

Detecção de fraude em urnas eletrônicas: uma estratégia puramente estatística

Daniel Chicayban Bastos¹
Luis Antonio Brasil Kowada¹
Maria Cristina Bessa Moreira²

¹Universidade Federal Fluminense
Instituto de Computação
Av. Gal. Milton Tavares de Souza
São Domingos, Niterói, RJ, 24210-310

²Universidade Federal Fluminense
Instituto de Matemática e Estatística
Rua Professor Marcos Waldemar de Freitas Reis
São Domingos, Niterói, RJ, 24210-201

10 de dezembro de 2018

Introdução

Dois aspectos de segurança são:

- ▶ Proteger um objeto contra violações.
- ▶ Detectar a violação que não foi possível evitar
 - ▶ Estimar o tamanho da violação.

Precisamos provar aos perdedores da corrida eleitoral que eles de fato perderam. (Jeroen van de Graaf, 2017.)

A votação paralela

Tabela 1: Número de urnas auditadas pela votação paralela

unidade federativa	urnas auditadas
até 15.000 seções	3
de 15.001 a 30.000	4
acima de 30.000	5

Fonte:

- ▶ TSE (2013). Resolução n. 23.397, 17 de dezembro de 2013. Diário da Justiça Eletrônico do Tribunal Superior Eleitoral, 248:2–10.
- ▶ TSE (2018). Resolução n. 23.574, 29 de maio de 2018. Diário da Justiça Eletrônico do Tribunal Superior Eleitoral, 122:111–114.

Detecção de fraude

Uma auditoria tem um procedimento A de teste de urnas eletrônicas. O teste pode responder F , significando fraude, ou L , significando urna legítima. Similarmente, uma urna U pode ser F de fraudulenta ou L de legítima. Se a auditoria é perfeita, então

$$P(A=L | U=L) = 1 \quad \text{e} \quad P(A=F | U=L) = 0.$$

Se não é perfeita, então

$$P(A=F | U=F) = t \quad \text{e} \quad P(A=L | U=F) = 1 - t.$$

Um exemplo

Suponha 5% de fraude e sensibilidade da auditoria de 70%. Qual a probabilidade de que uma urna seja classificada como fraudulenta? Dado que $P(A=F|U=F) = 0,70$, o teorema das probabilidades totais nos garante que

$$\begin{aligned}P(A=F) &= P(A=F|U=F)P(U=F) + P(A=F|U=L)P(U=L) \\ &= 0,70 \times 0,05 + 0 \times 0,95 = 0,035.\end{aligned}$$

Então a probabilidade de se detectá-la como fraudulenta é 0,035 num universo de 5% de urnas fraudulentas na população de urnas. (Como os eventos $A=F$ e $A=L$ são complementares, obtemos a probabilidade de 0,965 da auditoria detectar uma urna como legítima.)

Extrações em série

Defina X como uma variável aleatória que represente o número de urnas fraudulentas extraídas da população de urnas. Considere, como exemplo, três extrações em série. Então $X = \{0, 1, 2, 3\}$. Assuma que a extração de uma urna não altere a proporção de urnas fraudulentas na população de urnas, ou seja, assumo que a extração é com reposição. Então

$$X \sim \text{Binomial}(n = 3, p = 0,035).$$

Logo, a probabilidade de detecção de fraude é

$$\begin{aligned} P(X \geq 1) &= 1 - P(X < 1) = 1 - P(X=0) \\ &= 1 - P(A=L)^3 \\ &= 1 - 0,965^3 \\ &\approx 0,10. \end{aligned}$$

Extrações em série

Se desejamos, entretanto, uma probabilidade maior de revelar a fraude, como 0,99, precisamos procurar pelo número real n que satisfaça

$$1 - P(A=L)^n = 0,99$$

$$1 - 0,965^n = 0,99$$

$$0,965^n = 0,01$$

$$n = \ln 0,01 / \ln 0,965 \approx 129,26.$$

O número de urnas portanto precisa ser $\lceil 129,26 \rceil = 130$.

Generalizando o exemplo anterior...

Seja:

- ▶ γ a probabilidade desejada de detecção
- ▶ $t\theta$ a probabilidade de se encontrar, ao acaso, uma urna fraudulenta, sendo t a sensibilidade do teste e θ , a proporção de urnas fraudulentas na população de urnas

Assumindo uma extração com reposição, o tamanho n da amostra de urnas é

$$n = \left\lceil \frac{\ln(1 - \gamma)}{\ln(1 - t\theta)} \right\rceil.$$


Se n for grande...

Use o que tiver — em detrimento da probabilidade γ de detecção.

Tabela 2: Decaimento da probabilidade γ de detecção com respeito à diminuição do tamanho da amostra n e da sensibilidade t dado $\theta = 0,05$

n	200	100	50	25	12
$t = 0,5$	0,99	0,92	0,72	0,47	0,26
$t = 0,75$	0,99	0,98	0,85	0,62	0,37
$t = 1$	0,99	0,99	0,92	0,72	0,46

Aumento da confiança em função do tamanho da amostra



Uma estimativa da proporção de fraude

Constrói-se o estimador

$$\hat{\theta} := \frac{\sum_{i=1}^n A_i}{nt},$$

sendo

$$A_i(U) = \begin{cases} 1 & \text{se auditoria acusa fraude em } U \\ 0 & \text{senão} \end{cases}$$

Precisaremos de uma amostra de tamanho n tal que

$$P(|\hat{\theta} - \theta| < \epsilon) \geq \gamma,$$

que é

$$n \geq \frac{z_0^2 \theta_0 (1 - t\theta_0)}{t\epsilon^2},$$

sendo z_0 o valor tal que $P(Z > z_0) = (1 - \gamma)/2$, $Z \sim \text{Normal}(0,1)$.

Exemplo de estimativa da proporção de fraude

Seja:

- ▶ $t = 0,75$ a sensibilidade do teste de auditoria
- ▶ $\epsilon = 0,01$ o erro máximo tolerável para a estimativa de θ
- ▶ $\gamma = 0,99$ a confiança desejada
- ▶ uma proporção inicial $\theta_0 = 0,05$ arbitrada

Então:

$$n \geq \frac{2,5758^2 \times 0,05 \times (1 - 0,75 \times 0,05)}{0,75 \times 0,01^2},$$

- ▶ precisamos auditar pelo menos $n = 4.258$ urnas.

Correspondente à confiança de 0,99, $z_0 \approx 2,5758$ na tabela da distribuição Normal padrão.

Número de urnas em função da sensibilidade e confiança




Figura 1: Impacto no tamanho da amostra usando $\epsilon = 0,01$ e $\theta_0 = 0,05$. A linha tracejada mostra o número de urnas necessárias, 3.152, se o teste da auditoria for perfeito.

Número de urnas em função de θ_0

Número de urnas auditadas em função de θ_0 e sensibilidade.

θ_0	0,01	0,02	0,03	0,04	0,05	0,10
$t = 0,5$	1.321	2.628	3.922	5.202	6.470	12.607
$t = 0,75$	879	1.743	2.595	3.433	4.258	8.184
$t = 1$	657	1.301	1.931	2.548	3.152	5.972

Sobre a extração com reposição




Figura 2: Simulações da confiança em amostragem com e sem reposição.

Sobre a extração com reposição

- ▶ Pontos pretos representam a confiança em função da proporção de fraude na extração sem reposição; os brancos, com reposição.
- ▶ A curva representa a relação analítica entre a confiança e a proporção de fraude considerando a amostragem com reposição.
- ▶ A linha tracejada indica a confiança mínima de 0,6723 que é atingida com $\theta = 2/3$.
- ▶ As simulações seguem os valores do exemplo: $t = 0,75$, $n = 4.258$, $\epsilon = 0,01$.
- ▶ Simulação feita com 600 mil urnas.