

# Το επαναληπτικό

## Μη Παραμετρική Στατιστική

Παναγιώτης Παπασταμούλης  
Αναπληρωτής Καθηγητής  
Τμήμα Στατιστικής ΟΠΑ

[papastamoulis@aueb.gr](mailto:papastamoulis@aueb.gr)

2026



# Περιεχόμενα

- 1 Εμπειρική συνάρτηση κατανομής
- 2 Μη παραμετρική μέθοδος Δέλτα
- 3 Ο έλεγχος Kolmogorov-Smirnov για δύο ανεξάρτητους πληθυσμούς
  - Εισαγωγή
  - Παραδείγματα
  - Bootstrap συμπερασματολογία

## Άσκηση

Έστω  $X_1, \dots, X_n$  ανεξάρτητες και ισόνομες τ.μ. από κατανομή  $F$ .  
Να δειχτεί ότι

$$\text{Cov}(\hat{F}_n(x), \hat{F}_n(y)) = \frac{1}{n} [F(\min(x, y)) - F(x)F(y)]$$

για δύο διακριτά σημεία  $x$  και  $y$  ( $x \neq y$ ).

# Πρόβλημα

- Θεωρήστε τυχαίο δείγμα μεγέθους  $n$  απο εκθετική κατανομή  $\mathcal{E}(1)$
- Ενδιαφερόμαστε για την εκτίμηση του συναρτησιακού  $\sqrt{F(0.5)}$ , όπου  $F(x)$  η αθροιστική συνάρτηση κατανομής<sup>1</sup>
- Θεωρούμε τον εκτιμητή

$$\sqrt{\hat{F}_n(0.5)}$$

- Σκοπός: εύρεση ασυμπτωτικής κατανομής

---

<sup>1</sup>χωρίς να έχουμε γνώση της  $F$

# Μελέτη προσομοίωσης

# Πρόβλημα

- Θεωρήστε τυχαίο δείγμα μεγέθους  $n$  απο κανονική κατανομή  $\mathcal{N}(0, 1)$
- Ενδιαφερόμαστε για την εκτίμηση του συναρτησιακού  $\sqrt{F(-2)}$ , όπου  $F(x)$  η αθροιστική συνάρτηση κατανομής<sup>2</sup>

- Θεωρούμε τον εκτιμητή

$$\sqrt{\hat{F}_n(-2)}$$

- Σκοπός: εύρεση ασυμπτωτικής κατανομής

---

<sup>2</sup>χωρίς να έχουμε γνώση της  $F$

# Μελέτη προσομοίωσης

# Πρόβλημα

- Θεωρήστε τυχαίο δείγμα μεγέθους  $n$  απο κανονική κατανομή  $t_1$
- Ενδιαφερόμαστε για την εκτίμηση του συναρτησιακού  $\sqrt{F(-50)}$ , όπου  $F(x)$  η αθροιστική συνάρτηση κατανομής<sup>3</sup>
- Θεωρούμε τον εκτιμητή

$$\sqrt{\hat{F}_n(-50)}$$

- Σκοπός: εύρεση ασυμπτωτικής κατανομής

---

<sup>3</sup>χωρίς να έχουμε γνώση της  $F$

# Μελέτη προσομοίωσης

## Συνάρτηση επιρροής

Έστω  $X_1, \dots, X_n$  τυχαίο δείγμα  $n$  παρατηρήσεων από κατανομή  $F$  και  $\hat{F}_n(x)$  η εμπειρική συνάρτηση κατανομής. Για δεδομένο  $x$ , να δείξετε ότι η ασυμπτωτική κατανομή του συναρτησιακού  $\sqrt{\hat{F}_n(x)}$  είναι

$$\sqrt{\hat{F}_n(x)} \rightarrow \mathcal{N} \left( \sqrt{F(x)}, \frac{1 - F(x)}{4n} \right)$$

# Εισαγωγή

Ο έλεγχος του Kolmogorov (1933) για ένα δείγμα επεκτάθηκε από τον Smirnov (1939) για δύο δείγματα.

**Στόχος:** Σύγκριση δύο κατανομών βάσει ανεξάρτητων δειγμάτων.

- Δείγμα  $X_1, \dots, X_n \sim F_X$
- Δείγμα  $Y_1, \dots, Y_m \sim G_Y$
- Τα δείγματα είναι ανεξάρτητα

## Υπόθεση Ελέγχου

Θέλουμε να ελέγξουμε:

$$H_0 : F_X(x) = G_Y(x), \quad \forall x \in \mathbb{R}$$

$$H_1 : F_X(x) \neq G_Y(x), \quad \text{για κάποιο } x \in \mathbb{R}$$

**Ιδέα:** Σύγκριση των εμπειρικών συναρτήσεων κατανομής.

# Εμπειρικές Συναρτήσεις

Ορίζουμε:

- $\hat{F}_n(x)$ : εμπειρική CDF του δείγματος  $X$
- $\hat{G}_m(x)$ : εμπειρική CDF του δείγματος  $Y$

Η στατιστική συνάρτηση βασίζεται στη μέγιστη απόσταση μεταξύ τους.

# Στατιστική Kolmogorov–Smirnov

Η στατιστική συνάρτηση ορίζεται ως:

$$D_{n,m} = \sup_{x \in \mathbb{R}} |\hat{F}_n(x) - \hat{G}_m(x)|$$

Ισοδύναμα:

$$D_{n,m} = \max_{1 \leq i \leq n+m} |\hat{F}_n(Z_i) - \hat{G}_m(Z_i)|$$

όπου  $Z_1, \dots, Z_{n+m}$  είναι το διατεταγμένο ενωμένο δείγμα.

# Ανάλυση της Στατιστικής

Η στατιστική γράφεται ως:

$$D_{n,m} = \max\{D_{n,m}^+, D_{n,m}^-\}$$

όπου:

$$D_{n,m}^+ = \sup_x (F_n(x) - G_m(x))$$

$$D_{n,m}^- = \sup_x (G_m(x) - F_n(x))$$

## Θεώρημα

Έστω  $X_1, X_2, \dots, X_n$  ένα τυχαίο δείγμα από έναν πληθυσμό με άγνωστη αδροιστική συνάρτηση κατανομής  $F_X(\cdot)$  και  $Y_1, Y_2, \dots, Y_n$  ένα τυχαίο δείγμα από έναν πληθυσμό με άγνωστη αδροιστική συνάρτηση κατανομής  $G_Y(\cdot)$ . Υποθέτουμε ότι τα δύο δείγματα είναι ανεξάρτητα. Έστω, επιπρόσθετα,  $F_n(\cdot)$  και  $G_n(\cdot)$  οι αντίστοιχες εμπειρικές αδροιστικές συναρτήσεις κατανομής αυτών των πληθυσμών. Η κατανομή, υπό τη μηδενική υπόθεση  $H_0 : F_X(x) = G_Y(x), \forall x \in \mathbb{R}$ , των στατιστικών συναρτήσεων  $D_{n,n}^+ = \sup_x [F_n(x) - G_n(x)]$  και

$D_{n,n}^- = \sup_{x \in \mathbb{R}} (G_n(x) - F_n(x))$  δίνεται από τη σχέση:

$$P(D_{n,n}^+ > d) = P(D_{n,n}^- > d) = \frac{\binom{2n}{[n(d+1)]}}{\binom{2n}{n}},$$

όπου με  $[n(d+1)]$  συμβολίζουμε τον μεγαλύτερο ακέραιο που είναι μικρότερος ή ίσος από  $n(d+1)$ .

## Θεώρημα

Έστω ότι  $X_1, X_2, \dots, X_n$ , ένα τυχαίο δείγμα από έναν πληθυσμό με άγνωστη αδροιστική συνάρτηση κατανομής  $F_X(\cdot)$  και  $Y_1, Y_2, \dots, Y_m$ , ένα τυχαίο δείγμα από έναν πληθυσμό με άγνωστη αδροιστική συνάρτηση κατανομής  $G_Y(\cdot)$ . Υποθέτουμε ότι τα δύο δείγματα είναι ανεξάρτητα.

Έστω, επιπρόσθετα,  $F_n(\cdot)$  και  $G_m(\cdot)$  οι αντίστοιχες εμπειρικές αδροιστικές συναρτήσεις κατανομής αυτών. Όταν  $n$  και  $m$  είναι τέτοια, ώστε  $m, n \rightarrow \infty$ ,  $\frac{m}{n} \rightarrow q$ , με  $q$  σταθερό θετικό αριθμό, τότε, υπό τη μηδενική υπόθεση  $H_0 : F_X(x) = G_Y(x), \forall x \in \mathbb{R}$ , ισχύει ότι:

$$P \left( \sqrt{\frac{mn}{m+n}} D_{n,m} \leq d \right) \approx 1 - 2 \sum_{j=1}^{\infty} e^{-2j^2 d^2}.$$

# Άσκηση 1

Έστω δύο ανεξάρτητα τυχαία δείγματα

$$\mathbf{x} = (0.83, 3.57, 3.46, 2.05, 3.89, 2.54, 2.29, 1.15, 0.68, 0.84)$$


και

$$\mathbf{y} = (1.16, 1.45, 0.61, 2.67, 2.32, 2.84, 2.61, 1.59, 3.86, 3.12)$$

Να ελεγχθεί σε επίπεδο σημαντικότητας  $\alpha = 5\%$  η υπόθεση ισότητας των κατανομών.


# Εμπειρικές συναρτήσεις κατανομής και στατιστική συνάρτηση Kolmogorov-Smirnov

ECDF Comparison




# Εμπειρικές συναρτήσεις κατανομής και στατιστική συνάρτηση Kolmogorov-Smirnov

ECDF Comparison



# Εμπειρικές συναρτήσεις κατανομής και στατιστική συνάρτηση Kolmogorov-Smirnov

ECDF Comparison



Αναλυτικά:  $D_{n,m} = 0.3$

$i$	$z_i$	$\hat{F}_n(z_i)$	$\hat{G}_m(z_i)$	$ \hat{F}_n(z_i) - \hat{G}_m(z_i) $
1	0.61	0.00	0.10	0.10
2	0.68	0.10	0.10	0.00
3	0.83	0.20	0.10	0.10
4	0.84	0.30	0.10	0.20
5	1.15	0.40	0.10	<b>0.30</b>
6	1.16	0.40	0.20	0.20
7	1.45	0.40	0.30	0.10
8	1.59	0.40	0.40	0.00
9	2.05	0.50	0.40	0.10
10	2.29	0.60	0.40	0.20
11	2.32	0.60	0.50	0.10
12	2.54	0.70	0.50	0.20
13	2.61	0.70	0.60	0.10
14	2.67	0.70	0.70	0.00
15	2.84	0.70	0.80	0.10
16	3.12	0.70	0.90	0.20
17	3.46	0.80	0.90	0.10
18	3.57	0.90	0.90	0.00
19	3.86	0.90	1.00	0.10
20	3.89	1.00	1.00	0.00

## Με χρήση R

```
ks.test(x, y)
```

Exact two-sample Kolmogorov-Smirnov test

```
data: x and y
```

```
D = 0.3, p-value = 0.7869
```

```
alternative hypothesis: two-sided
```

## Με χρήση R

```
ks.test(x, y)
```

Exact two-sample Kolmogorov-Smirnov test

```
data: x and y
```

```
D = 0.3, p-value = 0.7869
```

```
alternative hypothesis: two-sided
```

Δεν απορρίπτουμε την υπόθεση ισότητας των κατανομών.

## Άσκηση 2

Έστω δύο ανεξάρτητα τυχαία δείγματα

$$\mathbf{x} = (0.83, 3.57, 3.46, 2.05, 3.89, 2.54, 2.29, 1.15, 0.68, 0.84, 1.16, 1.45)$$


και

$$\mathbf{y} = (1.88, 0.65, 0.34, 0.59, 2.36, 0.64, 0.29, 0.57)$$

Να ελεγχθεί σε επίπεδο σημαντικότητας  $\alpha = 5\%$  η υπόθεση ισότητας των κατανομών.


# Εμπειρικές συναρτήσεις κατανομής και στατιστική συνάρτηση Kolmogorov-Smirnov

ECDF Comparison




# Εμπειρικές συναρτήσεις κατανομής και στατιστική συνάρτηση Kolmogorov-Smirnov

ECDF Comparison



# Εμπειρικές συναρτήσεις κατανομής και στατιστική συνάρτηση Kolmogorov-Smirnov

ECDF Comparison



Αναλυτικά:  $D_{n,m} = 0.75$

$i$	$z_i$	$\hat{F}_n(z_i)$	$\hat{G}_m(z_i)$	$ \hat{F}_n(z_i) - \hat{G}_m(z_i) $
1	0.29	0.00	0.12	0.12
2	0.34	0.00	0.25	0.25
3	0.57	0.00	0.38	0.38
4	0.59	0.00	0.50	0.50
5	0.64	0.00	0.62	0.62
6	0.65	0.00	0.75	<b>0.75</b>
7	0.68	0.08	0.75	0.67
8	0.83	0.17	0.75	0.58
9	0.84	0.25	0.75	0.50
10	1.15	0.33	0.75	0.42
11	1.16	0.42	0.75	0.33
12	1.45	0.50	0.75	0.25
13	1.88	0.50	0.88	0.38
14	2.05	0.58	0.88	0.29
15	2.29	0.67	0.88	0.21
16	2.36	0.67	1.00	0.33
17	2.54	0.75	1.00	0.25
18	3.46	0.83	1.00	0.17
19	3.57	0.92	1.00	0.08
20	3.89	1.00	1.00	0.00

## Με χρήση R

```
ks.test(x, y)
```

Exact two-sample Kolmogorov-Smirnov test

```
data: x and y
```

```
D = 0.75, p-value = 0.004763
```

```
alternative hypothesis: two-sided
```

## Με χρήση R

```
ks.test(x, y)
```

Exact two-sample Kolmogorov-Smirnov test

```
data: x and y
```

```
D = 0.75, p-value = 0.004763
```

```
alternative hypothesis: two-sided
```


Απορρίπτουμε την υπόθεση ισότητας των κατανομών.

## Bootstrap version

- Πώς θα μπορούσαμε να απαντήσουμε το παραπάνω μέ χρήση bootstrap;

# Άσκηση 1: Bootstrap δείγματα (υπό την $H_0$ )

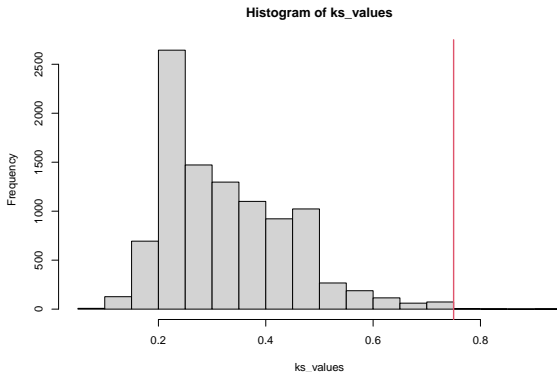
# Bootstrap στα δεδομένα της Άσκησης 1



Εκτιμηθέν  $p$ -value = 0.7012

## Άσκηση 2: Bootstrap δείγματα (υπό την $H_0$ )

## Bootstrap στα δεδομένα της Άσκησης 2



Εκτιμηθέν  $p$ -value = 0.0037