

Matematičke metode u marketingu. Eksploratorna faktorska analiza (EFA¹)

Lavoslav Čaklović
PMF-MO

2016

¹Exploratory Factor Analysis

TEORIJSKA RAZRADA MODELA

Faktorska analiza donosi zaključke o latentnim (skrivenim, neuočljivim) varijablama kao što su: inteligencija, muzikalnost, navike potrošača. . . koje se ne mogu direktno mjeriti. One se mjere putem njihovih manifestacija u odabranom kontekstu.

subjekti				manifestacije
↓	X_1	...	X_p	← mjerljivo
s_1	x_{11}	...	x_{1p}	
s_2	x_{21}	...	x_{2p}	
⋮	⋮	...	⋮	
s_m	x_{m1}	...	x_{mp}	

FA opisuje korelaciju među manifestinim varijablama X_1, \dots, X_p u terminima manjeg broja latentnih **faktora** koji su uzrok varijabilnosti u podacima..

Primjer

Marketinška firma želi ustanoviti što utječe na vjernost kupaca 'svojim' dućanima. U tu svrhi kupci su ispunjavali anketu (80 pitanja). Menadžeri pretpostavljaju da ta vjernost počiva na nekoliko faktora: ljubaznosti osoblja, kvaliteti usluga, atmosferi u dućanu, širini ponude, kvaliteti proizvoda i njihovoj cijeni.

Faktorska analiza daje odgovor je li moguće svih 80 atributa svrstati u 6 grupa koje će biti prepoznate kao gore navedeni faktori.

ORTOGONALNI MODEL

$$X_1 - \mu_1 = \lambda_{11}F_1 + \lambda_{12}F_2 + \cdots + \lambda_{1m}F_m + \epsilon_1$$

$$X_2 - \mu_2 = \lambda_{21}F_1 + \lambda_{22}F_2 + \cdots + \lambda_{2m}F_m + \epsilon_2$$

\vdots

$$X_p - \mu_p = \lambda_{p1}F_1 + \lambda_{p2}F_2 + \cdots + \lambda_{pm}F_m + \epsilon_p$$

λ_{ij} – **factor loading** i -tog atributa
na j -tom faktoru

ϵ_i – nerastavljivi faktor (unique, specific)

ili u matricnom obliku

$$\mathbb{R}^r \ni (X - \mu) = \Lambda \cdot F + \epsilon. \quad (1)$$

\uparrow

matrica punjenja (loadings matrix)

Pretpostavke ortogonalnog modela:

- $E(F) = 0, \quad \text{Var}(F) = E(FF^T) = I$ (2)



Reskaliranjem faktora se može svesti na taj slučaj tako da to nije ograničenje

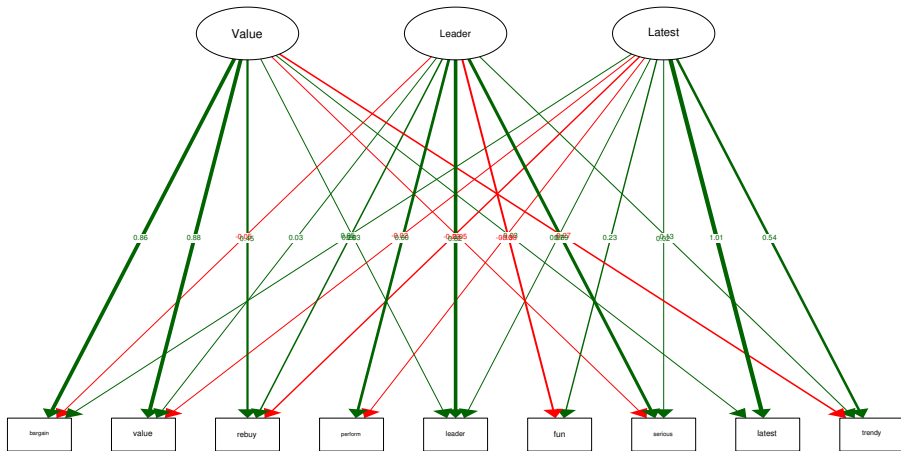
- $E(\epsilon) = 0, \quad \text{Var}(\epsilon) = E(\epsilon\epsilon^T) = \Psi = \text{diag}(\psi_1, \dots, \psi_p)$ (3)

- F i ϵ su nekorelirane, tj. $\text{Cov}(F, \epsilon) = 0$ (4)

- Varijable ϵ_i nisu korelirane. (5)

Napomena. Nekoreliranost (ortogonalnost) faktora je zahtjev nepostojanja sinergije među njima (teško uhvatljiv pojam).

Dijagram



Posljedice:

$$\begin{aligned}\text{Cov}(X, F) &= E((X - \mu)F^T) = E(\Lambda FF^T + \epsilon F^T) \\ &= \Lambda E(FF^T) + E(\epsilon F^T) = \Lambda\end{aligned}\quad (6)$$

odnosno⁸

$$\begin{aligned}\Sigma &:= E((X - \mu)(X - \mu)^T) \\ &= \Lambda E(FF^T)\Lambda^T + E(\epsilon F^T)\Lambda^T + \Lambda E(F\epsilon^T) + E(\epsilon\epsilon^T) \\ &= \Lambda\Lambda^T + \Psi.\end{aligned}\quad (7)$$

Specijalno, zbog dijagonalnosti Ψ ,

$$\sigma_i^2 := \text{Var}(X_i) = \underbrace{\lambda_{i1}^2 + \lambda_{i2}^2 + \dots + \lambda_{im}^2}_{\substack{\text{faktorsko objašnjenje varijance} \\ \text{communalities (oznaka: } h_i^2) \\ \text{što veće}}} + \underbrace{\psi_i}_{\substack{\text{specifična varijanca} \\ \text{uniqueness (oznaka: } u_i^2) \\ \text{što manja}}$$

⁸Minimal residual FA.

Upute za korištenje

- broj faktora mali u odnosu na broj varijabli
- $\frac{p(p+1)}{2}$ varijanci i kovarijanci iz Σ su reproducirani preko $pm + p$ faktora. Jedinstvenost faktora je upitna.
- nije istina da je jednačba $\Sigma = \Lambda\Lambda^T + \Psi$ rješiva za svako Σ .
Napr. za $m = 1$ (jednofaktorski model) i

$$\Sigma = \begin{bmatrix} 1 & 0.9 & 0.7 \\ 0.9 & 1 & 0.4 \\ 0.7 & 0.4 & 1 \end{bmatrix}$$

to nije moguće (zadatak).

- Poželjno je da koreliranost varijabli bude bar 0.3. U suprotnom, broj faktora neće biti puno manji od broja varijabli.
- KMO index > 0.8 , Kaiser-Meyer-Olkin statistic.

NEJEDINSTVENOST. ROTACIJE.

Teorem

Pretp: $m > 1$ i F rješenje faktorskog modela (1). Tada je $T^T F$ rješenje faktorskog modela za svaku ortogonalnu matricu T .

Dokaz.

$$\begin{aligned} X - \mu &= \Lambda F + \epsilon \\ &= \Lambda(TT^T)F + \epsilon \\ &= \underbrace{(\Lambda T)}_{\Lambda^*} \underbrace{(T^T F)}_{F^*} + \epsilon \end{aligned}$$

i vrijedi

$$\begin{aligned} E(F^*) &= E(T^T F) = T^T E(F) = 0 \\ \text{Var}(F^*) &= \text{Var}(T^T F) = T^T \text{Var}(F) T = T^T T = I \end{aligned}$$

FAKTORSKA ANALIZA U R-U

Rješava se jednačba (po Λ)

$$\Sigma = \Lambda\Lambda^T + \Psi.$$

- `factanal()` u R-ovom paketu `stat`¹².
- `fa()` u `psych` paketu. Ima 5 alternativa: `fm="minres"`, `fm="pa"`, `fm="wls"`, `fm="gls"` and `fm="ml"` (`fm`=factor method)

```
library(GPARotation)
factanal(data, rotation="varimax")
```

Rotacija nalazi novu bazu (faktore) koji se mogu bolje interpretirati. `varimax`, `quartimax` i `equimax` — ortogonalne, `promax` i `oblmin` — neortogonalne transformacije (faktori su korelirani).

¹²pomoću *maksimalne vjerodostojnosti (normalnost varijabli)*

Literatura

- Mulaik, S. A. (2009). Foundations of factor analysis (2nd ed.). Statistics in the Social and Behavioral Sciences. Boca Raton: Chapman & Hall/CRC.
- <https://cran.r-project.org/web/packages/psych/vignettes/overview.pdf>
- <http://www.di.fc.ul.pt/~jpn/r/factoranalysis/factoranalysis.html>
- <https://stat.ethz.ch/maathuis/teaching/spring14/Rscript-factor-analysis.R>