVIDI T. Active sequential hypothesis testing [J]. The Annals of Statistics, 2013, 41(6): 2703-2738.

[7] NAGHSHVAR M, JAVIDI T. Sequentiality and ada-

ptivity gains in active hypothesis testing [J]. IEEE J. Sel. Topics Signal Processing, 2013, 7(5): 768-782.

[8] COHEN K, ZHAO Q. Active hypothesis testing for anomaly detection [J]. IEEE Transactions on Information Theory, 2015, 61(3): 1432-1450.

[9] HUANG B, COHEN K, ZHAO Q. Active anomaly detection in heterogeneous processes [C]// 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Calgary, Alberta, Canada, 2018.

[10] VAIDHIYAN N K, SUNDARESAN R. Active search with a cost for switching actions [C]// IEEE Information Theory and Applications Workshop (ITA). San Diego, California, USA, 2015: 17-24.

[11] CHEN D, HUANG Q, FENG H, et al. Active Anomaly Detection with Switching Cost [EB/OL]. (2019-04-02). <https://arxiv.org/abs/1810.11800>, 2018.

[12] ABRAHAM W. Sequential analysis [M]. Courier Corporation, 1973.

作者简介:

谌 达 男,(1994-),硕士.研究方向为主动假设检验理论. E-mil:16210720026@fudan.edu.cn.

胡 波 男,(1968-),教授.研究方向为数字信号处理、数字通信和系统设计.

冯 辉 男,(1980-),副教授.研究方向为分布式信号处理应用.

(上接第 88 页)

[10] 李湘锋,赵有健,全成斌. 对称密钥加密算法在 IPsec 协议中的应用 [J]. 电子测量与仪器学报, 2014, 28(1): 75-83.

[12] HE HAO, YI W D, LI M, et al. Homomorphic hashing verification for wireless sensor networks rateless codes over-the-air programming [J/OL]. Journal of Beijing Institute of Technology; 1-10 [2019-01-18]. <https://doi.org/10.15918/j.jbit1004-0579.17150>.

[13] MD IFTEKHAR HUSSAIN, ZAVED IQUBAL AHMED, NITYANANDA SARMA, et al. An efficient TDMA MAC protocol for multi-hop WiFi-based

long distance networks [J]. Wireless Personal Communications, 2016, 86(4): 150-168.

[14] 张尧,叶玲. 基于 AES 的 WSN 加密算法 [J]. 计算机工程与设计, 2015, 36(3): 619-623.

作者简介:

石玲玲 女,(1990-),硕士,工程师.研究方向为计算机网络、信息安全. E-mail:15855401823@163.com.

李敬兆 男,(1964-),教授,博士生导师.研究方向为嵌入式技术、物联网和云计算.