

## Иерархическая процедура множественной проверки гипотез


Рябенко Евгений, аспирант ММП

Семинар «Байесовские методы машинного обучения»  
ВМК МГУ • 16 ноября 2011 г.

# Поиск экстрасенсов

Joseph Rhine, 1950: исследования экстрасенсорного восприятия. Первый этап — поиск экстрасенсов.

Испытуемому предлагалось угадать цвет 10 карт.



$H_0$ : испытуемый выбирает цвет карт наугад.

$H_1$ : испытуемый может предсказывать цвет карт.

Статистика  $t$  — число угаданных цветов.

$$P(t \geq 9 | H_0) = 11 \cdot \frac{1}{2}^{10} = 0.0107421875,$$

т.е. при  $t = 9$  достигаемый уровень значимости  $p \approx 0.01$ , событие достаточно редкое, можно отклонять  $H_0$  и признавать испытуемого экстрасенсом.


## Поиск экстрасенсов

Процедуру отбора прошли 1000 человек.

Девять из них угадали цвета 9 из 10 карт, двое — цвета всех 10 карт.

Ни один из них в последующих экспериментах не подтвердил своих способностей.

Вероятность того, что из 1000 человек хотя бы один случайно угадает цвета 9 или 10 из 10 карт:  $1 - \left(1 - 11 \cdot \frac{1}{2}^{10}\right)^{1000} \approx 0.9999796$ .




# Математическая формулировка

выборка:  $\mathbf{X} = \{X_1, \dots, X_n\} \sim P \in \Omega$ ;  
 нулевая гипотеза:  $H_0: P \in \omega, \omega \in \Omega$ ;  
 альтернатива:  $H_1: P \notin \omega$ ;  
 статистика:  $T(\mathbf{X}), T(\mathbf{X}) \sim F(x)$  при  $P \in \omega$ ;  
 $T(\mathbf{X}) \not\sim F(x)$  при  $P \notin \omega$ ;



реализация выборки:  $\mathbf{x} = \{x_1, \dots, x_n\}$ ;  
 реализация статистики:  $t = T(\mathbf{x})$ ;  
 достигаемый уровень значимости:  $p(\mathbf{x})$  — вероятность при  $H_0$  получить  $T(\mathbf{X}) = t$  или ещё более экстремальное;



Гипотеза отвергается при  $p(\mathbf{x}) \leq \alpha$ ,  $\alpha$  — уровень значимости.

# Правило проверки гипотезы



# Простейший пример

Требуется проверить симметричность монеты за 20 подбрасываний.


выборка:  $\mathbf{X} = \{X_1, \dots, X_{20}\} - i.i.d. Bern(20, q)$ ;

нулевая гипотеза:  $H_0: P = Bern(20, 0.5)$ ;

альтернатива:  $H_1: P \neq Bern(20, 0.5)$ ;

статистика:  $T(\mathbf{X}) = \max(\sum X_i, 20 - \sum X_i)$ ;

большие значения статистики свидетельствуют в пользу  $H_1$ ;



реализация выборки:  $\mathbf{x} = \{x_1, \dots, x_{20}\}$ ;

реализация статистики:  $t = T(\mathbf{x})$ ;

достижимый уровень значимости: при  $t = 20$   $p = \frac{2}{1048576} \approx 1.9 \times 10^{-6}$ ,

при  $t = 19$   $p = \frac{42}{1048576} \approx 4 \times 10^{-5}$ ,

при  $t = 15$   $p = \frac{43400}{1048576} \approx 0.04$ .

При  $t \geq 15$  гипотеза отвергается на уровне значимости  $\alpha = 0.05$ .

## Несимметричность задачи проверки гипотез

	$H_0$ верна	$H_0$ неверна
$H_0$ принимается	$H_0$ верно принята	Ошибка второго рода
$H_0$ отвергается	Ошибка первого рода	$H_0$ верно отвергнута

Вероятность ошибки первого рода жёстко ограничивается достаточно малой наперёд заданной величиной —  $P(p(\mathbf{x}) \leq \alpha | H_0) \leq \alpha$ .

Вероятность ошибки второго рода минимизируется путём выбора достаточно мощного критерия.

## Усложнение примера

Требуется проверить симметричность 1000 монет.

Пусть все монеты симметричны.

Вероятность того, что хотя бы одна не менее 15 раз за серию упадёт одной и той же стороной, равна

$$1 - \left(1 - \frac{43400}{1048576}\right)^{1000} \approx 0.9999999999999999995.$$

$t$	15	16	17	18	19	20
$P$	$1 - 5 \times 10^{-19}$	$1 - 7 \times 10^{-6}$	0.92	0.33	0.039	0.002

При проведении статистического анализа данных по большому количеству гипотез необходимо ограничивать не только вероятность каждой ошибки первого рода, но и некую глобальную меру ошибки, учитывающую число гипотез.



## Математическая постановка

данные:  $\mathbf{X} = \{\mathbf{X}_1, \dots, \mathbf{X}_m\} \sim P \in \Omega;$

нулевые гипотезы:  $H_i: P \in \omega_i, \omega_i \in \Omega;$

альтернативы:  $H'_i: P \notin \omega_i;$

статистики:  $T_i = T(\mathbf{X}_i)$  проверяет  $H_i$  против  $H'_i;$

реализации статистики:  $t_i = t(\mathbf{x}_i);$

достижимые уровни значимости:  $p_i = p(\mathbf{x}_i), i = 1, \dots, m;$

$\mathbf{M} = \{1, 2, \dots, m\};$

$\mathbf{M}_0 = \mathbf{M}_0(P) = \{i: H_i \text{ верна}\}$  — индексы верных гипотез,  $|\mathbf{M}_0| = m_0;$

$\mathbf{R} = \mathbf{R}(P, \alpha) = \{i: H_i \text{ отвергнута}\}$  — индексы отвергаемых гипотез,

$|\mathbf{R}| = R;$

$V = |\mathbf{M}_0 \cap \mathbf{R}|$  — число ошибок первого рода.

	Число верных $H_0$	Число неверных $H_0$	Всего
Число принятых $H_0$	$U$	$T$	$m - R$
Число отвергнутых $H_0$	$V$	$S$	$R$
Всего	$m_0$	$m - m_0$	$m$

Групповая вероятность ошибки первого рода (familywise error rate):

$$FWER = P(V \geq 1).$$

Контроль над групповой вероятностью ошибки на уровне  $\alpha$  означает

$$FWER = P(V \geq 1) \leq \alpha \quad \forall P.$$

$\alpha_1, \dots, \alpha_m$  — уровни значимости, на которых необходимо проверять гипотезы  $H_1, \dots, H_m$ ; задача — выбрать их так, чтобы обеспечить  $FWER \leq \alpha$ .

# Метод Бонферрони

**Метод Бонферрони:**  $\alpha_1 = \dots = \alpha_m = \alpha/m$ .

## Theorem

Если гипотезы  $H_i$ ,  $i = 1, \dots, m$ , отвергаются при  $p_i \leq \alpha/m$ , то  $FWER \leq \alpha$ .

## Доказательство.

$$\begin{aligned}
 FWER = P(V \geq 1) &\leq P\left(\bigcup_{i=1}^{m_0} \{p_i \leq \alpha/m\}\right) \leq \sum_{i=1}^{m_0} P(p_i \leq \alpha/m) \leq \\
 &\leq \sum_{i=1}^{m_0} \alpha/m = \frac{m_0}{m} \alpha \leq \alpha.
 \end{aligned}$$



## Поправка Бонферрони

При увеличении  $m$  в результате применения поправки Бонферрони мощность статистической процедуры резко уменьшается — шансы отклонить неверные гипотезы падают.

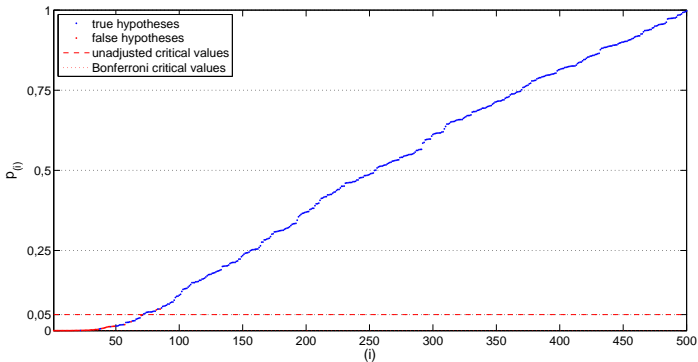
Пример: критерий Стьюдента для независимых выборок с одинаковой дисперсией  $\sigma^2 = 1$  и разностью средних  $\mu_1 - \mu_2 = 1$  при проверке гипотезы однородности на уровне значимости 0.05 имеет мощность 0.9 уже при длине выборок  $n = 23$ .

$m$	1	10		100		1000	
$n$	23	23	36	23	49	23	62
power	0.9	0.67	0.9	0.37	0.9	0.16	0.9

Если проверяется одновременно 1000000 гипотез, при размере выборок  $n = 10$  мощность 0.9 достигается при расстоянии между средними выборок в пять стандартных отклонений.

## Пример

$$m = 500, \quad m_0 = 50$$



Без поправки на множественные сравнения:  $R = 71$ ,  $V = 23$ .

С поправкой Бонферрони:  $R = 9$ ,  $V = 0$ .

# Метод Холма

Вариационный ряд достигаемых уровней значимости:

$$p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(m)},$$

$H_{(1)}, H_{(2)}, \dots, H_{(m)}$  — соответствующие нулевые гипотезы.

## Нисходящая процедура Холма:


- 1 Если  $p_{(1)} \geq \alpha_1 = \alpha/m$ , принять все нулевые гипотезы  $H_{(1)}, H_{(2)}, \dots, H_{(m)}$  и остановиться; иначе отвергнуть  $H_{(1)}$  и продолжать.
- 2 Если  $p_{(2)} \geq \alpha_2 = \alpha/(m-1)$ , принять нулевые гипотезы  $H_{(2)}, H_{(3)}, \dots, H_{(m)}$  и остановиться; иначе отвергнуть  $H_{(2)}$  и продолжать.
- 3 ...

$$\alpha_{(1)} = \alpha/m, \alpha_{(2)} = \alpha/(m-1), \dots, \alpha_{(m)} = \alpha.$$

$FWER \leq \alpha$  обеспечивается при любых  $p_i$ .

# Метод Холма

Метод Холма равномерно мощнее поправки Бонферрони, однако на практике различия между ними невелики.



Без поправки на множественные сравнения:  $R = 71$ ,  $V = 23$ .

С поправкой Бонферрони:  $R = 9$ ,  $V = 0$ .

С поправкой методом Холма:  $R = 10$ ,  $V = 0$ .

## Другие методы

- Если совместное нулевое распределение статистик  $T_1, \dots, T_m$  известно, константы  $\alpha_{(i)}$  могут быть найдены точно:

$$P_{0, \dots, 0}(\max(T_1, \dots, T_i) \geq c_{(m-i+1)}) = \alpha.$$

- Если статистики независимы, можно брать

$$\alpha_{(i)} = 1 - (1 - \alpha)^{\frac{1}{m-i+1}}.$$

- Если между статистиками положительная регрессионная зависимость, то  $\alpha_{(i)}$  лежат в диапазоне

$$1 - (1 - \alpha)^{\frac{1}{m-i+1}} \leq \alpha_{(i)} \leq \alpha.$$

- Если выполняется свойство subset pivotality (нулевое распределение любого подмножества статистик  $T_i$  не зависит от того, верны или неверны соответствующие оставшимся статистикам гипотезы), то можно найти  $\alpha_i$  по нулевому распределению максимальной статистики  $M_T = \max_i T_i$ :  $c = F_{M_T | \cup_{i \in M} H_i}^{-1}(1 - \alpha)$ .
- Если статистики можно представить как реализацию случайного поля, используются топологические методы.



Ожидаемая доля ложных отклонений гипотез среди всех отклонений (false discovery rate):

$$FDR = \mathbb{E} \left( \frac{V}{R} \cdot I_{\{R>0\}} \right) = \mathbb{E} (FDP)$$

( $FDP$  — доля ложных отклонений, false discovery proportion).

Контроль над ожидаемой долей ложных отклонений на уровне  $q$  означает

$$FDR = \mathbb{E} \left( \frac{V}{R} \cdot I_{\{R>0\}} \right) \leq q \quad \forall P.$$

$\alpha_1, \dots, \alpha_m$  — уровни значимости, на которых необходимо проверять гипотезы  $H_1, \dots, H_m$ ; задача — выбрать их так, чтобы обеспечить  $FDR \leq q$ .

## Байесовский вариант

Пусть  $T_i \sim F_0(t)$ ,  $i \in M_0$ ,  $T_i \sim F_1(t)$ ,  $i \in M \setminus M_0$ .

Функция распределения смеси:

$$F(t) = \frac{m_0}{m} F_0(t) + \frac{m - m_0}{m} F_1(t).$$

$$FDR(t) = \frac{m_0}{m} F_0(t) / F_1(t).$$

# Методы контроля FDR

Вариационный ряд достигаемых уровней значимости:

$$p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(m)},$$

$H_{(1)}, H_{(2)}, \dots, H_{(m)}$  — соответствующие нулевые гипотезы.


## Нисходящие методы:

- 1 Если  $p_{(1)} \geq \frac{1}{m} \frac{q}{c(m)}$ , принять все нулевые гипотезы  $H_{(1)}, H_{(2)}, \dots, H_{(m)}$  и остановиться; иначе отвергнуть  $H_{(1)}$  и продолжать.
- 2 Если  $p_{(2)} \geq \frac{2}{m} \frac{q}{c(m)}$ , принять нулевые гипотезы  $H_{(2)}, H_{(3)}, \dots, H_{(m)}$  и остановиться; иначе отвергнуть  $H_{(2)}$  и продолжать.
- 3 ...

При  $c(m) = 1$  получаем метод Бенджамини-Хохберга;  $FDR \leq m_0/mq \leq q$ , если между статистиками  $T_i$ ,  $i \in M_0$ , положительная регрессионная зависимость (или они независимы).

При  $c(m) = \sum_{i=1}^m \frac{1}{i}$  получаем метод Бенджамини-Йекутиели;  $FDR \leq m_0/mq \leq q$  безусловно.

## Метод Бенджамини-Хохберга




Без поправки на множественные сравнения:  $R = 71$ ,  $V = 23$ .

С поправкой Бонферрони:  $R = 9$ ,  $V = 0$ .

С поправкой методом Холма:  $R = 10$ ,  $V = 0$ .

С поправкой Бенджамини-Хохберга:  $R = 33$ ,  $V = 1$ .

## Метод Бенджамини-Йекутиели



Без поправки на множественные сравнения:  $R = 71$ ,  $V = 23$ .

С поправкой Бонферрони:  $R = 9$ ,  $V = 0$ .

С поправкой методом Холма:  $R = 10$ ,  $V = 0$ .

С поправкой Бенджамини-Хохберга:  $R = 33$ ,  $V = 1$ .

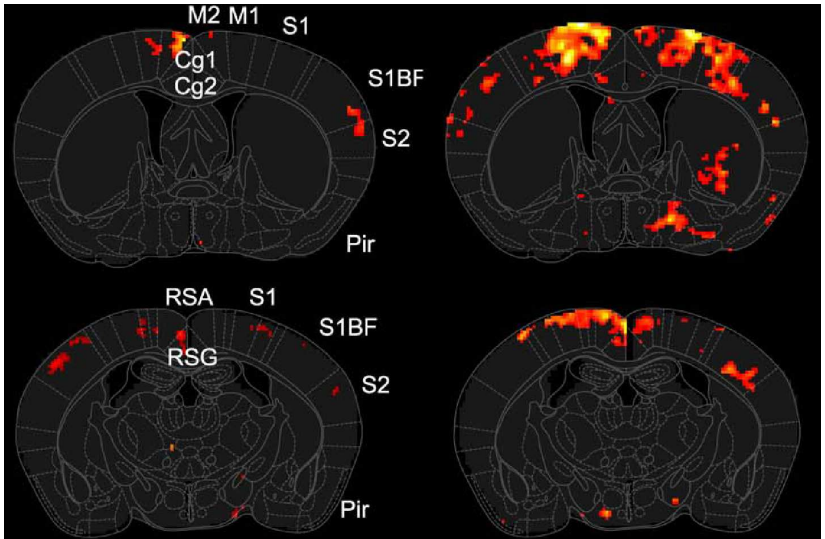
С поправкой Бенджамини-Йекутиели:  $R = 16$ ,  $V = 0$ .

## Способы улучшения


Если ожидается, что значение  $m_0$  невелико, можно оценить его и увеличить критические константы.

- $\hat{m}_0 = 2 \times \#\{p_i > 0.5\}$ ;
- $\hat{m}_0$  — число гипотез, не отвергаемых методом Бенджамини-Хохберга при  $q' = q / (q + 1)$ ;
- ...

# Экспрессия на срезах мозга



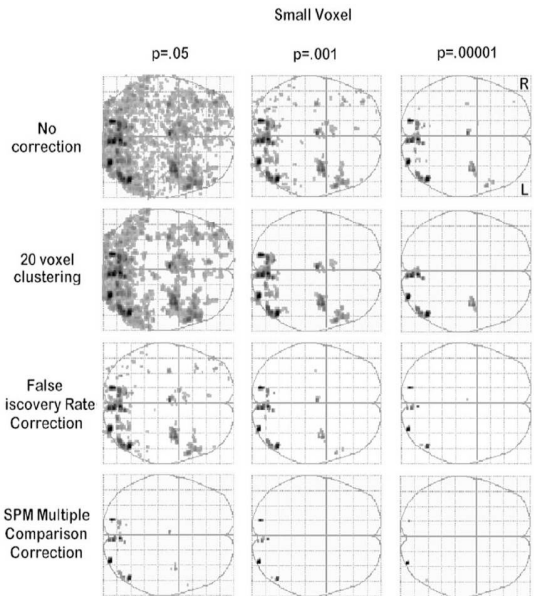
# Мёртвый лосось



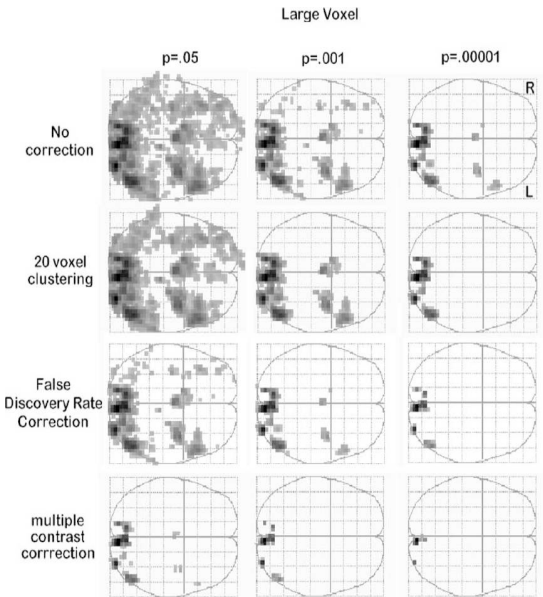
(Использовано отсечение по  $p$  с порогом  $\alpha = 0.001$ )





# Now you see it, now you don't



# Now you see it, now you don't



# FDR vs. FWER





# Типы контроля при наличии семейств

Далее рассматриваются меры ошибок первого рода, которые можно представить в виде  $\mathbb{E}(C)$  для некоторой случайной меры ошибок первого рода  $C$ .

$$FWER = P(V \geq 1) = \mathbb{E}(I_{\{V \geq 1\}})$$

$$FDR = \mathbb{E}\left(\frac{V}{R} \cdot I_{\{R > 0\}}\right) = \mathbb{E}(FDP)$$

Контроль на уровне семейств	$\mathbb{E}(C_{fam}) \leq q$
Контроль внутри каждого семейства	$\mathbb{E}(C_i) \leq q, \quad i = 1, \dots, m$
Контроль в среднем по отобранным семействам	$S$ — индексы отобранных семейств, $\mathbb{E}\left(\frac{\sum_{i \in S} C_i}{\max( S , 1)}\right) \leq q$
Глобальный контроль	$\mathbb{E}(C_{comb}) \leq q$

# Два экстремальных подхода

## Агрегированная проверка:


- проверяется множество индивидуальных гипотез, игнорируя семейства;
- обеспечен глобальный контроль;
- агрегированная проверка с глобальным контролем  $FDR$  не обеспечивает контроля  $FDR$  внутри семейств.

## Раздельная проверка:

- гипотезы каждого семейства проверяются независимо;
- обеспечен контроль внутри каждого семейства;
- мощность выше, чем при агрегированной проверке;
- не гарантируется глобальный контроль.

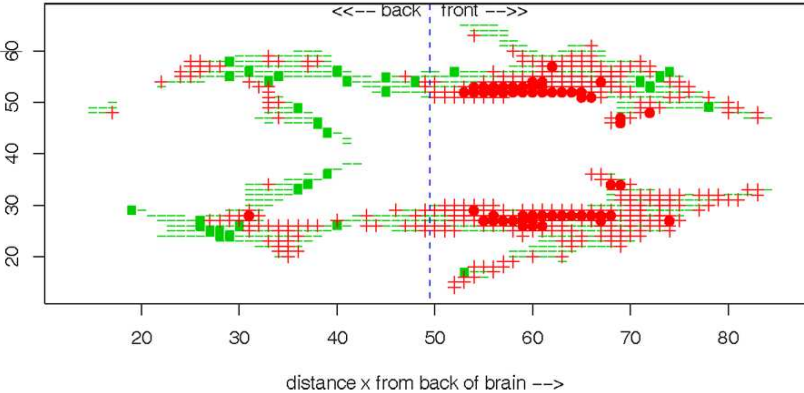
# Проблемы агрегированной проверки

Внутри семейств выводы могут быть искажены в обоих направлениях (в каких-то семействах получаем высокий уровень  $FDR$ , в каких-то — низкую мощность).



# Проблемы агрегированной проверки

Внутри семейств выводы могут быть искажены в обоих направлениях (в каких-то семействах получаем высокий уровень  $FDR$ , в каких-то — низкую мощность).





## Случай однородных семейств



Если распределение статистик  $F(t) = \frac{m_0}{m} F_0(t) + \frac{m-m_0}{m} F_1(t)$  во всех семействах одинаково, то:

- агрегированная проверка  $\approx$  отдельная проверка;
- контроль  $FDR$  обеспечен глобально и внутри каждого семейства;
- улучшать мощность некуда.

# Случай неоднородных семейств

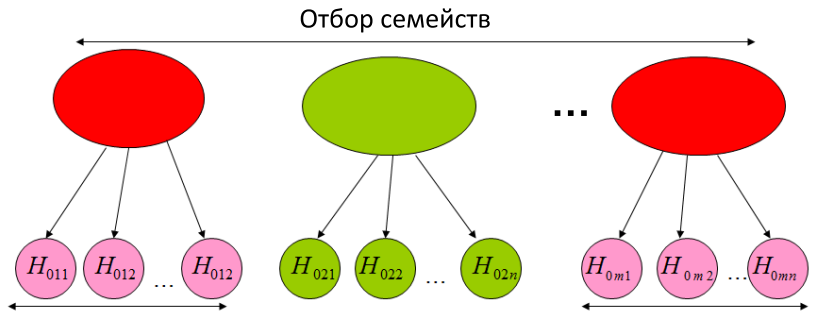
Если для разных семейств либо  $m_{oi} \approx 0$ , либо  $m_{oi} \approx 1$ , то:

- ни агрегированная, ни отдельная проверка методом Бенджамини-Хохберга не гарантирует контроль над  $FDR$  одновременно глобально и внутри каждого семейства;
- при большой размерности отдельная проверка будет иметь значительно большую мощность.



# Идея

- На первом этапе отобрать подающие надежды семейства (в которых есть признаки содержания ложных нулевых гипотез).
- На втором этапе сделать отдельную проверку гипотез в отобранных семействах.



Раздельная проверка	Проверка с отбором
В каждом семействе $i = 1, \dots, m$ применяется процедура, обеспечивающая контроль $\mathbb{E}(C)$	В каждом отобранном семействе $i \in S$ применяется процедура, обеспечивающая контроль $\mathbb{E}(C)$
$\mathbb{E}(C_i) \leq q, i = 1, \dots, m$	$\mathbb{E}(C_i   i \in S) \leq q, i = 1, \dots, m$
Контроль в среднем по всем семействам: $\mathbb{E} \left( \frac{\sum_{i=1}^m C_i}{m} \right) \leq q$	Контроль в среднем по отобранным семействам: $\mathbb{E} \left( \frac{\sum_{i \in S} C_i}{\max( S , 1)} \right) \leq q$

Контроль в среднем по отобраным семействам

$$\mathbb{E}(C_S) = \mathbb{E}\left(\frac{\sum_{i \in S} C_i}{\max(|S|, 1)}\right)$$

$\mathbb{E}(C)$	$\mathbb{E}(C_S)$	
$FWER$ $P(V \geq 1)$ $\mathbb{E}(I_{\{V \geq 1\}})$	$\mathbb{E}\left(\frac{\sum_{i \in S} I_{\{V \geq 1\}}}{\max( S , 1)}\right)$	$\mathbb{E}\left(\frac{\# \text{ семейств с } V \geq 1}{\# \text{ отобранных семейств}}\right)$
$FDR = \mathbb{E}(FDP)$	$\mathbb{E}\left(\frac{\sum_{i \in S} FDP_i}{\max( S , 1)}\right)$	Ожидаемое среднее значение $FDP$ по отобранным семействам

## Проблема

Проверка с отбором не обеспечивает контроль в среднем:

- рассмотрим  $m$  семейств по  $n$  верных гипотез;
- семейство отбирается, если  $p_i$  в нём меньше 0.05;
- каждое отобранное семейство проверяется с поправкой Бонферрони на уровне  $\alpha = 0.05$ ;
- $\mathbb{E}(C) = FWER$ .

$m$	$n$	$\mathbb{E}(\# \text{ отобранных}/m)$	$\mathbb{E}(C_S)$
20	100	0.99	0.049
100	20	0.64	0.076
100	10	0.40	0.122
100	2	0.10	0.506

# Исправленная процедура проверки с отбором

- На первом этапе к множеству достигаемых уровней значимости  $P$  применяется правило отбора  $S$ ;  $S(P)$  — множество отобранных семейств.
- На втором этапе в каждом отобранном семействе сделать отдельную проверку, применяя  $\mathbb{E}(C)$ -контролирующую процедуру на уровне  $q|S(P)|/m$ .

Контроль на уровне семейств	Нет
Контроль внутри каждого семейства	Да
Контроль в среднем по отобранным семействам	Да
Глобальный контроль	Нет

## Исправленная процедура проверки с отбором

### Требования.

- Правило отбора семейств должно быть **простым**: для каждого отбираемого семейства  $i$  при фиксированных достигаемых уровнях значимости всех гипотез все семейства и любом распределении достигаемых уровней значимости внутри семейства, при котором  $i \in S(P)$ , число отобранных семейств не меняется.
- Ограничения на структуру зависимости достигаемых уровней значимости.



## Иерархическая процедура проверки гипотез

Чтобы добавить контроль на уровне семейств, отбор нужно тоже проводить в соответствии с какой-либо процедурой множественной проверки гипотез.

- Каждому семейству поставить в соответствие его полную нулевую гипотезу.
- Скомбинировать  $\pi$ -величины внутри каждого семейства, получить  $\pi$ -величины для проверки полных нулевых гипотез.
- Выбрать и применить процедуру множественной проверки, контролирующую желаемую меру ошибки с учётом зависимости между  $\pi$ -величинами полных нулевых гипотез.
- Отобрать семейства, для которых полная нулевая гипотеза была отвергнута.
- Сделать отдельную проверку, применяя  $\mathbb{E}(C)$ -контролирующую процедуру на уровне  $q|S(P)|/m$ .

# Иерархическая процедура проверки гипотез

Контроль на уровне семейств	Да
Контроль внутри каждого семейства	Да
Контроль в среднем по отобранным семействам	Да
Глобальный контроль	Нет

Все одношаговые, нисходящие и восходящие методы контроля подходящих мер ошибок — простые.

- 1 Раздельная проверка гипотез на семействах не обеспечивает глобальный контроль над мерой ошибки.
- 2 При раздельной проверке гипотез только на предварительно отобранных семействах, не обеспечивается даже контроль в среднем.
- 3 Необходимо самостоятельно выбирать, какие виды контроля необходимы для интерпретации результатов.
- 4 Иерархическая процедура проверки может позволить увеличить мощность.