

**Πανεπιστήμιο Κρήτης - Τμήμα Επιστήμης Υπολογιστών**  
**ΗΥ-317: Εφαρμοσμένες Στοχαστικές Διαδικασίες-Εαρινό Εξάμηνο 2016**  
**Διδάσκων: Π. Τσακαλίδης**

**Συνδιασπορά - Συσχέτιση Τυχαίων Μεταβλητών**

Επιμέλεια: Κωνσταντίνα Φωτιάδου

**1. Συνδιασπορά Τυχαίων Μεταβλητών:**

Η συνδιασπορά δύο τυχαίων μεταβλητών  $X$  και  $Y$ , συμβολίζεται ως:  $cov(X, Y)$ , και ορίζεται ως:

$$cov(X, Y) = E[(X - E[X]) \cdot (Y - E[Y])]$$

Επίσης, ένας εναλλακτικός ορισμός της συνδιασποράς είναι ο ακόλουθος:


$$cov(X, Y) = E[X \cdot Y] - E[X] \cdot E[Y]$$

**Απόδειξη:**


$$\begin{aligned} cov(X, Y) &= E[(X - E[X]) \cdot (Y - E[Y])] = E[X \cdot Y - X \cdot E[Y] - Y \cdot E[X] + E[X] \cdot E[Y]] = \\ &= E[X \cdot Y] - E[X] \cdot E[Y] - E[Y] \cdot E[X] + E[X] \cdot E[Y] = E[X \cdot Y] - E[X] \cdot E[Y] \end{aligned}$$

**1.1. Παρατηρήσεις**

- Το πρόσημο της συνδιασποράς περιέχει ένα σημαντικό δείκτη της σχέσης των τυχαίων μεταβλητών  $X$  και  $Y$ .
- Μια θετική ή αρνητική συνδιασπορά μας δείχνει ότι οι τιμές των  $X - E[X]$  και  $Y - E[Y]$  τείνουν να έχουν ίδιο ή αντίθετο πρόσημο σ' ένα συγκεκριμένο μοναδικό πείραμα. Οι παρακάτω γραφικές παραστάσεις απεικονίζουν δύο γραφικά παραδείγματα θετικής και αρνητικής διασποράς, όπου οι τυχαίες μεταβλητές  $X$  και  $Y$  είναι ομοιόμορφα κατανεμημένες πάνω σε ελλείψεις.



**(α) Θετική Συνδιασπορά**



**(β) Αρνητική Συνδιασπορά**

Σχήμα 1: Παραδείγματα Θετικής και Αρνητικής Συνδιασποράς

**Χρήσιμες Ιδιότητες Συνδιασποράς**

1.  $cov(X, Y) = cov(Y, X)$
2.  $cov(X, X) = var(X)$
3.  $cov(X + Y, Z) = cov(X, Z) + cov(Y, Z)$
4.  $cov(c \cdot X, Y) = c \cdot cov(X, Y)$

**1.2. Ασυσχετίστες Τυχαίες Μεταβλητές**

- Όταν  $cov(X, Y) = 0$ , οι τυχαίες μεταβλητές  $X$  και  $Y$  είναι ασυσχετίστες.
- Αν δύο τυχαίες μεταβλητές  $X$  και  $Y$  είναι ανεξάρτητες, τότε θα είναι και ασυσχετίστες.

**Απόδειξη:**

Έχουμε ότι:


$$cov(X, Y) = E[(X - E[X]) \cdot (Y - E[Y])] = E[(X - E[X])] \cdot E[(Y - E[Y])] = (E[X] - E[X]) \cdot (E[Y] - E[Y]) = 0$$

Οπότε οι τ.μ  $X$  και  $Y$  είναι ασυσχετίστες.

- **Προσοχή!** Το αντίστροφο δεν ισχύει πάντα. Εάν δύο τυχαίες μεταβλητές είναι ασυσχετίστες, δεν είναι απαραίτητα ανεξάρτητες!

**Παράδειγμα 1.2.1**

Έστω ζεύγος τυχαίων μεταβλητών  $(X, Y)$  που παίρνει τιμές  $(1,0)$ ,  $(0,1)$ ,  $(-1,0)$ ,  $(0,-1)$ , κάθε μία με πιθανότητα  $p = 1/4$ . Εξετάζουμε αν οι τ.μ  $X$  και  $Y$  είναι ασυσχετίστες και ανεξάρτητες.



Σχήμα 2: Γραφική παράσταση της κατανομής των τ.μ  $X$  και  $Y$  του παραδείγματος 1.2.

Στο παραπάνω σχήμα παριστάνεται η κατανομή των τυχαίων μεταβλητών  $X$  και  $Y$ .

Όπως παρατηρούμε, είναι συμμετρικές ως προς την αρχή των αξόνων.

Για τις μέσες τιμές των τ.μ  $X$  και  $Y$  ισχύει:  $E[X] = E[Y] = 0$ .

Επιπλέον, για κάθε ζεύγος  $(x, y)$ , είτε  $x = 0$ , είτε  $y = 0$ . Οπότε συνεπάγεται ότι το γινόμενο  $x \cdot y = 0$ .

Επομένως, η συνδιασπορά των τ.μ  $X$  και  $Y$  γίνεται:

$$cov(X, Y) = E[(X - E[X]) \cdot (Y - E[Y])] = E[X \cdot Y] - E[X] \cdot E[Y] = 0$$

Άρα, οι τ.μ  $X$  και  $Y$  είναι ασυσχέτιστες.

Όμως, δεν είναι ανεξάρτητες! Για παράδειγμα, μια μη-μηδενική τιμή της  $X$  προσδιορίζει την τιμή της  $Y$  στο μηδεν.

### 1.3. Συντελεστής Συσχέτισης Τυχαίων Μεταβλητών:

Συντελεστή συσχέτισης δύο τυχαίων μεταβλητών  $X$  και  $Y$ , συμβολίζουμε την ποσότητα:  $\rho(X, Y)$  και ορίζουμε ως εξής:

$$\rho(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X) \cdot var(Y)}}$$

#### 1.3.1. Παρατηρήσεις

- Θεωρείται μια κανονικοποιημένη μορφή της συνδιασποράς των τυχαίων μεταβλητών  $X$  και  $Y$ .
- Το  $\rho$  παίρνει τιμές μεταξύ  $-1$  και  $1$ . Δηλαδή:  $\rho \in [-1, 1]$ .
- Όταν  $\rho > 0$ , οι τιμές  $X - E[X]$  και  $Y - E[Y]$  τείνουν να έχουν το ίδιο πρόσημο.
- Όταν  $\rho < 0$ , οι τιμές  $X - E[X]$  και  $Y - E[Y]$  τείνουν να έχουν αντίθετο πρόσημο.
- Το μέγεθος του  $|\rho|$  παρέχει ένα κανονικοποιημένο μέτρο του πόσο αυτό αληθεύει.
- Όσο πιο κοντά βρίσκεται η τιμή του  $|\rho|$  στο  $1$ , τόσο πιο έντονη γίνεται αυτή η τάση.
- Υποθέτοντας ότι οι  $X, Y$  έχουν θετικές διασπορές, αποδεικνύεται ότι  $\rho = 1$  ή  $\rho = -1$ , αν και μόνο αν υπάρχει μια θετική (ή αντίστοιχα αρνητική) σταθερά  $c$  ώστε:

$$Y - E[Y] = c \cdot (X - E[X]), \quad \forall(x, y)$$

#### Παράδειγμα 1.3.1

Θεωρείστε  $n$  ανεξάρτητες ρίψεις ενός νομίσματος με πιθανότητα να έρθει κορώνα ίση με  $p$ . Έστω  $X$  και  $Y$  ο αριθμός των κορώνων και των γραμμάτων, αντίστοιχα.

Να μελετηθεί η συσχέτιση των  $X$  και  $Y$ .

#### Λύση

Για κάθε ζευγάρι  $(x, y)$  έχουμε ότι:  $x + y = n$ . Επειδή οι τυχαίες μεταβλητές  $X$  και  $Y$  είναι διωνυμικές με παραμέτρους  $p$  και  $1 - p$ , αντίστοιχα, έχουμε:

$$E[X] + E[Y] = n \cdot p + n \cdot (1 - p) = np + n - np = n$$

Επίσης,  $\forall(x, y)$  έχουμε:

$$X - E[X] = -(Y - E[Y])$$

Για να υπολογίσουμε το συντελεστή συσχέτισης των τυχαίων μεταβλητών  $X$  και  $Y$ , θα πρέπει πρώτα να βρούμε τη συνδιασπορά των  $X$  και  $Y$ .

$$\begin{aligned} cov(X, Y) &= E[(X - E[X]) \cdot (Y - E[Y])] = -E[(X - E[X]) \cdot (X - E[X])] = \\ &= -E[(X - E[X])^2] = -var(X) \end{aligned}$$

Επομένως, έχουμε:

$$\rho(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X) \cdot var(Y)}} = \frac{-var(X)}{\sqrt{var(X) \cdot var(X)}} = \frac{-var(X)}{\sqrt{var^2(X)}} = -1$$

## 2. Συσχέτιση τυχαίων μεταβλητών ( Correlation )

**Ορισμός:** Η συσχέτιση δύο τυχαίων μεταβλητών  $X$  και  $Y$  ορίζεται ως:

$$E[X \cdot Y] = \int_{-\infty}^{+\infty} x \cdot y \cdot f_{X,Y}(x, y) dx dy$$

### 2.1. Παρατηρήσεις

- Δύο τυχαίες μεταβλητές  $X$  και  $Y$  λέγονται ορθογώνιες, αν η συσχέτισή τους είναι μηδενική, δηλαδή αν:  $E[X \cdot Y] = 0$ .
- Προκύπτει ότι αν οι τυχαίες μεταβλητές  $X$  και  $Y$  είναι στατιστικά ασυσχέτιστες, τότε οι τυχαίες μεταβλητές  $X - \mu_X$  και  $Y - \mu_Y$ , είναι ορθογώνιες.

### 2.2. Θεωρήματα Συσχέτισης τυχαίων μεταβλητών

#### Θεώρημα 1.

Αν οι τυχαίες μεταβλητές  $X$  και  $Y$  είναι στατιστικά ασυσχέτιστες, τότε η διασπορά του αθροίσματος είναι ίση με το άθροισμα των διασπορών των  $X$  και  $Y$ .

$$\sigma_{X+Y}^2 = \sigma_X^2 + \sigma_Y^2$$

#### Απόδειξη

Θεωρούμε την τυχαία μεταβλητή  $Z = X + Y \Leftrightarrow \mu_Z = \mu_X + \mu_Y$ .

Η διασπορά της τ.μ  $Z$  θα είναι:

$$\begin{aligned} \sigma_Z^2 &= E[(Z - \mu_Z)^2] = E\left[\left((X - \mu_X) + (Y - \mu_Y)\right)^2\right] = \\ &= E\left[(X - \mu_X)^2\right] + 2E\left[(X - \mu_X) \cdot (Y - \mu_Y)\right] + E\left[(Y - \mu_Y)^2\right] = \\ &= \sigma_X^2 + \sigma_Y^2 + cov(X, Y) = \sigma_X^2 + \sigma_Y^2, \text{ εφόσον } X, Y: \text{ ασυσχέτιστες} \end{aligned}$$

#### Θεώρημα 2.

Αν οι τυχαίες μεταβλητές  $X$  και  $Y$  είναι ορθογώνιες τότε:

$$E[(X + Y)^2] = E[X^2] + E[Y^2]$$

**Απόδειξη**

Έχουμε ότι:

$$E[(X + Y)^2] = E[X^2] + 2E[X \cdot Y] + E[Y^2] = E[X^2] + E[Y^2], \text{ εφόσον οι τ.μ } X, Y \text{ είναι ορθογώνιες}$$

**Θεώρημα 3.**

Αν οι τυχαίες μεταβλητές  $X$  και  $Y$  είναι ασυσχέτιστες και η μέση τιμή της μιας τουλάχιστον είναι μηδέν, τότε είναι ορθογώνιες.

**Απόδειξη**

Εφόσον οι τ.μ  $X$  και  $Y$  είναι ασυσχέτιστες, θα ισχύει:  $E[X \cdot Y] = E[X] \cdot E[Y]$ .

Επίσης, είτε  $E[X] = 0$  ή  $E[Y] = 0 \Rightarrow E[X \cdot Y] = 0 \Rightarrow$  οπότε οι τ.μ  $X$  και  $Y$  είναι ορθογώνιες.

**Ανισότητα Schwarz**

Για δύο τυχαίες μεταβλητές  $X$  και  $Y$  ισχύει η ακόλουθη ανισότητα:

$$\left(E[X \cdot Y]\right)^2 \leq E[X^2] \cdot E[Y^2]$$

**Απόδειξη**

Ορίζουμε την τυχαία μεταβλητή  $X - \lambda Y$ ,  $\lambda \in \mathbb{R}$ .

Και έστω  $P(\lambda) = E[(X - \lambda Y)^2] \forall \lambda \in \mathbb{R}$  έχουμε:

$$\begin{aligned} 0 \leq P(\lambda) &= E[(X - \lambda Y)^2] = \lambda^2 \cdot E[Y^2] + E[X^2] - 2 \cdot \lambda \cdot E[X \cdot Y] \Leftrightarrow \\ &\lambda^2 \cdot E[Y^2] - 2\lambda \cdot E[X \cdot Y] + E[X^2] = 0 \Leftrightarrow \end{aligned}$$

Βρίσκουμε την πρώτη παράγωγο ως προς  $\lambda$ :

$$P'(\lambda) = 2\lambda \cdot E[Y^2] - 2E[X \cdot Y]$$

Εξετάζουμε το πρόσημο και της δεύτερης παραγώγου της  $P(\lambda)$ :

$$P''(\lambda) = 2E[Y^2] > 0$$

Επειδή η δεύτερη παράγωγος είναι θετική, το τριώνυμο έχει τοπικό ελάχιστο. Μηδενίζοντας την πρώτη παράγωγο, βρίσκουμε το ελάχιστο:

$$\begin{aligned} 2\lambda \cdot E[Y^2] - 2E[X \cdot Y] &= 0 \Leftrightarrow \\ \lambda_{min} &= \frac{E[X \cdot Y]}{E[Y^2]} \end{aligned}$$

Υπολογίζουμε την αντίστοιχη τιμή του τριωνύμου:

$$\begin{aligned} 0 \leq E[X^2] + \frac{\left(E[X \cdot Y]\right)^2}{E[Y^2]} - 2 \cdot \frac{E[X \cdot Y]}{E[Y^2]} \cdot E[X \cdot Y] &\Leftrightarrow \\ 0 \leq E[X^2] - \frac{\left(E[X \cdot Y]\right)^2}{E[Y^2]} &\Leftrightarrow \\ \left(E[X \cdot Y]\right)^2 &\leq E[X^2] \cdot E[Y^2], \text{ Αποδείχθηκε} \end{aligned}$$

### 3. Συνδιασπορά Αθροίσματος Τυχαίων μεταβλητών

Μέσω της έννοιας της συνδιασποράς, μπορούμε να επεκτείνουμε την έννοια της διασποράς του αθροίσματος τ.μ και σε αθροίσματα μη- ανεξάρτητων τ.μ.

Εάν  $X_1, X_2, \dots, X_n$ , τ.μ με πεπερασμένες διασπορές, έχουμε:

$$var(X_1 + X_2) = var(X_1) + var(X_2) + 2 \cdot cov(X_1, X_2)$$

Στην γενικευμένη περίπτωση, έχουμε ότι:

$$var(X) = var\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n var(X_i) + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n cov(X_i, X_j)$$

#### Απόδειξη

Θέτουμε:  $\tilde{X}_i = X_i - E[X_i]$

Έχουμε:

$$\begin{aligned} var\left(\sum_{i=1}^n X_i\right) &= E\left[\left(\sum_{i=1}^n \tilde{X}_i\right)^2\right] = E\left[\sum_{i=1}^n \sum_{j=1}^n \tilde{X}_i \tilde{X}_j\right] = \sum_{i=1}^n \sum_{j=1}^n E[\tilde{X}_i \cdot \tilde{X}_j] = \\ &= \sum_{i=1}^n E[\tilde{X}_i^2] + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n E[\tilde{X}_i \cdot \tilde{X}_j] = \\ &= \sum_{i=1}^n var(X_i) + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n cov(X_i, X_j), \text{ Αποδείχθηκε} \end{aligned}$$

#### Εφαρμογή

Θεωρήστε το πρόβλημα των καπέλων, όπου  $n$  άτομα πετούν τα καπέλα τους σ'ένα κουτί και ακολούθως ανασύρουν από ένα καπέλο στην τύχη. Να βρεθεί η διασπορά της τ.μ  $X$ , η οποία εκφράζει τον αριθμό των ατόμων που ανασύρουν το δικό τους καπέλο.

#### Λύση

Έστω ότι  $X = X_1 + X_2 + \dots + X_n$ .

Επίσης, έστω  $X_i$ : Η τυχαία μεταβλητή που παίρνει την τιμή 1, αν το  $i$ -οστό άτομο ανασύρει το δικό του καπέλο. Διαφορετικά, παίρνει την τιμή 0.

Η τ.μ  $X_i \sim \text{Bernoulli}$ , με  $p = P(X_i = 1) = \frac{1}{n}$ .

Η διασπορά της τ.μ  $X_i$ ,  $var(X_i)$ , θα είναι:

$$var(X_i) = \frac{1}{n} \cdot \left(1 - \frac{1}{n}\right)$$

Για να βρούμε τη διασπορά της τ.μ  $X$ , θα πρέπει πρώτα να υπολογίσουμε την συνδιασπορά των τ.μ  $X_i$  και  $X_j$ .

Έχουμε:

$$\begin{aligned} cov(X_i, X_j) &= E\left[(X_i - E[X_i]) \cdot (X_j - E[X_j])\right] = E[X_i \cdot X_j] - E[X_i] \cdot E[X_j] = \\ &= P(X_i = 1 \text{ και } X_j = 1) - P(X_i = 1) \cdot P(X_j = 1) = \\ &= P(X_i = 1) \cdot P(X_j = 1 | X_i = 1) - P(X_i = 1) \cdot P(X_j = 1) = \\ &= \frac{1}{n} \cdot \frac{1}{n-1} - \frac{1}{n^2} = \frac{1}{n^2(n-1)} \end{aligned}$$

Επομένως, η διασπορά της τ.μ  $X$  υπολογίζεται από τον ακόλουθο τύπο :

$$\begin{aligned} \text{var}(X) &= \text{var}\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n \text{var}(X_i) + 2 \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{cov}(X_i, X_j) = \\ &= n \cdot \frac{1}{n} \cdot \left(1 - \frac{1}{n}\right) + 2 \cdot \frac{n(n-1)}{2} \cdot \frac{1}{n^2 \cdot (n-1)} = 1 \end{aligned}$$