

# Сравнение парных выборок посредством quantile matching functions

Алексей Балицкий

МФТИ(ГУ), ФУПМ

March 3, 2014

# План

## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

# План

## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

## Определения

$F, G$  - два распределения.

QMF (quantile matching function):

$$q = G^{-1}(F),$$

т.е.

$$G(q(x)) = F(x).$$

Shift function:

$$\Delta(x) = q(x) - x.$$

## Сравнение независимых выборок

Doksum & Sievers (1976) предложили оценки для построения доверительной ленты для функции сдвига.

Они опирались на статистику Смирнова-Колмогорова:

$$K = \max |F(\bar{Z}_i) - \hat{G}(\bar{Z}_i)|,$$

где  $Z_i (i = 1, \dots, n + m)$  – объединённая выборка из  $X_j \sim F, Y_k \sim G$ .

# План

## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

# Копула

$(X_i, Y_i) \sim H$  – совместное распределение  $F, G$ .

Копула распределения  $H$ :

$$C(u, u') = H(F^{-1}(u), G^{-1}(u'))$$

– задаёт распределение  $(U, U')$ ,  $U, U' \sim Unif[0, 1]$ ,

$$(F, G) \sim (F^{-1}(U), G^{-1}(U'))$$

## Статистика Смирнова-Колмогорова

$$K^q = \left(\frac{n}{2}\right)^{1/2} \max |F(Z_i) - \hat{G}(q(Z_i))|$$

Её распределение в условиях истинности гипотезы  $F = G$  зависит лишь от  $C$ .

При  $F = G$ :

$$K = \sup_u |\hat{B}(u)|,$$

$$\hat{B}(u) = \left(\frac{n}{2}\right)^{1/2} (\hat{F}(F^{-1}(u_i)) - \hat{G}(F^{-1}(u_i)))$$

## Распределение статистики Смирнова-Колмогорова

Оказывается,  $\hat{B}$  сходится к гауссовскому процессу, для которого  
 $Cov(\hat{B}(u), \hat{B}(u')) = \min(u, u') - \frac{C(u, u') + C(u', u)}{2}$ .

Тогда

$$P(K \geq a) \approx P_C(\sup |\hat{B}(u)| \geq a) \approx P_{\hat{C}}(\sup |\hat{B}(u)| \geq a) \approx \\ \approx_{(Aldous, 1989)} \frac{1}{n} \sum f_i \times \psi_a\left(\frac{j-f_1-\dots-f_j}{n}\right).$$

Здесь  $\psi_y(x) = (2\pi x^3)^{-1/2} y \exp\left(-\frac{y^2}{2x}\right)$ ,

$f_j$  – частота встречаемости  $j$  среди  $\max(\text{rank}(X_i), \text{rank}(Y_i))$ .

## Границы доверительной ленты

Уравнение

$$\frac{1}{n} \sum f_i \times \psi_a\left(\frac{j - f_1 - \dots - f_j}{n}\right) = \alpha$$

разрешают относительно  $a$  алгоритмом, описанным у Nelder & Mead (1965),

что позволяет найти квантили  $\hat{k}_\alpha$  распределения статистики Смирнова-Колмогорова.

# План

## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

## Перестановочный метод

Если  $C(u, u') = C(u', u)$ , можно рассмотреть орбиту выборки  $(X_1, \dots, X_n, Y_1, \dots, Y_n)$  под действием группы перестановок

$$G = \langle s_1, \dots, s_n \rangle, \quad s_i : (X_i, Y_i) \mapsto (Y_i, X_i).$$

$$P^{perm}(K \leq a) = 2^{-n} \sum_{s \in G} [K_s \leq a]$$

## Проверка симметричности копулы

$$T_1 = \frac{2}{n-1} \sum_{k < l} (\hat{C}\left(\frac{k}{n}, \frac{l}{n}\right) - \hat{C}\left(\frac{l}{n}, \frac{k}{n}\right))^2$$

$$T_2 = \left(\frac{n}{2}\right)^{1/2} \max_{k < l} |\hat{C}\left(\frac{k}{n}, \frac{l}{n}\right) - \hat{C}\left(\frac{l}{n}, \frac{k}{n}\right)|$$

## Доверительная лента

Пусть  $\hat{k}_\alpha$  определено.

$\{q : K^q \leq \hat{k}_\alpha\}$  – доверительное множество для QMF.

$$\begin{aligned} Y_{(j - [(2n)^{1/2} \hat{k}_\alpha])} &\leq q(X_{(j)}) \leq Y_{(j + [(2n)^{1/2} \hat{k}_\alpha])} \\ X_{(j - [(2n)^{1/2} \hat{k}_\alpha])} &\leq q^{-1}(Y_{(j)}) \leq X_{(j + [(2n)^{1/2} \hat{k}_\alpha])} \end{aligned}$$

Инвариантна относительно обмена  $(X, Y) \mapsto (Y, X)$ !

## Реализация в R

```
lband(x,y:NA,alpha:0.05,plotit:T,sm:T,  
      ylab="delta",xlab="x (first group)")
```

# План

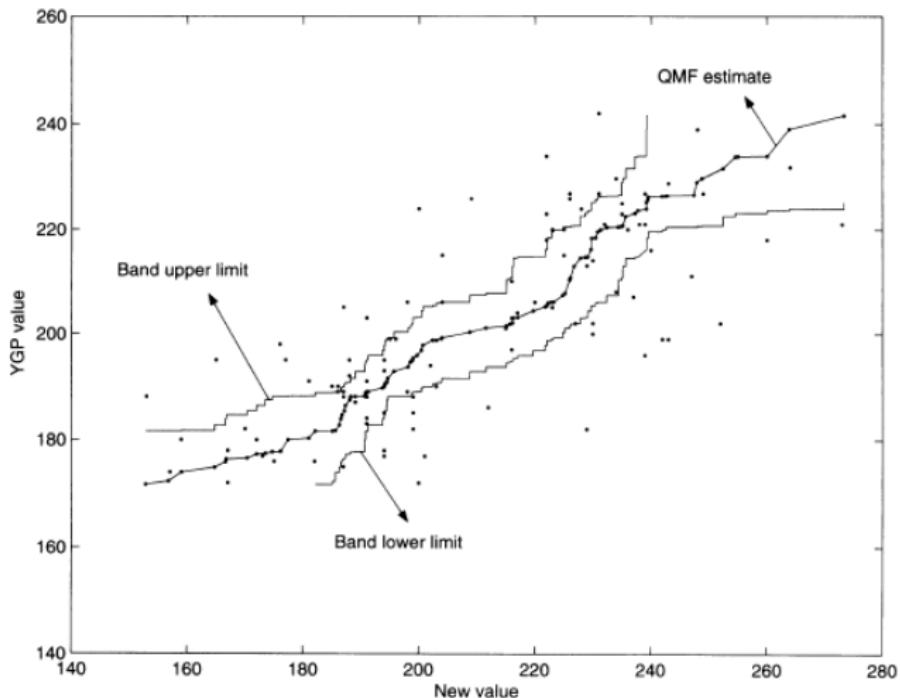
## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

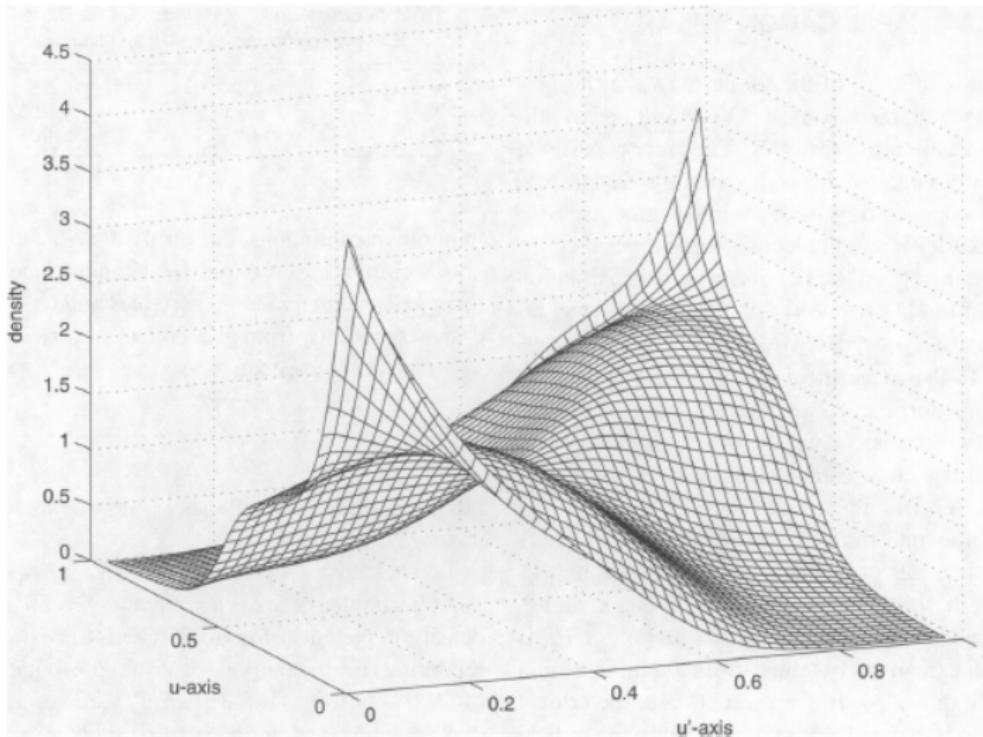
- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

# Исследование абразивных свойств угля



Scatterplot of 98 (YPG, new) Pairs Together With the Shift Function Estimate and 95% Simultaneous Confidence Band.

# Оценка копулы



# План

## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

## Метод Harrell'a и Davis'a

$$U \sim B(a, b) = Dirichlet(a, b), \quad a = (n+1)q, b = (n+1)(1-q).$$
$$p_U(u) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} u^{a-1} (1-u)^{b-1}.$$

$$W_i = P\left(\frac{i-1}{n} \leq U \leq \frac{i}{n}\right)$$

Оценка  $q$ -квантили:

$$\hat{\theta}_q = \sum_{i=1}^n W_i X_{(i)}.$$

# План

## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

## M-метод

$$H_0 : \theta_{qX} = \theta_{qY}$$

$$d_{qj}^* = \hat{\theta}_{qX}^* - \hat{\theta}_{qY}^*, \quad j = 1, \dots, B,$$

$\hat{\theta}_{qX}^*$ ,  $\hat{\theta}_{qY}^*$  – Harrell-Davis-оценки квантилей по бутстреп-репликации из множества пар  $(X_i, Y_i)$ .

Доверительный интервал для  $\theta_{qX} - \theta_{qY}$ :

$$(d_{(l+1)}^*, d_{(B-l)}^*),$$

где  $l = round(\frac{\alpha B}{2})$ .

## Реализация в R

```
shiftddhd(x,y,nboot=200,plotit=TRUE)
```

$$\bar{d}_q = \frac{1}{B} \sum_{j=1}^B d_{qj}^*$$

Доверительный интервал для  $\theta_{qX} - \theta_{qY}$ :

$$(\bar{d}_q - c\hat{\sigma}_{dq}, \bar{d}_q + c\hat{\sigma}_{dq}),$$

где  $c = \frac{37}{n^{1.4}} + 2.75$ ,  $\hat{\sigma}_{dq}^2 = \frac{1}{B-1} \sum_{j=1}^B (d_{qj}^* - \bar{d}_q)^2$ .

## D-Метод

$D_i = X_i - Y_i$ ,  $\delta_q$  – q-квантиль распределения  $D$ .

$$H_0 : \delta_q + \delta_{1-q} = 0$$

$$\Delta_j^* = \delta_q^* + \delta_{1-q}^*, \quad j = 1, \dots, B,$$

$\delta_q^*$  – Harrell-Davis-оценка квантили по бутстреп-репликации из выборки  $D_i$ .

Доверительный интервал для  $\delta_q + \delta_{1-q}$ :

$$(d_{(l+1)}^*, d_{(B-l)}^*),$$

где  $l = round(\frac{\alpha B}{2})$ .

# Сравнение

To provide some sense of how the power of methods M and D compare to the power of the method derived by Lombard (2005), data were generate from two normal distributions both having variance one,  $\rho = 0$ , the first marginal distribution had a mean of 0 and the second a mean of 1. Comparing the .25 quantiles at the .05 level, power was estimated to be 0.81 using method M with  $n = 25$ . For method D, power was estimated to be 0.88. Power using Lombard's method was estimated to be 0. Again, Lombard's method performs relatively well, in terms of power, given the goal of detecting differences between the quantiles close to the population median. But in terms of detecting differences when comparing quartiles or when  $q$  is relatively close to zero or one, power is poor.

# План

## 1 Результаты F.Lombard'a (2005)

- Метод больших выборок
- Перестановочный метод
- Пример применения

## 2 Результаты R.Wilcox'a и D.Erceg-Hurn'a (2012)

- Оценка квантилей методом Harrell'a и Davis'a
- Методы проверки гипотез о квантилях
- Примеры применения

## Влияние вмешательства на депрессию

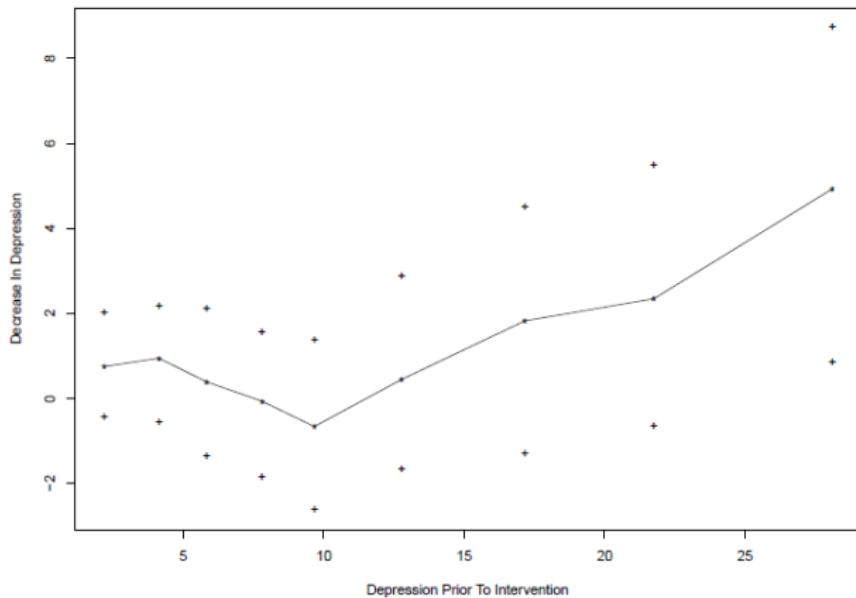


Figure 1: Decrease in depression is indicated by the y-axis. The x-axis indicates the level of

# Влияние алкоголя

Table 5.10: The Effect of Alcohol in the Control Group.

Time 1	0	32	9	0	2	0	41	0	0	0
	6	18	3	3	0	11	11	2	0	11
Time 3	0	25	10	11	2	0	17	0	3	6
	16	9	1	4	0	14	7	5	11	14

