

# Εισαγωγή στην Οικονομετρία

Άγγελος Αλεξόπουλος

*angelos@aueb.gr*

ΚΩΔ: *PROPTYCHIAKA1404*

Διάλεξη 6-7

Εαρινό Εξάμηνο 2024

## Διμεταβλητές Τυχαίες Μεταβλητές

- ▶ Ένα διμεταβλητό τυχαίο διάνυσμα είναι μια συνάρτηση από το χώρο δειγματοληψίας  $S$  στον  $\mathbb{R}^2$ , δηλαδή στον δισδιάστατο Ευκλείδειο χώρο.
- ▶ Οι συντεταγμένες ενός τυχαίου διανύσματος δεν είναι απαραίτητα όλες του ίδιου τύπου (δηλαδή μπορεί να είναι κατηγορικές, διακριτές, συνεχείς, ή οποιασδήποτε συνδυασμός).

## Διακριτά Δισδιάστατα Τυχαία Διανύσματα

- ▶ Το τυχαίο διάνυσμα  $(X, Y)$  ονομάζεται **διακριτό** τυχαίο διάνυσμα αν παίρνει τιμές σε ένα μετρήσιμο (πεπερασμένο ή άπειρο) σύνολο. Τότε η συνάρτηση  $f(x, y) : \mathbb{R}^2 \rightarrow \mathbb{R}$  που ορίζεται από:

$$f_{X,Y}(x, y) = f(x, y) = P(X = x, Y = y)$$

ονομάζεται από κοινού πιθανότητα **μάζας** ή από κοινού συνάρτηση μάζας πιθανοτήτων του  $(X, Y)$ , αν:

$$f(x, y) \geq 0 \quad \text{και} \quad \sum_{(x,y) \in \mathbb{R}^2} f(x, y) = P((X, Y) \in \mathbb{R}^2) = 1$$

- ▶ Για  $A$ , υποσύνολο του  $\mathbb{R}^2$ , έχουμε:

$$P((X, Y) \in A) = \sum_{(x,y) \in A} f(x, y)$$

## Διακριτά Δισδιάστατα Τυχαία Διανύσματα

► Κοινή Αναμενόμενη Τιμή:

Αν  $g : \mathbb{R}^2 \rightarrow \mathbb{R}$  τότε

$$E[g(X, Y)] = \sum_{(x,y) \in \mathbb{R}^2} g(x, y) f(x, y)$$

εφόσον υπάρχει.

► Περιθώριες πιθανότητες μάζας:

Έστω  $(X, Y)$  ένα διακριτό δισδιάστατο τυχαίο διάνυσμα με κοινή συνάρτηση μάζας πιθανοτήτων  $f(x, y)$ . Τότε οι μονοδιάστατες συναρτήσεις πιθανοτήτων του  $X$  και του  $Y$  δίνονται από:

$$f_X(x) = P(X = x) = \sum_{y \in \mathbb{R}} f(x, y)$$

$$f_Y(y) = P(Y = y) = \sum_{x \in \mathbb{R}} f(x, y)$$

## Συνεχή Δισδιάστατα Τυχαία Διανύσματα

- ▶ Μια συνάρτηση  $f(x, y) : \mathbb{R}^2 \rightarrow \mathbb{R}$  ονομάζεται από κοινού συνάρτηση **πυκνότητας** πιθανότητας ή από κοινού **συνάρτηση πυκνότητας πιθανότητας (σ.π.π.)** του **συνεχούς** δισδιάστατου τυχαίου διανύσματος  $(X, Y)$  αν για κάθε  $A \subset \mathbb{R}^2$ ,

$$P((X, Y) \in A) = \iint_A f(x, y) dx dy$$

- ▶ Η  $f(x, y)$  θα είναι μια δισδιάστατη συνάρτηση πυκνότητας αν

$$f(x, y) \geq 0 \quad \text{και} \quad \iint_{\mathbb{R}^2} f(x, y) = 1$$

και το αντιστρόφο ισχύει.

# Συνεχή Δισδιάστατα Τυχαία Διανύσματα

- ▶ Από κοινού αναμενόμενη τιμή: Αν  $g : \mathbb{R}^2 \rightarrow \mathbb{R}$  τότε

$$E[g(X, Y)] = \iint_{\mathbb{R}^2} g(x, y) f(x, y)$$

εφόσον υπάρχει.

- ▶ **Περιθώρια σ.π.π.:** Έστω  $(X, Y)$  ένα συνεχές δισδιάστατο τυχαίο διάνυσμα με κοινή συνάρτηση πυκνότητας πιθανότητας  $f(x, y)$ . Τότε οι μαρгинаλ πδψς του  $X$  και του  $Y$  δίνονται από:

$$f_X(x) = \int_{y \in \mathbb{R}} f(x, y)$$

$$f_Y(y) = \int_{x \in \mathbb{R}} f(x, y)$$

## Δεσμευμένες κατανομές

**Δεσμευμένη πιθανότητα μάζας:** Έστω  $(X, Y)$  ένα διακριτό διμεταβλητό τυχαίο διάνυσμα με από κοινού συνάρτηση πιθανότητας μάζας  $f(x, y)$  και μονοδιάστατες συναρτήσεις πιθανοτήτων:  $f_X(x)$  και  $f_Y(y)$ .

- ▶ Για οποιοδήποτε  $x$  τέτοιο ώστε  $P(X = x) = f_X(x) > 0$ , η δεσμευμένη πιθανότητα μάζας του  $Y$  δεδομένου ότι  $X = x$  είναι η συνάρτηση του  $y$ :

$$f(y|x) = P(Y = y|X = x) = \frac{f(x, y)}{f_X(x)}$$

- ▶ Για οποιοδήποτε  $y$  τέτοιο ώστε  $P(Y = y) = f_Y(y) > 0$ , η δεσμευμένη πιθανότητα μάζας του  $X$  δεδομένου ότι  $Y = y$  είναι η συνάρτηση του  $x$ :

$$f(x|y) = P(X = x|Y = y) = \frac{f(x, y)}{f_Y(y)}$$

## Δεσμευμένες κατανομές

**Δεσμευμένες σ.π.π.:** Έστω  $(X, Y)$  ένα **συνεχές** διμεταβλητό τυχαίο διάνυσμα με κοινή συνάρτηση σ.π.π.  $f(x, y)$  και περιθώριες σ.π.π.:  $f_X(x)$  και  $f_Y(y)$ .

- ▶ Για οποιοδήποτε  $x$  τέτοιο ώστε  $f_X(x) > 0$ , η δεσμευμένη σ.π.π. του  $Y$  δεδομένου ότι  $X = x$  είναι η συνάρτηση του  $y$ :

$$f(y|x) = \frac{f(x, y)}{f_X(x)}$$

- ▶ Για οποιοδήποτε  $y$  τέτοιο ώστε  $f_Y(y) > 0$ , η δεσμευμένη σ.π.π. του  $X$  δεδομένου ότι  $Y = y$  είναι η συνάρτηση του  $x$ :

$$f(x|y) = \frac{f(x, y)}{f_Y(y)}$$



# Δεσμευμένες κατανομές - Ιεραρχική Μοντελοποίηση

- ▶ Δεσμευμένη Αναμονόμενη τιμή:

$$E[X|Y = y] = \int_{\mathbb{R}} xf(x|y)dx$$

εφόσον υπάρχει.

- ▶ Δεσμευμένη Διακύμανση:

$$Var[X|Y = y] = \int_{\mathbb{R}} (x - E[X|Y = y])^2 f(x|y)dx$$

εφόσον υπάρχει.

- ▶ Παρατηρήστε ότι τόσο το  $E[X|Y = y]$  όσο και το  $Var[X|Y = y]$  είναι συναρτήσεις του  $y$ .

# Ιεραρχική Μοντελοποίηση

**Θεώρημα:**

$$E[X] = E[E[X|Y]] \Rightarrow E_X[X] = E_Y[E_{X|Y}[X|Y]]$$

$$\text{Var}[X] = E[\text{Var}[X|Y]] + \text{Var}[E[X|Y]]$$

**Απόδειξη:**

$$\begin{aligned} E[E[X|Y]] &= \int_{\mathbb{R}} \left[ \int_{\mathbb{R}} x f(x|y) dx \right] f_2(y) dy = \int_{\mathbb{R}} \left[ \int_{\mathbb{R}} x f(x|y) f_2(y) dy \right] dx \\ &= \int_{\mathbb{R}} \left[ x \int_{\mathbb{R}} f(x, y) dy \right] dx = \int_{\mathbb{R}} x f_1(x) dx = E[X] \end{aligned}$$

$$\begin{aligned}
 \text{Var}[X|Y = y] &= \int_{\mathbb{R}} (x - E[X|Y = y])^2 f(x|y) dx \\
 \Rightarrow E[\text{Var}[X|Y = y]] &= \int_{\mathbb{R}} \left[ \int_{\mathbb{R}} (x - E[X|Y = y])^2 f(x|y) dx \right] f_2(y) dy \\
 &= \int_{\mathbb{R}} \int_{\mathbb{R}} [x - E(X|Y)]^2 f(x, y) dx dy \\
 &= E \left[ [X - E(X|Y)]^2 \right]
 \end{aligned}$$

$$E[\text{Var}[X|Y = y]] = E \left[ [X - E(X|Y)]^2 \right] \quad \text{(I)}$$

$$\begin{aligned}
 \text{Var}(X) &= \int_{\mathbb{R}} \int_{\mathbb{R}} (x - E[X])^2 f(x, y) dx dy = E \left[ (X - E[X])^2 \right] \\
 &= E \left[ (X - E[X|Y] + E[X|Y] - E[X])^2 \right] \\
 &= E \left[ (X - E[X|Y])^2 \right] + E \left[ (E[X|Y] - E[X])^2 \right] \\
 &\quad + 2E \left\{ (X - E[X|Y])(E[X|Y] - E[X]) \right\} = \text{(II)}
 \end{aligned}$$

$$E \left[ [X - E(X|Y)]^2 \right] = E [\text{Var}[X|Y = y]] \quad \text{by (I)}$$

$$E \left[ (E[X|Y] - E[X])^2 \right] = E \left[ (E[X|Y] - E[E[X|Y]])^2 \right] = \text{Var}[E[X|Y]]$$

Πρέπει μόνο να δείξουμε ότι

$$\begin{aligned} & E \{ (X - E[X|Y])(E[X|Y] - E[X]) \} \\ = & E [ E \{ (X - E[X|Y])(E[X|Y] - E[X]) | Y \} ] = 0 \end{aligned}$$

Τότε η (II) θα μας δίνει το ζητούμενο. Έστω

$$A = E \{ (X - E[X|Y])(E[X|Y] - E[X]) | Y \}$$

Τότε

$$\begin{aligned} A &= E \{ (X - E[X|Y])(E[X|Y] - E[X]) | Y \} \\ &= [E[X|Y] - E[X]] [E \{ (X - E[X|Y]) | Y \}] \\ &= [E[X|Y] - E[X]] \times 0 \\ &= 0 \end{aligned}$$

## Ανεξαρτησία

**Θεώρημα** Οι  $X$  και  $Y$  είναι ανεξάρτητες αν και μόνον αν ισχύει μία από τις παρακάτω περιπτώσεις:

α.  $F(x, y) = F_X(x)F_Y(y) \quad \forall x, y$

β.  $p(x, y) = p_X(x)p_Y(y)$ , όταν οι  $X$  και  $Y$  είναι διακριτές.

γ.  $f(x, y) = f_X(x)f_Y(y)$ , όταν οι  $X$  και  $Y$  είναι συνεχείς.

- ▶ Εάν οι  $X$  και  $Y$  είναι ανεξάρτητες, τότε η δεσμευμένη κατανομή του  $Y|X$  είναι ίδια με την μαργιναλ κατανομή του  $Y$ , δηλαδή  $f(y|x) = f_Y(y)$ .
- ▶ Οι  $X$  και  $Y$  είναι ανεξάρτητες αν και μόνον αν:

$$E[h_1(X)h_2(Y)] = E[(h_1(X))]E[(h_2(Y))]$$

για όλες τις συναρτήσεις  $h_1(\cdot)$  και  $h_2(\cdot)$  για τις οποίες τα ολοκληρώματα υπάρχουν.

## Covariance / Συνδιακύμανση

- ▶ Έστω  $(X, Y)$  ένα ζευγάρι τυχαίων μεταβλητών με  $\mu_X = E[X]$  και  $\mu_Y = E[Y]$ . Τότε η **διαριανση** του  $X$  και  $Y$  είναι ο αριθμός που ορίζεται από:

$$\text{Cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = E[XY] - E[X]E[Y]$$

- ▶  $X$  και  $Y$  είναι ανεξάρτητες  $\Rightarrow \text{Cov}(X, Y) = 0$  το αντίστροφο **δεν** είναι αληθές.
- ▶ Εάν  $X$  και  $Y$  είναι οποιεσδήποτε δύο τυχαίες μεταβλητές και  $a$  και  $b$  είναι οποιεσδήποτε δύο σταθερές, τότε:

$$\text{Var}(aX + bY) = a^2 \text{Var}(X) + b^2 \text{Var}(Y) + 2ab \text{Cov}(X, Y)$$

## Correlation/Συσχέτιση

- ▶ Έστω  $(X, Y)$  ένα ζευγάρι τυχαίων μεταβλητών με  $0 < \text{Var}[X] < +\infty$  και  $0 < \text{Var}[Y] < +\infty$ . Τότε ο συντελεστής **σσορρελατιον/συσχέτισης**  $\rho$  του  $X$  και του  $Y$  είναι ο αριθμός που ορίζεται από:

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}[X]}\sqrt{\text{Var}[Y]}}$$

- ▶ Για  $ac \neq 0$  ισχύει:

$$\rho(aX + b, cY + d) = \frac{ac}{|ac|} \rho(X, Y)$$

- ▶ Γενικά:  $-1 \leq \rho(X, Y) \leq 1$   $\rho(X, Y)^2 = 1 \Leftrightarrow Y = kX$  για κάποια σταθερά  $k$ .
- ▶ Αν οι  $X$  και  $Y$  είναι ανεξάρτητες,  $\Rightarrow X$  και  $Y$  είναι μη συσχετισμένες/υνσορρελατεδ ( $\rho(X, Y) = 0$ ). Η αντίστροφη πρόταση δεν είναι αληθής.



## Τυχαία Διανύσματα

- ▶ Ένα διάνυσμα  $X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix}$  είναι ένα τυχαίο διάνυσμα εάν για οποιοδήποτε  $t = \begin{bmatrix} t_1 \\ \vdots \\ t_n \end{bmatrix} \in \mathbb{R}^n$  έχουμε:  $t'X$  να είναι μια πραγματική τυχαία μεταβλητή.
- ▶ Εάν  $t_i = \begin{bmatrix} 0 & \vdots & t_i & \vdots & 0 \end{bmatrix} \in \mathbb{R}^n$  έχουμε: τότε  $X_i = t_i'X$  είναι μια συνιστώσα (ή προβολή).

## Τυχαία Διανύσματα

- ▶ Ένα διάνυσμα  $X = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix}$  είναι ένα τυχαίο διάνυσμα εάν για οποιοδήποτε  $t = \begin{bmatrix} t_1 \\ \vdots \\ t_n \end{bmatrix} \in \mathbb{R}^n$  έχουμε:  $t'X$  να είναι μια πραγματική τυχαία μεταβλητή.
- ▶ Εάν  $t_i = \begin{bmatrix} 0 & \vdots & t_i & \vdots & 0 \end{bmatrix} \in \mathbb{R}^n$  έχουμε: τότε  $X_i = t_i'X$  είναι μια συνιστώσα (ή προβολή).
- ▶ Συνάρτηση πολυμεταβλητής αθροιστικής κατανομής :

$$F(x_1, \dots, x_n) = P(X_1 \leq x_1, \dots, X_n \leq x_n)$$

# Τυχαία Διανύσματα

- ▶ **Συνεχή τυχαία διανύσματα:** Το  $X$  είναι συνεχές εάν:

$$F(x_1, \dots, x_n) = \int_{-\infty}^{x_n} \dots \int_{-\infty}^{x_1} f(u_1, \dots, u_n) du_1 \dots du_n$$

που:

$$f(u_1, \dots, u_n) \geq 0 \quad \text{και} \quad \int_{\mathbb{R}^n} f(u_1, \dots, u_n) du_1 \dots du_n = 1$$

- ▶ **Αναμενόμενη τιμή:** Αν  $g : \mathbb{R}^n \rightarrow \mathbb{R}$  τότε:

$$E[g(X)] = \int_{\mathbb{R}^n} g(X) f(X) dx$$

εφόσον το ολοκλήρωμα υπάρχει.

## Ανεξαρτησία

- ▶ Οι συντεταγμένες του τυχαίου διανύσματος  $X$ :  $X_1, X_2, \dots, X_n$  είναι ανεξάρτητες αν και μόνον αν:

$$f(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i)$$

- ▶ Οι συντεταγμένες του τυχαίου διανύσματος  $X$ :  $X_1, X_2, \dots, X_n$  είναι ανεξάρτητες αν και μόνον αν:

$$E \left[ \prod_{i=1}^n h(X_i) \right] = \prod_{i=1}^n E[(h_i(X_i))]$$

για όλες τις συναρτήσεις  $h_i(\cdot)$ , για τις οποίες τα ολοκληρώματα υπάρχουν.

# Τυχαίο Δείγμα

- ▶ Οι τυχαίες μεταβλητές  $X_1, X_2, \dots, X_n$  ονομάζονται ένα **τυχαίο δείγμα** μεγέθους  $n$  αν:
  - (α) Οι  $X_1, X_2, \dots, X_n$  είναι ανεξάρτητες
  - (β) Οι περιθώριες της κάθε  $X_i$  είναι η ίδια συνάρτηση  $f(x)$ .
- ▶ Αν οι  $X_1, X_2, \dots, X_n$  είναι τυχαίο δείγμα, τότε τις ονομάζουμε *independent identically distributed (iid)* τυχαίες μεταβλητές και τότε ισχύει:

$$f(x_1, \dots, x_n | \theta) = \prod_{i=1}^n f(x_i | \theta)$$

## Τυχαίο Δείγμα

- ▶ Η συνάρτηση  $f(x_1, \dots, x_n | \theta)$  είναι γνωστή ως **πιθανοφάνεια**, και συμβολίζεται ως  $L(\theta | \underline{x}) = L(\theta | x_1, \dots, x_n)$ , και για ένα συγκεκριμένο σύνολο δεδομένων  $(x_1, x_2, \dots, x_n)$  είναι απλά μια συνάρτηση της άγνωστης παραμέτρου  $\theta$ , δηλαδή  $\ell(\theta)$ .
- ▶ **Σημείωση:**  $X_i$  υποδηλώνει την τυχαία μεταβλητή ενώ  $x_i$  είναι η τιμή της τυχαίας μεταβλητής σε ένα τυχαίο δείγμα (δηλαδή  $X_i = x_i$ )

## Στατιστικές Συναρτήσεις

- ▶  $X_1, \dots, X_n$  είναι ένα τυχαίο δείγμα μεγέθους  $n$  από έναν πληθυσμό και έστω  $T(x_1, \dots, x_n)$  μια πραγματική (ή διανυσματική) συνάρτηση η οποία έχει σαν πεδίο ορισμού τον δειγματικό χώρο των  $(X_1, \dots, X_n)$ . Τότε η τυχαία μεταβλητή (ή διάνυσμα)  $Y = T(X_1, \dots, X_n)$  ονομάζεται **Στατιστική Συνάρτηση**.
- ▶ Δεδομένου ότι η τιμή του  $Y$  θα ποικίλλει από δείγμα σε δείγμα, μπορούμε να βρούμε την κατανομή πιθανότητας, την οποία θα ονομάσουμε **δειγματική κατανομή** του  $Y$ .
- ▶ Μια στατιστική **δεν** μπορεί να είναι μια συνάρτηση της παραμέτρου.
- ▶ Δύο από τις πιο δημοφιλείς στατιστικές συναρτήσεις είναι:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

**Θεώρημα :** Έαν  $X_1, \dots, X_n$  είναι ένα τυχαίο δείγμα μεγέθους  $n$  από έναν πληθυσμό και  $g(x)$  συνάρτηση τ.ω.  $E[g(X_1)]$  και  $Var[g(X_1)]$  ορίζονται, τότε

$$E\left[\sum_{i=1}^n g(X_i)\right] = nE[g(X_1)]$$

και

$$Var\left[\sum_{i=1}^n g(X_i)\right] = nVar[g(X_1)]$$



**Θεώρημα :** Έαν  $X_1, \dots, X_n$  είναι ένα τυχαίο δείγμα μεγέθους  $n$  από έναν πληθυσμό με  $E[X_i] = \mu$  και  $Var[X_i] = \sigma^2 < \infty$  τότε

$$E[\bar{X}] = \mu \quad V[\bar{X}] = \frac{\sigma^2}{n} \quad E[s^2] = \sigma^2$$

**Proof:**

$$E[\bar{X}] = E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n} E\left[\sum_{i=1}^n X_i\right] = \frac{1}{n} n E[X_1] = \mu$$

$$V[\bar{X}] = V\left[\frac{1}{n} \sum_{i=1}^n X_i\right] = \frac{1}{n^2} V\left[\sum_{i=1}^n X_i\right] = \frac{1}{n^2} n V[X_1] = \frac{\sigma^2}{n}$$

$$\begin{aligned} E[S^2] &= E\left[\frac{1}{n-1}\left(\sum_{i=1}^n X_i^2 - n\bar{X}^2\right)\right] = \frac{1}{n-1}\left[nE[X_1^2] - nE[\bar{X}^2]\right] \\ &= \frac{1}{n-1}\left[n\left(V[X_1] + (E[X_1])^2\right) - n\left(V[\bar{X}] + (E[\bar{X}])^2\right)\right] \\ &= \frac{1}{n-1}\left[n(\sigma^2 + \mu^2) - n\left(\frac{\sigma^2}{n} + \mu^2\right)\right] \\ &= \frac{1}{n-1}\left[n\sigma^2 + \sigma^2\right] = \frac{(n-1)\sigma^2}{n-1} = \sigma^2 \end{aligned}$$