

# СТАТИСТИЧЕСКИЕ КРИТЕРИИ ДЛЯ ОБНАРУЖЕНИЯ ИСТОЧНИКОВ СИГНАЛА В УСЛОВИЯХ НЕОПРЕДЕЛЕННОГО ФОНА

Бабёнов Глеб Игоревич

Научный руководитель:

к.ф.-м.н. с.н.с. ОТФ ИЯИ РАН Пётр Сергеевич Сатунин


Московский государственный университет имени М.В.Ломоносова

Физический факультет

Кафедра физики частиц и космологии

27 мая 2026

# Постановка задачи



# Частотный подход

## Распределение Пуассона

$$P_{\text{on, off}} = \text{Pois}(N_{\text{on, off}} | \langle N_{\text{on, off}} \rangle),$$

где  $\langle N_{\text{on}} \rangle = s + \epsilon b$ ,  $\langle N_{\text{off}} \rangle = b$  – параметры модели.

- $s$  – сигнал;
- $b$  – фон;
- $\epsilon$  – отношение продолжительностей наблюдения за конкретной областью пространства:  $t_{\text{on}} = \epsilon t_{\text{off}}$

# Частотный подход

## Распределение Пуассона

$$P_{\text{on, off}} = \text{Pois}(N_{\text{on, off}} | \langle N_{\text{on, off}} \rangle),$$

где  $\langle N_{\text{on}} \rangle = s + \epsilon b$ ,  $\langle N_{\text{off}} \rangle = b$  – параметры модели.

- $s$  – сигнал;
- $b$  – фон;
- $\epsilon$  – отношение продолжительностей наблюдения за конкретной областью пространства:  $t_{\text{on}} = \epsilon t_{\text{off}}$

## Likelihood function

$$L = \frac{(s + \epsilon b)^{N_{\text{on}}}}{N_{\text{on}}!} e^{-(s + \epsilon b)} \frac{b^{N_{\text{off}}}}{N_{\text{off}}!} e^{-b}$$

# Частотный подход

## Wilks' theorem

Пусть у нас есть набор данных  $X = (x_1, \dots, x_n)$ , параметров  $\Theta = (s, b)$  и нулевая гипотеза  $H_0: s = s_0$ .

Тогда

$$S = -2 \ln \Lambda \stackrel{n \rightarrow \infty}{\sim} \chi_1^2,$$

где  $\Lambda = \frac{L(X|s=s_0, b=\hat{b})}{L(X|s=\hat{s}, b=\hat{b})}$  – отношение функции правдоподобия при нулевой гипотезе к функции правдоподобия при альтернативной.

# Частотный подход

## Wilks' theorem

Пусть у нас есть набор данных  $X = (x_1, \dots, x_n)$ , параметров  $\Theta = (s, b)$  и нулевая гипотеза  $H_0: s = s_0$ .

Тогда

$$S = -2 \ln \Lambda \stackrel{n \rightarrow \infty}{\sim} \chi_1^2,$$

где  $\Lambda = \frac{L(X|s=s_0, b=\hat{b})}{L(X|s=\hat{s}, b=\hat{b})}$  – отношение функции правдоподобия при нулевой гипотезе к функции правдоподобия при альтернативной.

В нашем случае:

- $H_0: s = 0$  – отсутствие сигнала;
- $H_1: s > 0$  – наличие сигнала

# Частотный подход

## Wilks' theorem

Пусть у нас есть набор данных  $X = (x_1, \dots, x_n)$ , параметров  $\Theta = (s, b)$  и нулевая гипотеза  $H_0: s = s_0$ .

Тогда

$$S = -2 \ln \Lambda \stackrel{n \rightarrow \infty}{\sim} \chi_1^2,$$

где  $\Lambda = \frac{L(X|s=s_0, b=\hat{b})}{L(X|s=\hat{s}, b=\hat{b})}$  – отношение функции правдоподобия при нулевой гипотезе к функции правдоподобия при альтернативной.

В нашем случае:

- $H_0: s = 0$  – отсутствие сигнала;
- $H_1: s > 0$  – наличие сигнала

# Байесовский подход

## Bayes' theorem

**Предположим**, что  $A_1, A_2, \dots, A_N$  образуют полную систему событий, а событие  $B$  имеет ненулевую вероятность:  $P(B) > 0$ .

**Тогда**

$$P(A_k|B) = \frac{P(B|A_k)P(A_k)}{\sum_i P(B|A_i)P(A_i)}$$

определяет правило вычисления условной вероятности события  $A_k$  – при условии, что событие  $B$  уже имело место – по безусловной вероятности события  $A_k$  и условным вероятностям  $P(B|A_k)$ .

# Байесовский подход

## Bayes' theorem

**Предположим**, что  $A_1, A_2, \dots, A_N$  образуют полную систему событий, а событие  $B$  имеет ненулевую вероятность:  $P(B) > 0$ .

**Тогда**

$$P(A_k|B) = \frac{P(B|A_k)P(A_k)}{\sum_i P(B|A_i)P(A_i)}$$

определяет правило вычисления условной вероятности события  $A_k$  – при условии, что событие  $B$  уже имело место – по безусловной вероятности события  $A_k$  и условным вероятностям  $P(B|A_k)$ .

## Непрерывный случай

$$p(\lambda|X) = \frac{p(X|\lambda)\pi(\lambda)}{\int_0^{\infty} p(X|\lambda)\pi(\lambda)d\lambda}, \quad \lambda > 0$$

# Байесовский подход

## Выбор приора в отсутствие априорных знаний

Правило Джеффриса: если  $\lambda$  принимает только положительные значения  $\lambda > 0$ , то мы полагаем на всей числовой прямой  $(-\infty, +\infty)$ :  $\pi(\ln \lambda) = \text{const}$ , то есть

$$\pi(\lambda) \sim \frac{1}{\lambda}$$

# Байесовский подход

## Выбор приора в отсутствие априорных знаний

Правило Джеффриса: если  $\lambda$  принимает только положительные значения  $\lambda > 0$ , то мы полагаем на всей числовой прямой  $(-\infty, +\infty)$ :  $\pi(\ln \lambda) = \text{const}$ , то есть

$$\pi(\lambda) \sim \frac{1}{\lambda}$$

## Апостериорное распределение для распределения Пуассона

$$p(\lambda|X) \sim \pi(\lambda)L(X|\lambda) \sim e^{-n\lambda} \cdot \lambda^{\sum_{i=1}^n x_i - 1},$$

то есть гамма-распределение  $\text{Gamma}(\alpha, \beta)$  с параметрами  $\alpha = \sum_{i=1}^n x_i$ ,  
 $\beta = n$ .

# Байесовский подход

## Параметры распределения

$$\lambda_{\text{on, off}} \sim \text{Gamma}(\alpha_{\text{on, off}}, \beta_{\text{on, off}}),$$

где  $\alpha_{\text{on, off}} = N_{\text{on, off}}$ ,  $\beta_{\text{on}} = 1$ ,  $\beta_{\text{off}} = \frac{1}{\epsilon}$ , поскольку область  $S_{\text{off}}$  наблюдается в  $\frac{1}{\epsilon}$  раз чаще, чем  $S_{\text{on}}$ .

# Байесовский подход

## Параметры распределения

$$\lambda_{\text{on, off}} \sim \text{Gamma}(\alpha_{\text{on, off}}, \beta_{\text{on, off}}),$$

где  $\alpha_{\text{on, off}} = N_{\text{on, off}}$ ,  $\beta_{\text{on}} = 1$ ,  $\beta_{\text{off}} = \frac{1}{\epsilon}$ , поскольку область  $S_{\text{off}}$  наблюдается в  $\frac{1}{\epsilon}$  раз чаще, чем  $S_{\text{on}}$ .

Байесовская вероятность  $P(H_1|X) = P(\lambda_{\text{on}} > \lambda_{\text{off}})$

$$= \int_0^{\infty} d\lambda_{\text{off}} \int_{\lambda_{\text{off}}}^{\infty} d\lambda_{\text{on}} \frac{\beta_{\text{on}}^{\alpha_{\text{on}}}}{\Gamma(\alpha_{\text{on}})} e^{-\beta_{\text{on}}\lambda_{\text{on}}} \lambda_{\text{on}}^{\alpha_{\text{on}}-1} \frac{\beta_{\text{off}}^{\alpha_{\text{off}}}}{\Gamma(\alpha_{\text{off}})} e^{-\beta_{\text{off}}\lambda_{\text{off}}} \lambda_{\text{off}}^{\alpha_{\text{off}}-1}$$

# Байесовский подход

Байесовская вероятность  $P(H_1|X) = P(\lambda_{\text{on}} > \lambda_{\text{off}})$

$$P(\lambda_{\text{on}} > \lambda_{\text{off}}) = \sum_{k=0}^{N_{\text{on}}-1} \frac{(1 + \frac{1}{\epsilon})^{-(k+N_{\text{off}})}}{\epsilon^{N_{\text{off}}} (k + N_{\text{off}}) B(k + 1, N_{\text{off}})}$$

# Байесовский подход

Байесовская вероятность  $P(H_1|X) = P(\lambda_{\text{on}} > \lambda_{\text{off}})$

$$P(\lambda_{\text{on}} > \lambda_{\text{off}}) = \sum_{k=0}^{N_{\text{on}}-1} \frac{(1 + \frac{1}{\epsilon})^{-(k+N_{\text{off}})}}{\epsilon^{N_{\text{off}}} B(k+1, N_{\text{off}})}$$

## Байесовский критерий

Мы отвергаем нулевую гипотезу  $H_0$  на уровне значимости  $\alpha$ , если

$$P(H_1|X) > 1 - \alpha.$$

# Проверка корректности методов

## Теорема о p-value

**Пусть**  $T$  – тестовая статистика и  $p\text{-value} = P(T \geq T_{\text{obs}} | H_0)$  – соответствующее p-value.

**Тогда** при условии, что  $H_0$  верна:

$$p\text{-value} \sim \text{Uniform}(0, 1).$$

# Проверка корректности методов

## Теорема о p-value

**Пусть**  $T$  – тестовая статистика и  $p\text{-value} = P(T \geq T_{\text{obs}} | H_0)$  – соответствующее p-value.

**Тогда** при условии, что  $H_0$  верна:

$$p\text{-value} \sim \text{Uniform}(0, 1).$$

## Способ проверки

- 10 000 генераций:  $N_{\text{on}} \sim \text{Pois}(\epsilon b)$ ,  $N_{\text{off}} \sim \text{Pois}(b)$  для различных уровней значимости  $\alpha$ ;

# Проверка корректности методов

## Теорема о p-value

**Пусть**  $T$  – тестовая статистика и  $p\text{-value} = P(T \geq T_{\text{obs}} | H_0)$  – соответствующее p-value.

**Тогда** при условии, что  $H_0$  верна:

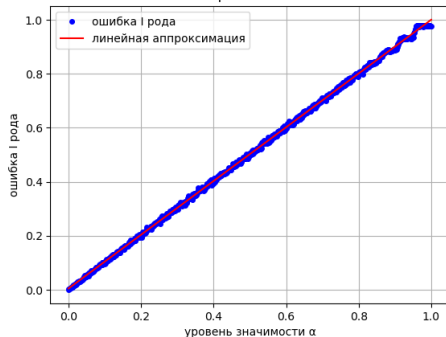
$$p\text{-value} \sim \text{Uniform}(0, 1).$$

## Способ проверки


- 1 10 000 генераций:  $N_{\text{on}} \sim \text{Pois}(\epsilon b)$ ,  $N_{\text{off}} \sim \text{Pois}(b)$  для различных уровней значимости  $\alpha$ ;
- 2 построение зависимости ошибки I рода от  $\alpha$

# Проверка корректности методов

Теорема Уилкса



Формула Байеса




## Линейная аппроксимация МНК

- частотный подход:  $a_1 = 0.9960$ ,  $a_0 = 0.0046$ ,  $R^2 = 0.9996$ ;
- байесовский подход:  $a_1 = 0.9833$ ,  $a_0 = -0.0245$ ,  $R^2 = 0.9979$

# Проверка корректности методов

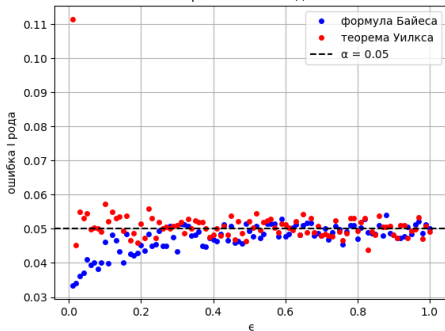
## Зависимость ошибки I рода от параметра $b$

Сравнение методов



## Зависимость ошибки I рода от параметра $\epsilon$

Сравнение методов



# Сравнение методов

## Сравнение чувствительности

- 1 10 000 генераций:  $N_{\text{он}} \sim \text{Pois}(\epsilon b(1 + \delta))$ ,  $N_{\text{офф}} \sim \text{Pois}(b)$  для различных величин эффекта  $\delta$  (то есть  $s = \epsilon\delta b$ );

# Сравнение методов

## Сравнение чувствительности

- 1 10 000 генераций:  $N_{\text{он}} \sim \text{Pois}(\epsilon b(1 + \delta))$ ,  $N_{\text{офф}} \sim \text{Pois}(b)$  для различных величин эффекта  $\delta$  (то есть  $s = \epsilon\delta b$ );
- 2 построение зависимости ошибки II рода от  $\delta$


# Сравнение методов

## Сравнение чувствительности

- 10 000 генераций:  $N_{\text{он}} \sim \text{Pois}(\epsilon b(1 + \delta))$ ,  $N_{\text{офф}} \sim \text{Pois}(b)$  для различных величин эффекта  $\delta$  (то есть  $s = \epsilon \delta b$ );
- построение зависимости ошибки II рода от  $\delta$


**b = 50**

Сравнение методов при b = 50



**b = 200**

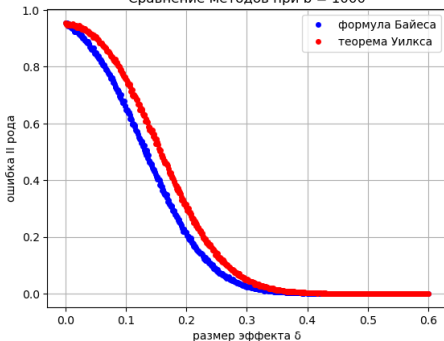
Сравнение методов при b = 200



# Сравнение методов


$b = 1\ 000$

Сравнение методов при  $b = 1000$



$b = 10\ 000$

Сравнение методов при  $b = 10000$



## Вывод

Байесовский метод чаще «замечает» сигнал там, где он, действительно, присутствует, нежели частотный подход.

# Робастность байесовского подхода

Добавим **овердисперсию** в распределение Пуассона

$$\mathbb{E}[X] = \lambda, \quad \text{Var}[X] = \lambda + \kappa\lambda^2$$

при помощи репараметризации отрицательного биномиального распределения  $X \sim \text{NB}(r, p)$ :




$$\begin{cases} r = \frac{1}{\kappa} \\ p = \frac{1}{1+\kappa\lambda} \end{cases},$$

для которого исходно  $\mathbb{E}[X] = \frac{r(1-p)}{p}$  и  $\text{Var}[X] = \frac{r(1-p)}{p^2}$ .


Причем:

$$\lim_{\kappa \rightarrow 0} \text{NB}(\kappa, \lambda) = \text{Pois}(\lambda)$$


# Робастность байесовского подхода



# Робастность байесовского подхода



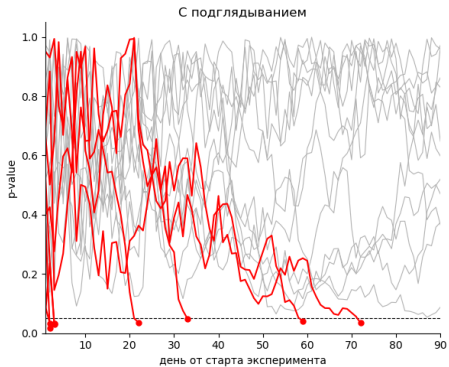
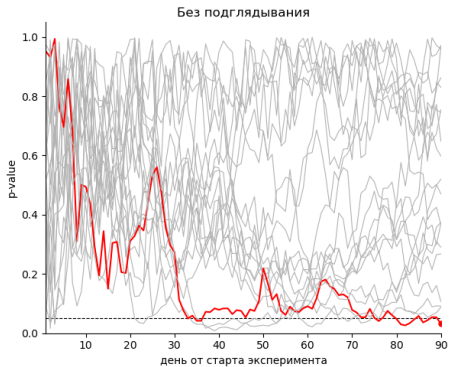
# Робастность байесовского подхода



К примеру, при  $N_{\text{off}} \approx 200$  событий, метод можно использовать даже когда мы не учли дополнительные 20% дисперсии!

# Peeking problem vs Bayes

## Проблема подглядывания



# Peeking problem vs Bayes

## Методология проверки

- $s = 0$ ;
- $b = \text{const}$  во времени;
- собираем данные в течение месяца;
- уровень значимости  $\alpha = 5\%$ ;
- подглядывание – ежедневное применение критерия и остановка эксперимента в момент достижения статистической значимости

# Peeking problem vs Bayes

## Методология проверки

- $s = 0$ ;
- $b = \text{const}$  во времени;
- собираем данные в течение месяца;
- уровень значимости  $\alpha = 5\%$ ;
- подглядывание – ежедневное применение критерия и остановка эксперимента в момент достижения статистической значимости

## Bayes

- без подглядывания: ошибка I рода равна 4.8%
- с подглядыванием: ошибка I рода равна 22.32%

# Peeking problem vs Bayes

## Методология проверки

- $s = 0$ ;
- $b = \text{const}$  во времени;
- собираем данные в течение месяца;
- уровень значимости  $\alpha = 5\%$ ;
- подглядывание – ежедневное применение критерия и остановка эксперимента в момент достижения статистической значимости

## Bayes

- без подглядывания: ошибка I рода равна 4.8%
- с подглядыванием: ошибка I рода равна 22.32%

## Wilks

- без подглядывания: ошибка I рода равна 4.95%
- с подглядыванием: ошибка I рода равна 28.33%

# Дизайн эксперимента

- 1 фиксируем уровень значимости  $\alpha = 5\%$  и мощность  $\beta = 80\%$ ;

# Дизайн эксперимента

- 1 фиксируем уровень значимости  $\alpha = 5\%$  и мощность  $\beta = 80\%$ ;
- 2 на исторических данных оцениваем примерное число фоновых событий в день:  $N_{\text{off}} = 20$ ;

# Дизайн эксперимента


- 1 фиксируем уровень значимости  $\alpha = 5\%$  и мощность  $\beta = 80\%$ ;
- 2 на исторических данных оцениваем примерное число фоновых событий в день:  $N_{\text{off}} = 20$ ;
- 3 определяем минимальный сигнал, который хотим задетектировать:  $s = 1$  за день;

# Дизайн эксперимента

- 1 фиксируем уровень значимости  $\alpha = 5\%$  и мощность  $\beta = 80\%$ ;
- 2 на исторических данных оцениваем примерное число фоновых событий в день:  $N_{\text{off}} = 20$ ;
- 3 определяем минимальный сигнал, который хотим задетектировать:  $s = 1$  за день;
- 4 строим график зависимости мощности от длительности эксперимента


# Дизайн эксперимента

Определение необходимой длительности эксперимента




# Дизайн эксперимента

Определение необходимой длительности эксперимента




# Дизайн эксперимента

Определение необходимой длительности эксперимента




# Дизайн эксперимента

## Bayes



## Wilks



Частотный подход на 9 дней дольше!

# Результаты работы

## Итоги

- критерий Ли–Ма дает сбои при малой статистике;
- разработан байесовский критерий прямого вычисления вероятности гипотезы о наличии фона;
- продемонстрировано преимущество байесовского подхода в мощности;
- продемонстрирована робастность байесовского метода;
- проблема подглядывания сохраняется;
- критерий применен к реальным наблюдениям

# Результаты работы

## Итоги

- критерий Ли–Ма дает сбои при малой статистике;
- разработан байесовский критерий прямого вычисления вероятности гипотезы о наличии фона;
- продемонстрировано преимущество байесовского подхода в мощности;
- продемонстрирована робастность байесовского метода;
- проблема подглядывания сохраняется;
- критерий применен к реальным наблюдениям

## Перспективы

- внедрение байесовского критерия в классическую обработку;
- использование информативных priоров;
- разработка байесовских стоп-правил

# Дополнение I

## Отношение likelihood

$$\Lambda = \frac{L(X|H_0)}{L(X|H_1)} = \frac{L(N_{\text{on}}, N_{\text{off}}|s = 0, b = \hat{b}_c)}{L(N_{\text{on}}, N_{\text{off}}|s = N_{\text{on}} - \epsilon N_{\text{off}}, b = N_{\text{off}})},$$

где  $\hat{b}_c = \frac{N_{\text{on}} + N_{\text{off}}}{\epsilon + 1}$  – ОМП.

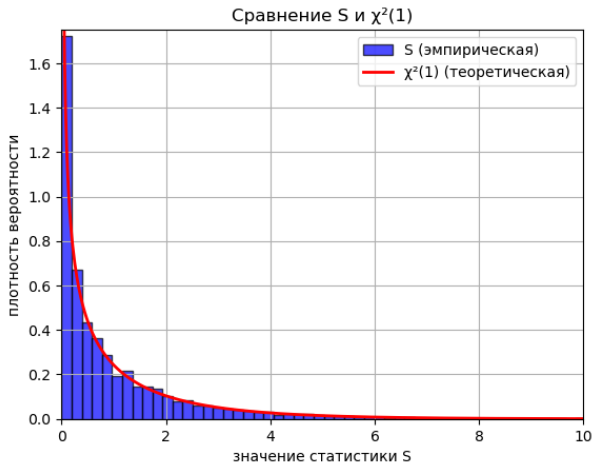
## Итоговая статистика

$$S = 2 \left[ N_{\text{on}} \ln \left( \frac{\epsilon + 1}{\epsilon} \left( \frac{N_{\text{on}}}{N_{\text{on}} + N_{\text{off}}} \right) \right) + N_{\text{off}} \ln \left( (\epsilon + 1) \left( \frac{N_{\text{off}}}{N_{\text{on}} + N_{\text{off}}} \right) \right) \right]$$

# Дополнение I


## Wilks' theorem

$$S = -2 \ln \Lambda \stackrel{n \rightarrow \infty}{\sim} \chi_1^2,$$



# Дополнение I

## Тесты Колмогорова-Смирнова



Бесконечность начинается с 2 000...

# Дополнение II

## Peeking problem vs Bayes



# Дополнение III

## Практическое применение

Источник	$N_{\text{on}}$	$N_{\text{off}}$	$\epsilon$	$P(\lambda_{\text{on}} > \lambda_{\text{off}})$	$S$	p-value
HEGRA	36	104	0.2	0.996	7.32	0.007
H.E.S.S.	4	1	0.095	$> 0.999$	14.73	$10^{-4}$
GRB 070419A	2	14	0.057	0.808	1.18	0.278
GRB 070521	3	113	0.057	0.049	2.20	0.138
GRB 070612B	3	21	0.066	0.832	1.29	0.256
GRB 080310	3	23	0.128	0.449	$9 \cdot 10^{-4}$	0.976
GRB 080604	2	40	0.063	0.293	0.11	0.741
GRB 080607	4	16	0.112	0.883	1.74	0.187
GRB 080825C	15	19	0.063	$> 0.999$	40.43	$2 \cdot 10^{-10}$
GRB 081024A	1	7	0.142	0.395	$3 \cdot 10^{-5}$	0.996
GRB 090418A	3	16	0.123	0.685	0.41	0.523
GRB 090429B	2	7	0.106	0.825	1.26	0.262
GRB 090515	4	24	0.126	0.642	0.25	0.616