


# FAKTORSKA ANALIZA

Vježba 12



**Faktorska analiza** je zajedničko ime za više metoda kojima je cilj kondenzacija većeg broja **manifestnih varijabli**, među kojima postoji povezanost (korelacija), na manji broj **latentnih dimenzija (faktora)** koje su izvor te povezanosti.

**Manifestne varijable** su varijable, odnosno obilježja koja se mogu izravno mjeriti postojećim mjernim instrumentima (npr. skok udalj s mjesta, bacanje medicinke iz ležanja na leđima, bacanje kugle).


**Latentne dimenzije** su varijable, odnosno obilježja koja nisu izravno mjerljiva postojećim mjernim instrumentima, već se izračunavaju kao linearna kombinacija manifestnih varijabli (npr. eksplozivna snaga).

## Komponentni model faktorske analize

**Komponentni model** ili **metoda glavnih komponenata** je metoda ekstrakcije, odnosno izračunavanja latentnih dimenzija koju je 1933. godine predložio američki ekonomist i statističar **Harold Hotelling**.

Metodom glavnih komponenata se iz skupa od  $m$  manifestnih varijabli na temelju nereducirane korelacijske matrice izračuna  $m$  latentnih dimenzija koje su međusobno linearno nezavisne, a nazivaju se **glavne komponente**.

**Glavne komponente** su linearne kombinacije manifestnih varijabli izračunate na način da prva glavna komponenta objašnjava maksimalan moguć dio ukupne varijance manifestnih varijabli te da druga, kao i svaka sljedeća glavna komponenta, objašnjava najveći dio preostale varijance manifestnih varijabli, odnosno najveći dio varijance manifestnih varijabli koji nije objašnjen prethodnim glavnim komponentama.



Harold Hotelling  
(1895. – 1973.)

## Komponentni model faktorske analize

Glavne komponente izračunavaju se na sljedeći način:

Neka su u matrici  $B$  podaci skupa  $E = \{e_i; i = 1, \dots, n\}$  entiteta koji su opisani skupom  $V = \{v_j; j = 1, \dots, m\}$  manifestnih varijabli. Operacijom

$$\mathbf{Z} = \mathbf{B}_c \mathbf{V}^{-1}$$

gdje je

- $\mathbf{B}_c$  - matrica centriranih podataka dobivenih operacijom  $\mathbf{B}_c = \mathbf{B}^{-1} \mathbf{m}^T$
  - $\mathbf{m}$  - vektor aritmetičkih sredina varijabli matrice  $\mathbf{B}$
  - $\mathbf{V}^{-1}$  - dijagonalna matrica standardnih devijacija varijabli iz matrice  $\mathbf{B}$
- izračuna se matrica standardiziranih podataka ( $\mathbf{Z}$ ).

## Komponentni model faktorske analize

Operacijom

$$\mathbf{R} = \mathbf{Z}^T \mathbf{Z} n^{-1} = \begin{vmatrix} 1 & r_{12} & \cdot & \cdot & r_{1m} \\ r_{21} & 1 & \cdot & \cdot & r_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ r_{m1} & r_{m2} & \cdot & \cdot & 1 \end{vmatrix}$$

izračuna se matrica korelacija manifestnih varijabli ( $\mathbf{R}$ ) u čijoj su glavnoj dijagonali jedinice, odnosno varijance standardiziranih varijabli. Zbroj varijanci svih standardiziranih varijabli, odnosno ukupna varijanca skupa standardiziranih varijabli jednaka je  $m$ , odnosno broju manifestnih varijabli.

## Komponentni model faktorske analize

Operacijom spektralne dekompozicije matrice korelacija

$$\begin{matrix}
 \mathbf{R} & = & \mathbf{X} & \boldsymbol{\lambda} & \mathbf{X}^T \\
 \left| \begin{array}{ccccc} 1 & r_{12} & \cdot & \cdot & r_{1m} \\ r_{21} & 1 & \cdot & \cdot & r_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ r_{m1} & r_{m2} & \cdot & \cdot & 1 \end{array} \right| & = & \left| \begin{array}{ccccc} x_{11} & x_{12} & \cdot & \cdot & x_{1m} \\ x_{21} & x_{22} & \cdot & \cdot & x_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{m1} & x_{m2} & \cdot & \cdot & x_{mm} \end{array} \right| \cdot \left| \begin{array}{c} \lambda_1 \\ \lambda_2 \\ \cdot \\ \cdot \\ \lambda_m \end{array} \right| \cdot \left| \begin{array}{ccccc} x_{11} & x_{21} & \cdot & \cdot & x_{m1} \\ x_{12} & x_{22} & \cdot & \cdot & x_{m2} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{1m} & x_{2m} & \cdot & \cdot & x_{mm} \end{array} \right|
 \end{matrix}$$

izračunaju se **matrica svojstvenih vektora** ( $\mathbf{X}$ ) i **matrica svojstvenih vrijednosti** ( $\boldsymbol{\lambda}$ ).

## Komponentni model faktorske analize

**Matrica svojstvenih vektora ( $\mathbf{X}$ )** je kvadratna matrica reda  $m \times m$  za koju vrijedi da je  $\mathbf{X}^T \mathbf{X} = \mathbf{X} \mathbf{X}^T = \mathbf{I}$  tj. da su vektori matrice linearno nezavisni, a u čijim su stupcima ponderi za izračunavanje glavnih komponenata iz standardiziranih varijabli.

**Matrica svojstvenih vrijednosti ( $\boldsymbol{\lambda}$ )** je dijagonalna matrica reda  $m \times m$  za koju vrijedi da je  $\lambda_1 + \lambda_2 + \dots + \lambda_m = m$ , tj. da je zbroj svojstvenih vrijednosti jednak ukupnoj varijanci standardiziranih varijabli, te da je  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ , tj. da se svojstvene vrijednosti nižu od najveće prema najmanjoj.

## Komponentni model faktorske analize

Operacijom

$$\mathbf{K} = \mathbf{Z} \mathbf{X}$$
$$\begin{vmatrix} k_{11} & k_{12} & \cdot & \cdot & k_{1m} \\ k_{21} & k_{22} & \cdot & \cdot & k_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ k_{n1} & k_{n2} & \cdot & \cdot & k_{nm} \end{vmatrix} = \begin{vmatrix} z_{11} & z_{12} & \cdot & \cdot & z_{1m} \\ z_{21} & z_{22} & \cdot & \cdot & z_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ z_{n1} & z_{n2} & \cdot & \cdot & z_{nm} \end{vmatrix} \cdot \begin{vmatrix} x_{11} & x_{12} & \cdot & \cdot & x_{1m} \\ x_{21} & x_{22} & \cdot & \cdot & x_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{m1} & x_{m2} & \cdot & \cdot & x_{mm} \end{vmatrix}$$

izračuna se **matrica glavnih komponenata (K)**.



## Komponentni model faktorske analize

**Matrica glavnih komponenata (K)** je matrica reda  $n \times m$  koju čine rezultati  $n$  ispitanika u  $m$  linearno nezavisnih (ortogonalnih) glavnih komponenata. Varijanca prve glavne komponente jednaka je  $\lambda_1$ , varijanca druge glavne komponente  $\lambda_2$ , itd.

Pošto vrijedi da je  $\lambda_1 + \lambda_2 + \dots + \lambda_m = m$  te da je  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ , može se zaključiti da je ukupna varijanca  $m$  standardiziranih varijabli raspodijeljena tako da prva glavna komponenta objašnjava najveći dio ukupne varijance, druga glavna komponenta najveći dio preostale varijance, itd.

## Komponentni model faktorske analize

Operacijom


$$\mathbf{H} = \mathbf{X} \boldsymbol{\lambda}^{1/2}$$

$$\begin{vmatrix} h_{11} & h_{12} & \cdot & \cdot & h_{1m} \\ h_{21} & h_{22} & \cdot & \cdot & h_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ h_{m1} & h_{m2} & \cdot & \cdot & h_{mm} \end{vmatrix} = \begin{vmatrix} x_{11} & x_{12} & \cdot & \cdot & x_{1m} \\ x_{21} & x_{22} & \cdot & \cdot & x_{2m} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ x_{m1} & x_{m2} & \cdot & \cdot & x_{mm} \end{vmatrix} \cdot \begin{vmatrix} \sqrt{\lambda_1} & & & & \\ & \sqrt{\lambda_2} & & & \\ & & \cdot & & \\ & & & \cdot & \\ & & & & \sqrt{\lambda_m} \end{vmatrix}$$

izračuna se **matrica glavnih osovina** (H). Matrica glavnih osovina je matrica korelacija manifestnih varijabli i glavnih komponenata. Elementi ove matrice ukazuju koliki je doprinos svake pojedine manifestne varijable pri formiranju svake pojedine glavne komponente.


## Komponentni model faktorske analize

Neka je skup od  $n$  entiteta opisan sa 6 manifestnih varijabli ( $v_1, \dots, v_6$ ). Na temelju korelacijske matrice može se utvrditi odnos odgovarajućih standardiziranih vektora u  $n$ -dimenzionalnom prostoru.



## Komponentni model faktorske analize

Na temelju matrice glavnih osovina može se utvrditi prostorni odnos standardiziranih manifestnih vektora i standardiziranih glavnih komponenata.



## Kriteriji za odabir značajnih glavnih komponenata

Pošto je osnovni cilj faktorske analize kondenzacija većeg broja manifestnih varijabli na manji broj latentnih dimenzija, potrebno je izvršiti **redukciju broja glavnih komponenata**.

Redukcija broja glavnih komponenata odnosno određivanje broja značajnih glavnih komponenata vrši se putem različitih kriterija kao što su **GK-kriterij**, **PB-kriterij** i **Scree-test**.


Prema **GK-kriteriju** glavna komponenta  $j$  je značajna ako je njena varijanca ( $\lambda_j$ ) veća ili jednaka 1.

Prema **PB-kriteriju** broj značajnih glavnih komponenata jednak je broju svojstvenih vrijednosti poredanih po veličini čiji zbroj ne prelazi  $\sum s_{mc}$  (sumu kvadrata multiplih korelacija).

**Scree-test** je grafički kriterij. Na **scree plotu** se subjektivnom procjenom odredi točka nakon koje se svojstvene vrijednosti smanjuju u skladu s blagim linearnim trendom. Značajnima se smatraju sve prethodne glavne komponente.

## Kriteriji za odabir značajnih glavnih komponenata

### Scree plot



GK - kriterij

## Kriteriji za odabir značajnih glavnih komponenata

### Komunaliteti i unikviteti

$$\mathbf{H} = \begin{array}{c} \begin{array}{c} \text{značajne glavne} \\ \text{komponente} \end{array} \qquad \begin{array}{c} \text{glavne komponente} \\ \text{koje nisu značajne} \end{array} \\ \left[ \begin{array}{cccc|cccc} h_{11} & \cdot & \cdot & h_{1k} & \cdot & \cdot & \cdot & h_{1m} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ h_{m1} & \cdot & \cdot & h_{mk} & \cdot & \cdot & \cdot & h_{mm} \end{array} \right] \end{array}$$

(Matrica  $\mathbf{H}$  prije i nakon redukcije broja glavnih komponenata)

## Kriteriji za odabir značajnih glavnih komponenata

### Komunaliteti i unikviteti

Varijancu svake manifestne varijable moguće je dekomponirati na **komunalitet** ( $h^2$ ) i **unikvitet** ( $u^2$ ) pri čemu je

$$s_j^2 = 1 = h_j^2 + u_j^2$$

**Komunalitet** je dio varijance manifestne varijable  $j$  koji je moguće objasniti s  $k$  značajnih glavnih komponenata.

$$h_j^2 = \sum_{p=1}^k h_{jp}^2 = h_{j1}^2 + h_{j2}^2 + \dots + h_{jk}^2$$

**Unikvitet** je dio varijance manifestne varijable  $j$  koji nije moguće objasniti s  $k$  značajnih glavnih komponenata

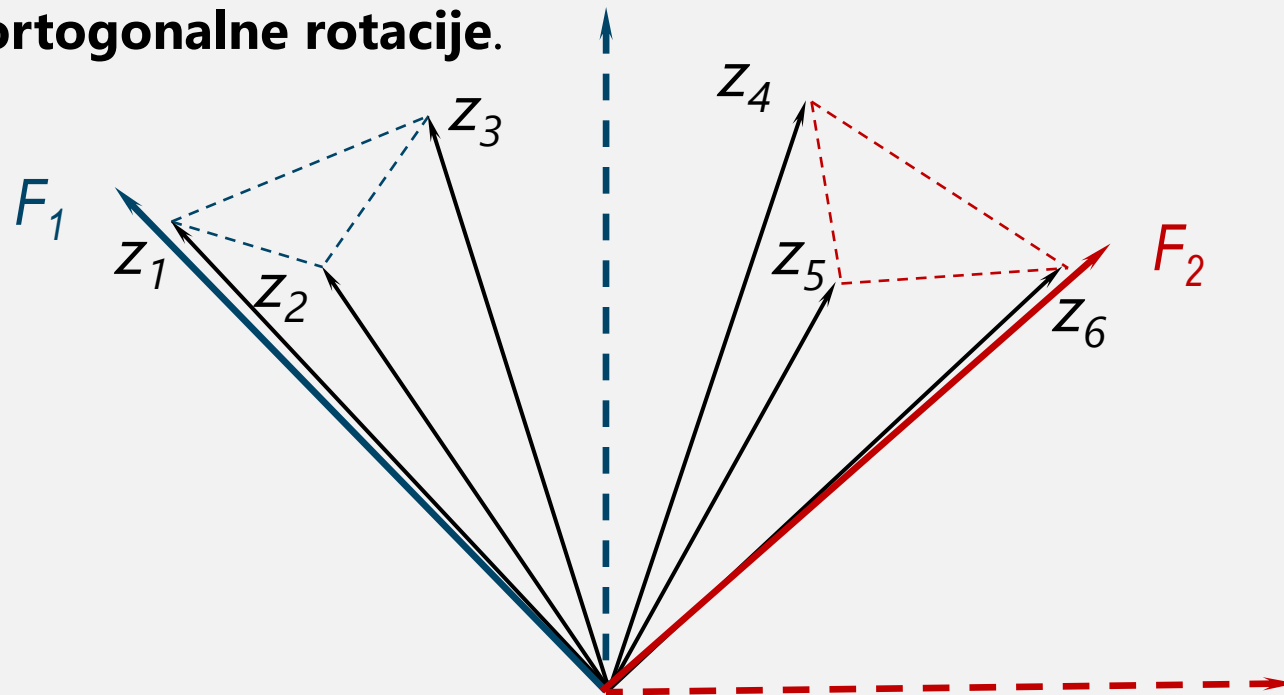
$$u_j^2 = 1 - h_j^2$$



## Rotacije

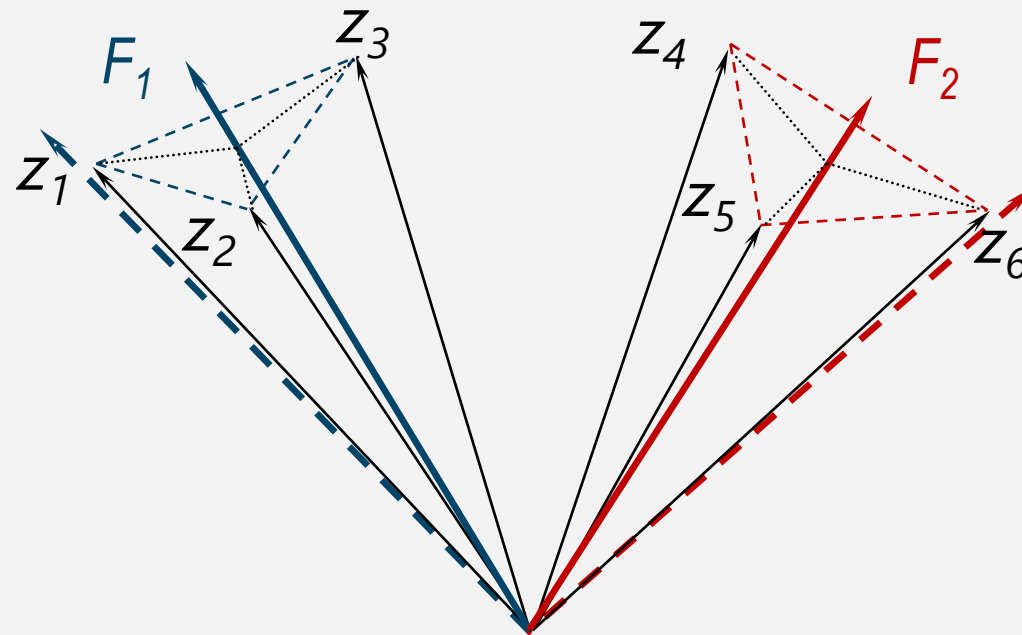
Pravi uvid u strukturu međusobnih odnosa manifestnih varijabli često nije moguće steći putem glavnih komponenata. U takvim se slučajevima koriste transformacije glavnih komponenata čija je svrha postizanje jednostavne faktorske strukture, a koje se nazivaju **rotacije**.

Transformacije glavnih komponenata koje se provode uz uvjet zadržavanja njihove linearne nezavisnosti nazivaju se **ortogonalne rotacije**.



## Rotacije

Transformacije glavnih komponentata koje se provode bez uvjeta zadržavanja njihove linearne nezavisnosti nazivaju se **neortogonalne** ili **kosokutne rotacije**.





## Rotacije

Interpretacija faktora nakon rotacije vrši se putem **matrice strukture (F)**, **matrice sklopa (A)**, i **matrice korelacija među faktorima (M)**.


**Matricu strukture** čine korelacije manifestnih varijabli s faktorima, a **matricu sklopa** čine paralelne projekcije manifestnih varijabli na faktore.

Matrica sklopa često jasnije pokazuje koje varijable određuju pojedine faktore nego matrica strukture.



## Rotacije

Paralelne projekcije i ortogonalne projekcije manifestnih varijabli na faktore bit će sličnije što su korelacije među faktorima manje. Matrica strukture bit će jednaka matrici sklopa ako su faktori potpuno nezavisni.






**Zadatak:** Na varijablama matrice *JUDO3F.csv* provedite komponentni model faktorske analize uz *GK-kriterij* redukcije i neortogonalnu *oblimin* rotaciju! Izračunajte matricu faktorske strukture i matricu rezultata entiteta na faktorima!

Eigenvalue

Copy

	Eigenvalue	Cum.Eign	Percentage	Cum.Per
1	3.991	3.991	44.345	44.345
2	1.732	5.723	19.245	63.590
3	1.151	6.874	12.784	76.374
4	0.807	7.680	8.963	85.337
5	0.481	8.161	5.339	90.677
6	0.342	8.503	3.797	94.473
7	0.250	8.753	2.779	97.252
8	0.132	8.884	1.464	98.716
9	0.116	9.000	1.284	100.000

Sum SMC = 5.602



Graph Factor Loadings (Factors)

