

# Statystyka Inżynierska

dr hab. inż. Jacek Tarasiuk

AGH , WFiIS 2013

## Wykład 3

### DYSKRETNE I CIĄGŁE ROZKŁADY JEDNOWYMIAROWE, PODSTAWY ESTYMACJI

Dwuwymiarowa, dyskretna funkcja rozkładu prawdopodobieństwa, Rozkłady brzegowe i warunkowe, Kowariancja i współczynnik korelacji, Korelacja i niezależność, Prosta regresji, Regresja ortogonalna, Populacja, Próba losowa, Estymator, Estymacja

Przez zmienną losową dwuwymiarową będziemy rozumieli taką parę funkcji  $X(e)$  i  $Y(e)$  określonych na przestrzeni zdarzeń elementarnych, że dla każdej pary liczb rzeczywistych  $x, y$  można określić prawdopodobieństwo zaistnienia zdarzenia  $A$  takiego że:

$$P(A) = P(X < x, Y < y)$$

Dwuwymiarowa zmienna losowa jest **zmienną dyskretną** jeśli składowe  $X$  i  $Y$  mają skończony lub przeliczalny zbiór wartości.

### 1. Zmienna losowa dwuwymiarowa

2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

**Rozkładem prawdopodobieństwa** dwuwymiarowej dyskretnej zmiennej losowej nazywamy zbiór prawdopodobieństwa wszystkich zdarzeń  $(X=x_i, Y=y_j)$ :

$$P(X = x_i, Y = y_j) = p_{ij}$$

Gdzie  $i=1,2 \dots$  oraz  $j=1,2 \dots$

Z warunków normalizacji wynika, że:  $\sum_i \sum_j p_{ij} = 1$

Dystrybuantą takiej zmiennej losowej będzie funkcja:

$$F(x, y) = P(X < x, Y < y)$$

1. Zmienna losowa dwuwymiarowa

### 2. Rozkład i dystrybuanta

3. Rozkłady brzegowe

4. Rozkłady warunkowe

5. Charakterystyki

6. Korelacja i niezależność

7. Prosta regresji

8. Regresja ortogonalna

9. Próba losowa i populacja

10. Parametr rozkładu i estymator

11. Estymacja przedziałowa

**Rozkłady brzegowe** w przypadku dwuwymiarowej dyskretnej zmiennej losowej definiujemy jako:

$$p_{i\bullet} = \sum_k p_{ik} \qquad p_{\bullet j} = \sum_k p_{kj}$$

Rozkłady brzegowe określają prawdopodobieństwo, że jedna ze zmiennych losowych przyjmie jakąś wartość, niezależnie od tego jaką wartość przyjmuje druga zmienna losowa.

$$P(X = x_i) = p_{i\bullet} \qquad P(Y = y_j) = p_{\bullet j}$$

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
- 3. Rozkłady brzegowe**
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

**Rozkłady warunkowe** w przypadku dwuwymiarowej dyskretnej zmiennej losowej definiujemy jako:

$$P(X = x_i | Y = y_k) = \frac{p_{ik}}{p_{\bullet k}}$$

$$P(Y = y_j | X = x_k) = \frac{p_{kj}}{p_{k\bullet}}$$

Rozkłady brzegowe określają prawdopodobieństwo, że jedna ze zmiennych losowych przyjmie jakąś wartość, w sytuacji gdy druga przyjmuje konkretną wartość (podaną w warunku).

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
- 4. Rozkłady warunkowe**
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

**Momentem zwykłym** rzędu  $r+s$  dwuwymiarowej zmiennej losowej  $(X,Y)$  nazywamy wartość oczekiwaną iloczynu zmiennych losowych  $X^r Y^s$ :

$$\alpha_{rs} = E(X^r Y^s) = \sum_i \sum_j x_i^r y_j^s p_{ij}$$

Gdy  $s=0$  i  $r=1$  to  $\alpha_{10}=EX$ , czyli jest to wartość oczekiwana zmiennej  $X$ .

Gdy  $s=1$  i  $r=0$  to  $\alpha_{01}=EY$ , czyli jest to wartość oczekiwana zmiennej  $Y$ .

Punkt  $(\alpha_{10}, \alpha_{01})$  nazywamy **środkiem masy rozkładu prawdopodobieństwa** dwuwymiarowej zmiennej losowej  $(X,Y)$ .

Gdy  $E(XY)=EX \cdot EY$  **to zmienne  $X$  i  $Y$  są niezależne.**

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
- 5. Charakterystyki**
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

**Momentem centralnym** rzędu  $r+s$  dwuwymiarowej zmiennej losowej  $(X,Y)$  nazywamy wartość oczekiwaną iloczynu zmiennych losowych  $(X-EX)^r(Y-EY)^s$ :

$$\mu_{rs} = E\left(\left(X - EX\right)^r \left(Y - EY\right)^s\right)$$
$$\mu_{rs} = \sum_i \sum_j \left(x - EX\right)^r \left(y - EY\right)^s p_{ij}$$

Gdy  $s=0$  i  $r=2$  to  $\mu_{20}=D^2X$ , czyli jest to wariancja zmiennej  $X$ .

Gdy  $s=2$  i  $r=0$  to  $\mu_{02}=D^2Y$ , czyli jest to wariancja zmiennej  $Y$ .

Gdy  $s=1$  i  $r=1$  to  $\mu_{11}=\text{cov}(X,Y)$  co nazywamy kowariancją zmiennych losowych  $X,Y$ .

Pomiędzy powyższymi wielkościami istnieją bardzo użyteczne związki:

$$D^2X = E(X^2) - (EX)^2 \quad D^2Y = E(Y^2) - (EY)^2$$
$$\text{cov}(X,Y) = E(XY) - EX \cdot EY$$

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
- 5. Charakterystyki**
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

**Współczynnikiem korelacji**  $\rho$  dwuwymiarowej zmiennej losowej  $(X, Y)$  nazywamy:

$$\rho = \frac{\text{cov}(X, Y)}{\sqrt{D^2 X \cdot D^2 Y}}$$

Oczywiście  $D^2 X$  ani  $D^2 Y$  nie mogą być równe zero.

Jeżeli  $\rho=1$  to znaczy, że zmienne  $Y$  i  $X$  związane są ścisłą relacją  $Y=aX+b$ , przy czym  $a$  jest dodatnie. Podobnie, gdy  $\rho=-1$ , tylko  $a$  jest wówczas ujemne.

Im wartość  $\rho$  jest bliższa 1 lub -1 tym „częściej” zmienne losowe  $X$  i  $Y$  spełniają relację liniowej zależności.

Mówimy wówczas, że zmienne są silnie lub słabo **skorelowane**.

Wartość współczynnika  $\rho=0$  oznacza **brak korelacji**.

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
- 5. Charakterystyki**
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa



Jeżeli  $E(XY) = EX \cdot EY$  to zmienne  $X$  i  $Y$  są niezależne.

Ponieważ kowariancja:  $cov(X, Y) = E(X, Y) - EX \cdot EY$  to jeżeli zmienne są niezależne, to ich kowariancja jest równa 0, w konsekwencji współczynnik korelacji  $\rho = 0$ , czyli zmienne są nieskorelowane.

**Jeżeli zmienne losowe są niezależne to są nieskorelowane, ale jeżeli są nieskorelowane to nie muszą być niezależne!**


**Jeżeli zmienne losowe są skorelowane, to są również zależne.**

Jeżeli zmienne losowe  $X$  i  $Y$  są niezależne, to zachodzą również związki:

$$p_{ij} = p_{i \cdot} \cdot p_{\cdot j}$$

$$F(x, y) = F_X(x) \cdot F_Y(y)$$

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
- 6. Korelacja i niezależność**
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa



Prostą regresji drugiego rodzaju zmiennej losowej  $Y$  względem zmiennej losowej  $X$  nazywamy prostą o równaniu  $y=ax+b$ , której współczynniki  $a$  i  $b$  są tak dobrane, aby średnie odchylenie kwadratowe zmiennej losowej  $Y$  od zmiennej losowej  $aX+b$  było najmniejsze:

$$E[Y - (aX + b)]^2 = \min$$

Można wykazać, że współczynniki takiej prostej dadzą się wyliczyć jako:

$$a = \rho \sqrt{\frac{D^2 Y}{D^2 X}} = \rho \frac{\sigma_Y}{\sigma_X}$$

$$b = EY - a \cdot EX$$

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
- 7. Prosta regresji**
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

Dla dowolnych zmiennych  $X$  i  $Y$  istnieje zawsze przekształcenie liniowe, sprowadzające te zmienne do postaci, w której współczynnik korelacji pomiędzy zmiennymi równa się zero.

Przekształcenie to ma postać:

$$X^* = (X - EX) \cos \varphi + (Y - EY) \sin \varphi$$

$$Y^* = -(X - EX) \sin \varphi + (Y - EY) \cos \varphi$$

przy czym:

$$\operatorname{tg}(2\varphi) = \frac{\operatorname{cov}(X, Y)}{D^2 X - D^2 Y}$$

$$y - EY = \operatorname{tg} \varphi (x - EX)$$

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
- 8. Regresja ortogonalna**
9. Próba losowa i populacja
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

- ❑ Badania wyczerpujące (całkowite) i niewyczerpujące (częściowe).
- ❑ Populacja generalna i populacja próbna.
- ❑ Próba reprezentatywna:
  - ❑ losowy wybór z populacji generalnej
  - ❑ dostateczna liczność próby
- ❑ Oceny parametru populacji generalnej dokonujemy na podstawie pomiarów w populacji próbnej.

Prawdziwość oceny parametru populacji generalnej na podstawie próby jest zdarzeniem losowym.

Wartość tego prawdopodobieństwa zależy od wielkości próby

oraz

od dokładności oceny.

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
- 9. Próba losowa i populacja**
10. Parametr rozkładu i estymator
11. Estymacja przedziałowa

### Parametr

### Estymator

Wartość oczekiwana

$$EX = \sum_i x_i \cdot p_i$$

$$\bar{X} = \frac{1}{n} \sum_i X_i$$

Wariancja

$$D^2 X = \sum_i (x_i - EX)^2 \cdot p_i$$

$$S^{*2} = \frac{1}{n-1} \sum_i (X_i - \bar{X})^2$$

Prawdopodobieństwo sukcesu (wskaźnik struktury)

$$p = \frac{k}{n}$$

$$\hat{p} = \frac{k}{n}$$

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
- 10. Parametr rozkładu i estymator**
11. Estymacja przedziałowa


# Estymacja przedziałowa

Jeśli  $X$  ma rozkład  $N(\mu, \sigma)$ , to  $\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$  ma rozkład  $N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$

Po znormalizowaniu, zmienna  $U = \frac{\bar{X} - \mu}{\sigma} \cdot \sqrt{n}$  będzie podlegać rozkładowi  $N(0,1)$ .

Możemy znaleźć nieskończenie wiele przedziałów, w których zmienna ta znajdzie się z prawdopodobieństwem  $1-\alpha$ :

$$P(u_1 < U < u_2) = 1 - \alpha = \Phi(u_2) - \Phi(u_1)$$



$$\alpha_1 + \alpha_2 = \alpha \quad u_1 = u(\alpha_1) \quad u_2 = u(1 - \alpha_2)$$

$$P\left(u(\alpha_1) < \frac{\bar{X} - \mu}{\sigma} \cdot \sqrt{n} < u(1 - \alpha_2)\right) = 1 - \alpha$$

$$P\left(\bar{X} - u(1 - \alpha_2) \cdot \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} - u(\alpha_1) \cdot \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator

## 11. Estymacja przedziałowa

Tylko jeden z tych przedziałów będzie symetryczny. Taki dla którego:  $\alpha_1 = \alpha_2 = \frac{\alpha}{2}$ , a wówczas możemy powiedzieć, że przedział:

$$\left( \bar{X} - u \left( 1 - \frac{\alpha}{2} \right) \cdot \frac{\sigma}{\sqrt{n}}, \bar{X} + u \left( 1 - \frac{\alpha}{2} \right) \cdot \frac{\sigma}{\sqrt{n}} \right)$$

z prawdopodobieństwem  $1 - \alpha$  pokrywa prawdziwą wartość oczekiwaną  $\mu$  dla badanego rozkładu.

Jeśli nie znamy wariancji  $\sigma^2$  to musimy ją estymować:

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

i wówczas przedział wygląda następująco:

$$\left( \bar{X} - u \left( 1 - \frac{\alpha}{2} \right) \cdot \frac{S^*}{\sqrt{n}}, \bar{X} + u \left( 1 - \frac{\alpha}{2} \right) \cdot \frac{S^*}{\sqrt{n}} \right)$$

**Oba powyższe przedziały to tzw. przedziały ufności dla wartości oczekiwanej rozkładu na poziomie ufności  $1 - \alpha$ .**

1. Zmienna losowa dwuwymiarowa
2. Rozkład i dystrybuanta
3. Rozkłady brzegowe
4. Rozkłady warunkowe
5. Charakterystyki
6. Korelacja i niezależność
7. Prosta regresji
8. Regresja ortogonalna
9. Próba losowa i populacja
10. Parametr rozkładu i estymator

### **11. Estymacja przedziałowa**