

21-6-2022

uoa. webex.com/join/aburnetas

## Bootstrap - simulation

$$X \sim F(\theta)$$

Θέλουμε να εκτιμήσουμε το  $\theta$ .

Δείγμα (πραγματικό από τον πληθυσμό)

$$(x_1, x_2, \dots, x_n) \text{ από } F$$

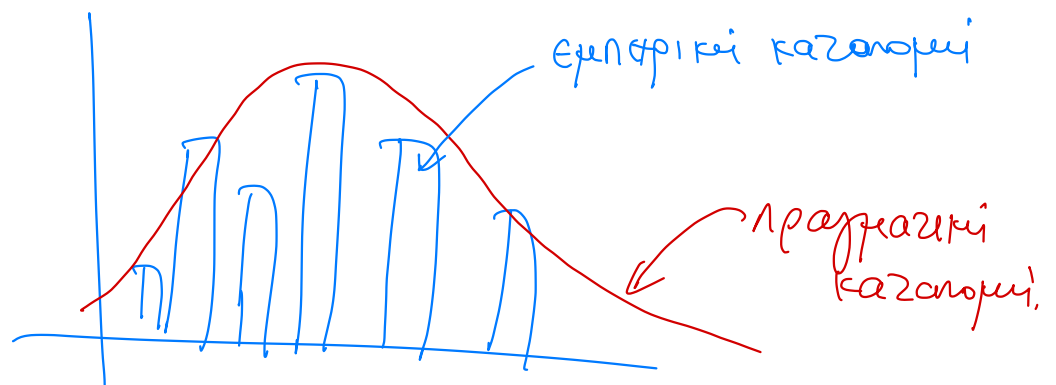
$$\hat{\theta} = T(x_1, \dots, x_n) \leftarrow \begin{array}{l} \text{στατιστική συνάρτηση} \\ \text{εκτίμηση του } \theta \text{ -} \\ \text{(σημιακή εκτίμηση)} \end{array}$$

sampling  
distribution

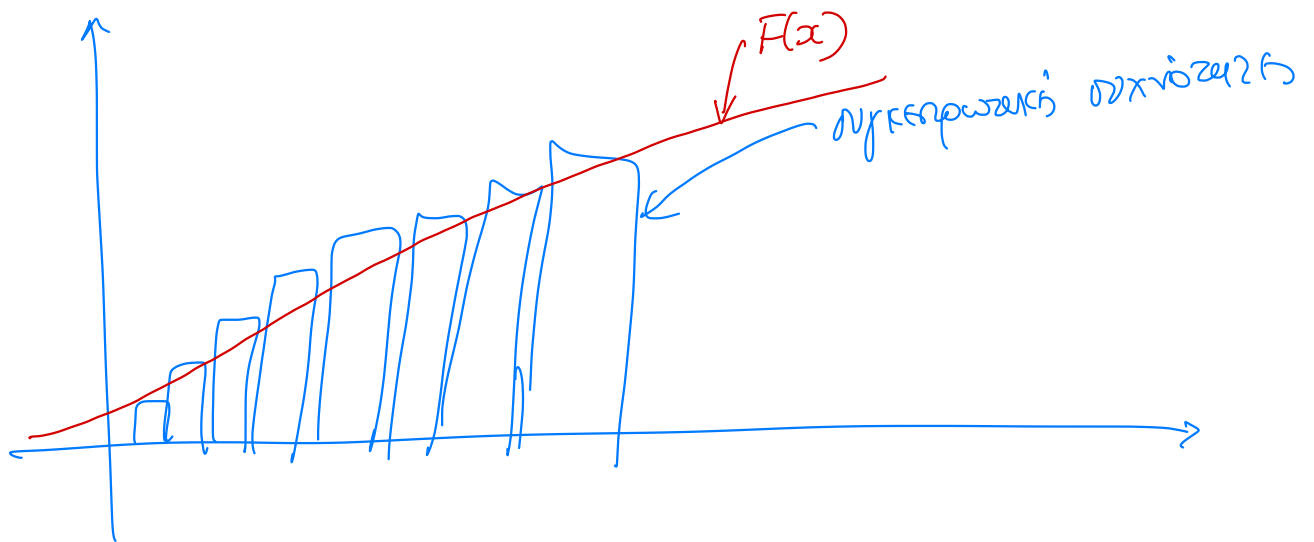
→ τυχαία μεταβλητή

που τυχαία δείχεται από την

## Ιστόγραμμα



αυτή η μέθοδος ιστόγραμμα  $\rightarrow$  σππ



Βασική Ιδιότητα 1: Γεννήτρια ωραίων  
αριθμών από Εμπειρική κατανομή.

Η Εμπειρική κατανομή διαφέρει

π.χ.  $n = 10$   
 $x = (2, 3, 2, 5, 6, 1, 3, 2, 3, 4)$

συν.

1 :	4/10	5 :	1/10
2 :	3/10	6 :	1/10
3 :	3/10		
4 :	1/5		

Επιλεκτική κατανομή

Διακριτική

	1	2	3	4	5	6
p	$\frac{1}{10}$	$\frac{2}{10}$	$\frac{3}{10}$	$\frac{1}{10}$	$\frac{1}{6}$	$\frac{1}{10}$

Βασική Ιδιότητα 2 : Αν πάρω ένα δείγμα μεγέθους  $n$  από το αρχικό μου δείγμα (με επανάθεση)

$\Rightarrow$  η κατανομή αυτού του νέου δείγματος είναι η επιλεκτική κατανομή του αρχικού.

R: `sample(x, i, replace=TRUE)`

$\hookrightarrow$  τυχαίο σύνολο (δείγμα) μεγέθους  $i$  από τα στοιχεία του  $x$ , με επανάθεση (επιτρέπονται οι επαναλήψεις)

# Προσφαζικόζα

αγρωσι κατανομι F

Ενα δείγμα <sup>(n)</sup> από F (x)

$\theta$  : αγρωσι παραμ.

$\hat{\theta} = T(x)$  : εκτίμησι

Αν  $n \rightarrow \infty$   $\hat{\theta} \rightarrow \theta$   
(συνέντα)

# Δείγμα (x)


$F_e$  : επειλερική (από x)

$\hat{\theta}$  (αανδρική τιμή παραμετρών κάτω από  $F_e$ )

Μέσω bootstrap (sample)

παιρνω  $N$  δείγματα μεγέθους  $n$  από  $F_e$

Σε καθένα υποδείγμα



διαφορετικές τιμές ως εκτεμνίς  $T$ .

π.χ. bias T

$$E(T) - \theta = b$$

$$\hat{T}_N - \hat{\theta} = \hat{b}$$

εκτίμησι bias μέσω bootstrap.

Έχουμε :  $\hat{\theta}$  : εκτίμηση του  $\theta$

$\hat{b}$  : εκτίμηση του bias  $b$

$$\hat{b} = \widehat{ET} - \theta$$

Διόρθωση του  $\hat{\theta}$  για να πάρουμε υπόψη το bias

Βελτιωμένη εκτίμηση του  $\theta$

$$\tilde{\theta} = \hat{\theta} - \hat{b} = \hat{\theta} - (\bar{T}_N - \hat{\theta})$$

$$\Rightarrow \boxed{\tilde{\theta} = 2\hat{\theta} - \bar{T}_N} \quad \text{bias correction μέσω bootstrap.}$$

## Παράδειγμα 2

Έστω ότι θέλουμε να εκτιμήσουμε το μέσο ζυγαρωμένο σφάλμα των  $T$ .

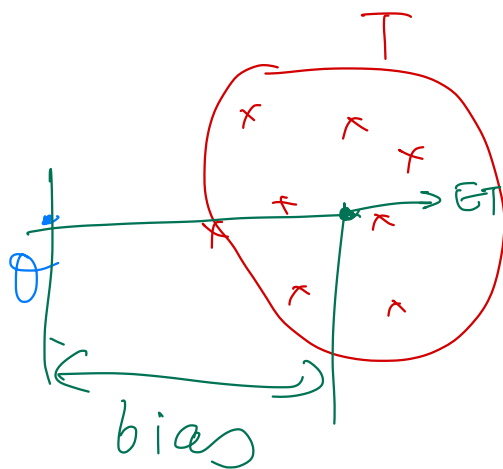
$$MSE = E(T - \theta)^2$$

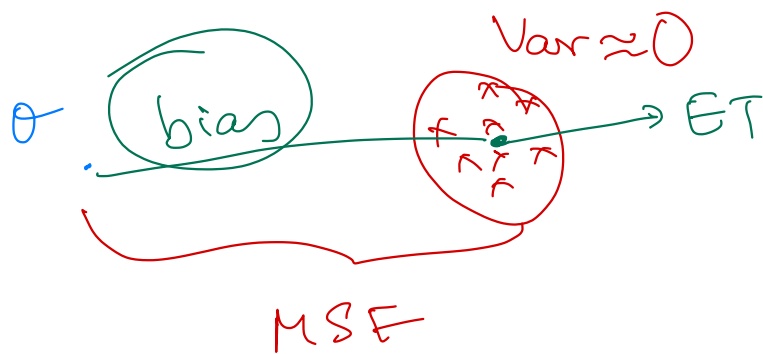
Αν η  $T$  αμερόμηκτα  $E(T) = \theta \Rightarrow$

$$\Rightarrow MSE = E(T - E(T))^2 = \text{Var}(T)$$

$$\hat{MSE} = S^2 \quad (\text{διαφορατική διασπορά})$$

Αν  $T$  δεν είναι αμερόμηκτα  $MSE = ?$





Συμπέρασμα:  $MSE = \text{Var}(T) + (ET - \theta)^2$   
 bias-variance decomposition

Εκτίμηση MSE μέσω bootstrap

$T_1, \dots, T_N$  από  $N$  δείγματα bootstrap.

$$\hat{MSE} = \frac{1}{N} \sum_{j=1}^N (T_j - \hat{\theta})^2$$

Παράδειγμα Έστω  $X \sim \text{Exp}(\lambda)$

Δείγμα μεγ.  $n$ :  $x_1, \dots, x_n$

$$\hat{\lambda} = \frac{1}{\bar{X}_n}$$

Έστω  $\lambda$  άγνωστο (συγκεκριμένο  
προέρχεται από  
συγκριτ. ανάλυση)

Εξέταση bias μέσω bootstrap.

①  $N$  bootstrap δείγματα από  $X$   
( $N$  δείγματα μεγ.  $n$  με επανάληψη)

Γε κάθε δείγμα  $j=1, \dots, N$

υπόψ.  $T_j = \frac{1}{(\bar{X}_n)_j}$

②  $\bar{T}_N = \frac{1}{N} \sum_{j=1}^N T_j$

③  $\hat{b} = \bar{T}_N - \frac{1}{\bar{X}_n} \leftarrow (\text{αρχικό})$



④ Corrected estimate (2)

$$\hat{a} = \frac{2}{\bar{X}_n} - \bar{T}_n$$

$$= \hat{a} - \hat{b}$$

# Markov Chain Monte Carlo (MCMC)

## Αλγόριθμος Metropolis-Hastings

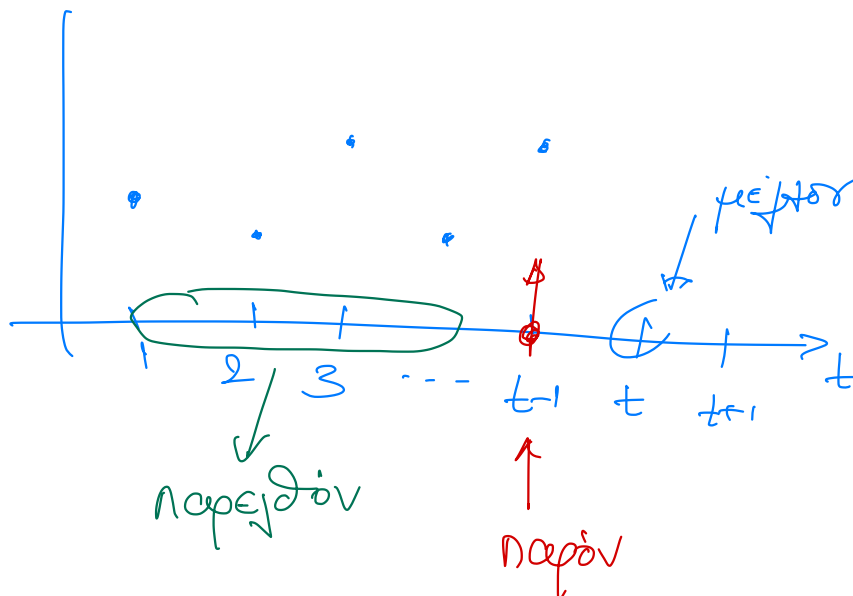
### Μαρκοβιανή Διαδικασία

Χρονοσειρά  $(X_1, X_2, \dots, X_t, X_{t+1}, \dots)$

$X_t$ : τιμή ενός μεγέθους (κατάσταση συστήματος)  
κατά τον περίοδο  $t$ .

Η κατανομή της  $X_t$  δεδομένων  $X_1, X_2, \dots, X_{t-1}$   
εξαρτάται μόνο από το  $X_{t-1}$  & όχι  
από τα προηγούμενα επίσης


### Μαρκοβιανή ιδιότητα



# Συνάρτηση Πιθανότητας μετάβασης (Transition kernel)

$$X^{(t)} \mid X^{(t-1)} = x \quad \text{τυχαία μεταβλητή με σππ} \quad q(y|x)$$

π.χ. δεδ  $X^{(t-1)} = x : X^{(t)} \sim \mathcal{N}(x, 1)$




## Στάσιμη και Οριακή κατανομή.

Κατω από κάποιες γενικές συνθήκες

η  $X_t$  όταν  $t \rightarrow \infty$  έχει οριακή κατανομή  $\pi(x)$ .

$$P(X_t = x) \xrightarrow{t \rightarrow \infty} \pi(x)$$



Η  $\pi(x)$  προκύπτει από  $q(y|x)$  μέσω κατάλληλων εξισώσεων.

### Βασική Ιδιότητα 1:

Έστω  $f(x)$  μια κατανομή για την οποία θέλουμε να κατασκευάσουμε γεννήτρια.

Αν βρούμε  $??$  ένα transition kernel  $q(y|x)$  τέτοιο ώστε  $\pi(x) = f(x)$

αυτό δίνει μια γεννήτρια:

## Αλγόριθμος

$X_0 : x$  αυθαίρετο

$X_1 \sim q(y/x_0)$  (από προορμωτά)

$X_1 \neq x_1 : X_2 \sim q(y/x_1)$

$X_3 \sim q(y/x_2)$

---

Βασική Ιδέα 2 : Πως προσδιορίζουμε το κατάλληλο kernel  $q(y|x)$ ?

## Αλγόριθμος Metropolis-Hastings

Εστω οποιοδήποτε kernel  $q(y|x)$

1. Δημιουργούμε με  $Y \sim q(y/x_{t-1})$  εστω  $Y=y$   
(προορμωτά)  $X_{t-1}=x$
2. Εστω  $\rho(x,y) = \min \left\{ \frac{f(y)q(x/y)}{f(x)q(y/x)}, 1 \right\}$

$$0 \leq \rho(x,y) \leq 1.$$

3. Κρατάμε το  $y$   $\delta\mu\phi$ .  $X_t = y$  με πιθαν.  $\rho$   
 το απορρίπτουμε  $\delta\mu\phi$ .  $X_t = x$  με πιθαν.  $1-\rho$

(Γέωυ προοομοίωμω)

$U \sim U(0,1)$   $\rightarrow$  αν  $U \leq \rho \Rightarrow X_t = y$   
 $\rightarrow$   $U > \rho \Rightarrow X_t = x$

