



Faktor- és főkomponens analízis

Informatikai Tudományok Doktori Iskola



Adatredukció

Olyan statisztikai módszerek tartoznak ide, melyek lehetővé teszik, hogy az adatmátrix méretét csökkentve kisebb költséggel értékelhessük ki a statisztikai sokaságot. A redukált adatmennyiségből levont statisztikai következtetések érvényesek maradnak az eredeti statisztikai sokaságra is. A csökkentés vonatkozhat az esetszám csökkentésére és a változók számának a csökkentésére egyaránt.

- Klaszteranalízis
- Ritkítás véletlenszám generálással
- Faktoralízis
- Főkomponens-analízis
- Többdimenziós skálázás (MDS)

2012. 03. 13.

Dr Ketskeméty László előadása

2



A faktoranalízis problematikája

Nagyszámú, sztochasztikusan erősen összefüggő változónk van. A változók redundáns információt hordoznak. Ismeretlen, kisszámú faktorváltozót keresünk.

- Hogyan lehet a változók által közösen magyarázott információt korrelálatlan faktorokkal kifejezni?
- A faktorok milyen mértékben magyarázzák az eredeti változókat?
- Mely változók vannak ugyanazokkal a faktorokkal kifejezve?
- Hogyan lehet ezek alapján a változóinkat csoportosítani?
- Mi lehet az egyes faktorok jelentése?

2012. 03. 13.

Dr Ketskeméty László előadása

3



A faktoranalízis problematikája

- A változók számának csökkentése, de úgy, hogy ezáltal a megfigyelésekben rejlő információ ne csökkenjen lényegesen; lényegkiemelés.
- Nehezen megadható fogalmak (pl. gazdasági fejlettség) definiálása összetett mutatórendszerrel való jellemzés útján.
- Osztályozási (csoportosítási) feladatok: a csoportképző ismérvek kijelölt változók nem függetlenek és nem azonos szórásúak, ezért nem lehet azonos súllyal venni figyelembe őket – a változókat kialakító közös faktorok alapján csoportosítunk.



A módszerek jellemzői

- Számolásigényesek, számítógépes programcsomagok segítségével hajthatók végre.
- Többdimenziós normális eloszlású megfigyelések esetén optimumtulajdonságokkal rendelkeznek, de bármely más, véges szórású mintaeloszlás esetén is igaz, hogy természetesen definiált célfüggvényeket optimalizálnak.
- A klasszikus módszerek nem robusztusak, érzékenyek a kiugró és extrém értékekre, de léteznek nemparaméteres, robusztusabb változatok is, amelyek rangstatistikákkal dolgoznak.



A módszerek jellemzői

A módszert olyan esetekben lehet alkalmazni, amikor a sokaságot nagyszámú változóval jellemezzük, és feltételezhetően a változóink egymást átfedő (koherens) információt hordoznak. Az elemzés egyik célja éppen az, hogy a közös információt egymástól korrelálatlan faktorokkal jellemezzük.

A faktoranalízis módszere alapvetően abban különbözik a regresszió módszerétől, hogy a prediktor változók a vizsgálat megkezdődésekor nem ismertek, azok előállítására és értelmezésére a feladat.

Csak akkor van esély jó faktorelemzésre, ha a vizsgálatba bevont változók között erős összefüggés van.

A VÁLTOZÓK KÖZÖTTI ÖSSZEFÜGGÉS EREJÉNEK MÉRÉSE

$$KMO = \frac{\sum_{i=1}^p \sum_{j=1, j \neq i}^p R_{ij}^2}{\sum_{i=1}^p \sum_{j=1, j \neq i}^p R_{ij}^2 + \sum_{i=1}^p \sum_{j=1, j \neq i}^p R_{ij}^2}$$

$$\rho_{ij} = \frac{R_{ij}}{\sqrt{R_{ii} \cdot R_{jj}}}$$

parciális korrelációs együttható

$$r_{ij} = R(X_i, X_j)$$

Kaiser-Meyer-Olkin mérték

korrelációs együttható

$0.9 \leq KMO$
 $0.8 \leq KMO < 0.9$
 $0.7 \leq KMO < 0.8$
 $0.6 \leq KMO < 0.7$
 $0.5 \leq KMO < 0.6$
 $KMO < 0.5$

csodálatos (marvelous)
 dicséretes (meritorious)
 közepes middling)
 mérsékelt (mediocre)
 szánalmas (miserable)
 elfogadhatatlan (unacceptable)


2012. 03. 13.

Dr Ketskeméty László előadása

7

Parciális korrelációs együttható

Vesszük x és z -re merőleges komponenseit (r_x -et és r_y -t), és ezek totális korrelációját vesszük. x és y parciális korrelációs együtthatója annak a lineáris kapcsolatnak az erősséget fejezi ki, ami nem magyarázható z -vel.




2012. 03. 13.

Dr Ketskeméty László előadása

8

Többszörös korrelációs együttható

A többszörös korrelációs együttható z korrelációs együtthatója az x, y -ra vett lineáris regressziójával. Ez a többszörös korrelációs együttható a maximális korreláció, amely a z változó és a többi változó tetszőleges lineáris kombinációja között előfordul.



2012. 03. 13.

Dr Ketskeméty László előadása

9

A VÁLTOZÓK KÖZÖTTI ÖSSZEFÜGGÉS EREJÉNEK MÉRÉSE

$$MSA_i = \frac{\sum_{j \neq i} r_{ij}^2}{\sum_{j \neq i} p_{ij}^2 + \sum_{j \neq i} r_{ij}^2} \quad (i = 1, 2, \dots, p)$$

measure of sampling adequacy

Az indulási p db változóból azokat érdemes elhagyni, amelyeknél az MSA_i érték a legkisebb.

Elvégezhető még a Bartlett-féle gömb próba. Itt az a nullhipotézis, hogy a vizsgált változók függetlenek egymástól. Akkor érdemes továbbmenni, ha ez a próba nem szignifikáns!

2012. 03. 13.

Dr Ketskeméty László előadása

10

Bartlett-féle gömb próba

- Azt a nullhipotézist teszteli, hogy a változóink korrelációs mátrixa egységmátrix-e. Ebben az esetben a változók páronként korrelálatlanok lennének, vagyis a változók nem hordoznának redundáns információt.

- A nullhipotézist akkor vetjük el, ha a próbastatisztika számított értéke nagy, azaz a próba szignifikancia-szintje nullához közeli érték.

- Amennyiben a próba szignifikáns, nincs értelme belefogni a faktorelemzésbe.

2012. 03. 13.

Dr Ketskeméty László előadása

11

A k -FAKTOROS MODELL

Adottak az X_1, X_2, \dots, X_p változók, a belőlük alkotott p -dimenziós vektor \underline{X} .

$$\underline{X} = \underline{A} \cdot \underline{F} + \underline{U} + \underline{m}$$

\underline{A} pk -as átviteli mátrix

\underline{F} k -dimenziós közös faktor-vektor

\underline{U} p -dimenziós egyedi faktor-vektor

$E\underline{X} = \underline{m}$ várható érték vektor

2012. 03. 13.

Dr Ketskeméty László előadása

12



A k-FAKTOROS MODELL FELTÉTELEI

F_1, F_2, \dots, F_k páronként korrelálatlanok $R(F_i, F_j) = 0$

$E(F_i) = 0, D^2(F_i) = 1$

U_1, U_2, \dots, U_p páronként korrelálatlanok $R(U_i, U_j) = 0$

$E(U_i) = 0, D^2(U_i) = \Psi_{ii}$

F_1, F_2, \dots, F_k és U_1, U_2, \dots, U_p páronként korrelálatlanok:

$$R(U_i, U_j) = 0$$

2012. 03. 13.


Dr Ketskeméty László előadása

13



Adat mátrix \rightarrow átviteli mátrix

- A faktoranalízist teljesen behatárolja a változók korrelációs mátrixának felépítése.
- A faktoranalízis ténylegesen a korrelációs struktúrát tárja fel, írja le.



2012. 03. 13.

Dr Ketskeméty László előadása

14



Identifikáció

Egy k-faktoros modell pontosan akkor oldható meg, ha

$$\underline{\Sigma} = \underline{A} \cdot \underline{A}^T + \underline{\Psi}$$

$\underline{\Sigma} = \text{cov}(X_i, X_j)$ \underline{X} kovarianciamátrixa

$\underline{\Psi}$ \underline{U}

Van $p(p+1)/2$ egyenlet, és p
 $(p+1)/2 > k+1$ esetben az egy
 $(p+1)/2 < k+1$ esetben az

Aluldefiniált esetben különböző módon adhatunk meg kényszerfeltételeket, amelyek más-más eredményhez (átviteli mátrixhoz) vezethetnek! Ezek közül a legjobban magyarázható megoldást fogjuk választani.

- Maximum líkelyhob. fogjuk választani.
- Főkomponens-analízis
- A legkisebb négyzetek módszere
-

2012. 03. 13.

Dr Ketskeméty László előadása

15

A k-FAKTOROS MODELL KOORDINÁNTÁNKÉNT

$$X_i = \sum_{j=1}^k a_{ij} F_j + U_i + m_i$$

F koordinátái mindegyik X_i előállításában szerepelnek

U koordinátái közül csak U_i szerepel X_i előállításában

$$D^2 X_i = \sum_{j=1}^k a_{ij}^2 + \Psi_{ii}$$

Az X_i variáciája

A kummuláns

Az egyedi variancia

$$\frac{\sum_{j=1}^k a_{ij}^2}{D^2 X_i}$$

Ez az arány azt fejezi ki, hány %-ot magyaráznak a közös faktorok.

2012. 03. 13.

Dr Ketskeméty László előadása

16

A k-FAKTOROS MODELL KOORDINÁNTÁNKÉNT

Az átviteli mátrix együtthatóinak jelentése:

$$\text{cov}(X_i, F_j) = a_{ij}$$

$$R(X_i, F_j) = \frac{a_{ij}}{DX_i}$$

A kommunalitás a változók variációjának az a része, amit a közös faktorok magyaráznak:

$$D^2 X_i = \sum_{j=1}^k a_{ij}^2 + D^2 U_i$$

2012. 03. 13.

Dr Ketskeméty László előadása

17

A FAKTOROK FORGATÁSA (ROTÁCIÓ)

Az átviteli mátrixnak Lawley módszerével történő egyértelművé tétele a becslési eljárások matematikai elemzését segíti, de az az ára, hogy a kapott közös faktorok gyakran csak nehezen értelmezhetők. Alkalmos elforgatással esetleg szemléletesebb jelentést adhatunk a faktoroknak. Ha például a faktorsúlyok között csak 0-hoz közeli vagy aránylag nagy értékek fordulnak elő, akkor a változók csoportosíthatók annak alapján hogy melyik faktor mely változóban játszik fontos szerepet, szerencsés esetben a változók halmaza akár diszjunkt osztályokra is bontható.

2012. 03. 13.

Dr Ketskeméty László előadása

18



A FAKTOROK FORGATÁSA (ROTÁCIÓ)

$$\underline{\Sigma} = \underline{A} \cdot \underline{A}^T + \underline{\Psi} = \underline{A} \underline{E} \underline{A}^T + \underline{\Psi} = \underline{A} \underline{G} \underline{G}^T \underline{A}^T + \underline{\Psi} = \underline{A}^* \cdot \underline{A}^{*T} + \underline{\Psi}$$

$$\underline{A}^* = \underline{A} \underline{G}$$
 Az új átviteli mátrix

$$\underline{F}^* = \underline{G} \underline{F}$$
 Az új faktorvektor

G ügyes megválasztásával a modell jobban magyarázható lesz!

- Varimax: azon változók száma kevés lesz, melyekhez sok faktor szerenel nagy súllyal
- Quartimax: a magyarázó faktorok számát minimalizálja
- Equamax: a két eljárás keverékét végzi

2012. 03. 13.


Dr Ketskeméty László előadása

19



A FAKTOROK FORGATÁSA (ROTÁCIÓ)

A rotáció szemléltetése egy egyszerű kétdimenziós példán:



Az eredeti változók **a** és **b** csoportja a rotáció nélkül kapott mindkét faktoron jelentős faktorsúllyal rendelkezik.

2012. 03. 13.


Dr Ketskeméty László előadása

20



A FAKTOROK FORGATÁSA (ROTÁCIÓ)

A rotáció szemléltetése egy egyszerű kétdimenziós példán:



Az eredeti változók **a** csoportja csak a rotációval kapott egyik, a **b** csoport pedig csak a másik faktoron rendelkezik jelentős faktorsúllyal.

2012. 03. 13.

Dr Ketskeméty László előadása

21



Varimax-rotáció

Célja, hogy minél több 0-hoz közeli faktorsúlyt állítson elő

$$\sum_{j=1}^k \sum_{i=1}^n (b_{ij} - \bar{b}_j)^2 = \sum_{j=1}^k \sum_{i=1}^n b_{ij}^2 - n \sum_{j=1}^k \bar{b}_j^2 \longrightarrow \max$$

ahol

$$b_{ij} = \frac{a_{ij}^2}{h_i^2}, \quad \bar{b}_j = \frac{1}{n} \sum_{i=1}^n b_{ij}$$

$A = (a_{ij})$ a keresett átviteli mátrix

h_i^2 az i -edik változó kommunalitása

2012. 03. 13.

Dr Ketskeméty László előadása

22



Varimax-rotáció

Mivel a forgatások az átviteli mátrix sorainak normáit nem változtatják meg, az egész eljárás során a kommunalitások változatlanok maradnak.

A fokozatos maximalizálás úgy történik, hogy minden lépésben csak egy-egy faktorpárt forgatunk el:

ha a (j, m) párt választjuk $(1 \leq j < m \leq k)$, akkor csak az a_{ij} és a_{im} faktorsúlyok változnak:

$$a'_{ij} = a_{ij} \cos\varphi - a_{im} \sin\varphi, \quad a'_{im} = a_{ij} \sin\varphi + a_{im} \cos\varphi$$

ahol φ az elforgatás szöge; ez lépésenként csak egyváltozós szélsőérték-feladat megoldását jelenti. Minden ciklusban végighaladunk minden páron (összesen $k(k-1)/2$ pár van), és a ciklus végén ellenőrizzük a célfüggvény változását. Akkor állunk meg, ha már csak elhanyagolható mértékben változik.

2012. 03. 13.

Dr Ketskeméty László előadása

23



Főkomponensanalízis

A faktoranalízis speciális esete. Dimenziószám csökkentésre használható. Az eredetileg p változóval jellemzett statisztikai sokaságot $k \ll p$ változóval (főkomponensekkel) jellemezzük. A k -dimenziós statisztikai elemzések következtetései a p -dimenziós sokaságra is érvényesek lesznek. Ezzel jelentős költséget lehet megtakarítani. Lehetőség van a $p > 3$ dimenziós sokaságot (ha $k < 4$) pontfelhő grafikonon szemléltetni. A főkomponensek terében a változók korrelálatlanok lesznek.

A főkomponens-transzformáció:

$$\underline{F} = \underline{G}^T (\underline{X} - \underline{m}) \quad \Rightarrow \quad \underline{X} = \underline{G} \cdot \underline{F} + \underline{m}$$

$$\underline{F} = (F_1, F_2, \dots, F_p) \quad \underline{G} = (\underline{g}_1, \underline{g}_2, \dots, \underline{g}_p)$$

a főkomponens-vektor a főirányok mátrixa

2012. 03. 13.

Dr Ketskeméty László előadása

24



A FŐKOMPONENS-MODELL TULAJDONSÁGAI

• A főkomponensek korrelálatlanok: $R(F_i, F_j) = 0$

• A főkomponensek csökkenő jelentőségűek:


$E(F_i)$ F_i magyaráz a legtöbbet, F_2 a második legtöbbet, ..., F_p magyaráz a legkevesebbet T -ből.

$$T = \sum_{i=1}^p \lambda_i \dots$$

$\frac{\lambda_i}{T}$ megmutatja, hány %-ot magyaráz F_i



Könyökábra (scree-plot)





A FŐKOMPONENS-MODELL TULAJDONSÁGAI

• A főirányok jelentése: $\sum \underline{g}_i = \lambda_i \underline{g}_i$

\underline{g}_1 ebben az irányban a legnagyobb a variancia

\underline{g}_2 ebben az irányban a legnagyobb a variancia a \underline{g}_1 irányra merőleges irányok között

⋮

• Dimenziócsökkentés:

Ha \underline{X} helyett az első k főfaktor-alkotta vektorral számolunk, az elvesztett információ csupán:

$$1 - \frac{\lambda_1 + \lambda_2 + \dots + \lambda_k}{T}$$



Watanabe-tétele

Belátható, hogyha p dimenziót lecsökkentünk $k < p$ dimenzióra, akkor az összes lehetséges dimenziócsökkentési eljárással összevetve, a főkomponens analízissel végrehajtott dimenziócsökkentés minimalizálja az információvesztést! Az eredeti változók totális variációjára és a k főfaktor totális variációjára van egymáshoz a legközelebb! Ezt az optimális arányt fejezi ki a kovariancia-mátrix sajátértékeiből számítható arány, amely jó esetben közel esik 1-hez:

$$\frac{\sum_{j=1}^k \lambda_j}{\sum_{j=1}^p \lambda_j}$$


2012. 03. 13.

Dr Ketskeméty László előadása

28



2D FŐKOMPONENSANALÍZIS



- Az első főkomponens irány (z_1) azon egyenes iránya az X síkon, amely körül a legkisebb a pontok szóródása.
- A második főkomponens irány (z_2) erre merőleges.

2012. 03. 13.


Dr Ketskeméty László előadása

29



3D FŐKOMPONENSANALÍZIS

Tengelyek nem derékszögeket zárnak be: a változók korreláltak!




2012. 03. 13.

Dr Ketskeméty László előadása

30

3D FŐKOMPONENSANALÍZIS

Ebben az irányban tudunk legjobban differenciálni a pontok között. A főkomponensek hosszát (fontosságát) az ún. sajátértékek (*eigenvalue*) jellemezzük, ami az értelmezett variancia.




2012. 03. 13.

Dr Ketskeméty László előadása

31

3D FŐKOMPONENSANALÍZIS

Az eljárást folytatni lehetne a harmadik főkomponens megkeresésével, de ennek a konkrét esetben már nincs értelme, mivel ebben az irányban már jelentéktelen a szóródás ⇒ az adatok leírására 2 dimenzió elegendő!



2012. 03. 13.

Dr Ketskeméty László előadása

32

Példa a faktoranalízisre I.


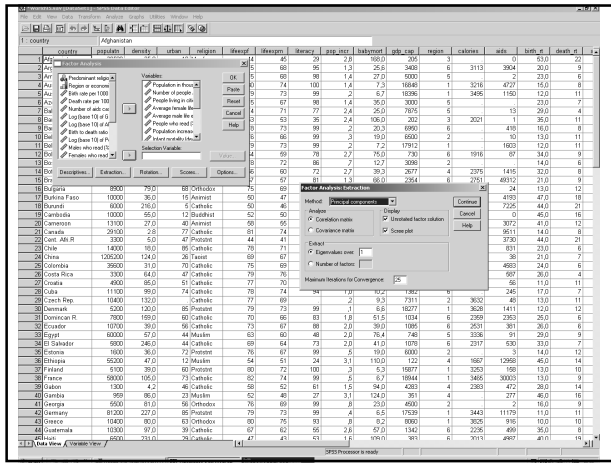
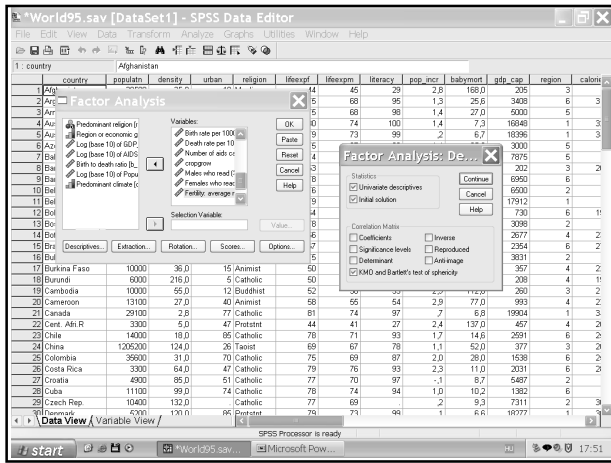
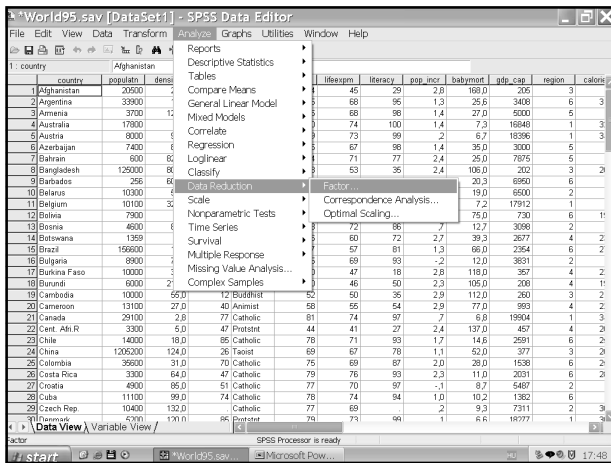
Megvizsgáljuk, milyen kapcsolat van a *world 95* állomány változói között!

	Name	Type	Width	Decimals	Label
1	country	String	12	0	
2	populatio	Numeric	9	0	Population in thousands
3	density	Numeric	8	1	Number of people / sq. kilometer
4	urban	Numeric	5	0	People living in cities (%)
5	religion	String	8	0	Predominant religion
6	lifeexpm	Numeric	4	0	Average female life expectancy
7	lifeexpm	Numeric	5	0	Average male life expectancy
8	literacy	Numeric	4	0	People who read (%)
9	pop_grow	Numeric	5	1	Population increase (% per year)
10	infantmort	Numeric	6	1	Infant mortality (deaths per 1000 live births)
11	gdp_cap	Numeric	6	0	Gross domestic product / capita
12	region	Numeric	12	0	Region or economic group
13	calories	Numeric	6	0	Daily calorie intake
14	aids	Numeric	8	0	Aids cases
15	birth_rt	Numeric	5	1	Birth rate per 1000 people
16	death_rt	Numeric	6	0	Death rate per 1000 people
17	aids_rt	Numeric	8	2	Number of aids cases / 100000 people
18	log_gdp	Numeric	8	2	Log (base 10) of GDP_CAP
19	log_aids	Numeric	8	2	Log (base 10) of AIDS_RT
20	birth_death	Numeric	8	2	Birth to death ratio
21	fertility	Numeric	6	1	Fertility: average number of kids
22	log_pop	Numeric	8	2	Log (base 10) of Population
23	cropprow	Numeric	4	0	
24	lit_male	Numeric	4	0	Males who read (%)
25	lit_fema	Numeric	4	0	Females who read (%)
26	climate	Numeric	3	0	Predominant climate

2012. 03. 13.

Dr Ketskeméty László előadása

33






Factor Analysis

Descriptive Statistics

	Mean	Std. Deviation ^a	Analysis N ^b	Missing N
Population in thousands	47723.88	148726.364	109	0
Number of people / sq. kilometer	203.415	675.7052	109	0
People living in cities (%)	56.53	24.091	109	1
Average female life expectancy	70.16	10.572	109	0
Average male life expectancy	64.92	9.273	109	0
People who read (%)	78.34	22.670	109	2
Population increase (% per year)	1.682	1.1976	109	0
Gross domestic product / capita	5859.98	6479.836	109	0
Infant mortality (deaths per 1000 live births)	42.313	38.0792	109	0
Daily calorie intake	2763.83	470.025	109	34
Aids cases	7914.26	40121.542	109	3
Birth rate per 1000 people	25.923	12.3609	109	0
Death rate per 1000 people	9.56	4.233	109	1
Number of AIDS cases / 100000 people	24.3794	48.76328	109	3
Population growth	17.98	15.594	109	3
Males who read (%)	78.73	18.031	109	24
Females who read (%)	67.26	25.229	109	24
Fertility: average number of kids	3.563	1.8848	109	2

^a For each variable, missing values are replaced with the variable mean.



Példa a faktoranalízisre II.

Milyen kapcsolat van a gépkocsik jellemzői között?

	Name	Type	Width	Decim	Label
1	mpg	Numeric	4	0	Miles per Gallon
2	engine	Numeric	5	0	Engine Displacement (cu. inches)
3	horse	Numeric	5	0	Horsepower
4	weight	Numeric	4	0	Vehicle Weight (lbs.)
5	accel	Numeric	4	0	Time to Accelerate from 0 to 60 mph (sec)
6	year	Numeric	2	0	Model Year (modulo 100)
7	origin	Numeric	1	0	Country of Origin
8	cylinder	Numeric	1	0	Number of Cylinders
9	filter_\$	Numeric	1	0	cylrec = 1 cylrec = 2 (FILTER)

2012. 03. 13.

Dr Ketskémty László előadása

49

Factor Analysis dialog box showing selected variables: Miles per Gallon (mpg), Engine Displacement (engine), Horsepower (horse), Vehicle Weight (weight), and Time to Accelerate (accel). The Selection Variable is set to filter_\$.



Factor Analysis

Warnings

Only one component was extracted. Component plots cannot be produced.

Descriptive

	Mean
Miles per Gallon	23.44
Engine Displacement (cu. inches)	194.01
Horsepower	104.34
Vehicle Weight (lbs.)	2968.57
Time to Accelerate from 0 to 60 mph (sec)	15.26

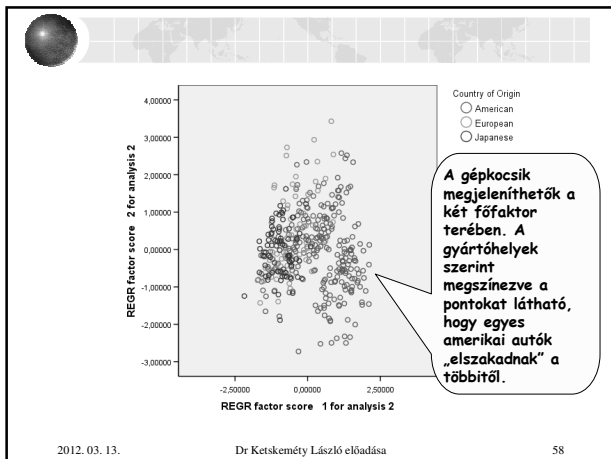
a. For each variable, missing values are replaced with the variable mean.


Kaptunk egy figyelmeztetést, hogy csak egyetlen dimenziót tartottunk meg a beállításkor, tehát a 2-D és 3-D ábrák nem készülhetnek el.

2012. 03. 13.

Dr Ketskémty László előadása

51





Példa a főkomponens analízisre

Elemezzük ki a banki ügyfelek 700 esetet tartalmazó állományát főkomponens analízissel! Csoportosítsuk az állomány változóit!

Variable Information

Variable	Label	Measurement Level
age	Age in years	Scale
ed	Level of education	Ordinal
employ	Years with current employer	Scale
address	Years at current address	Scale
income	Household income in thousands	Scale
debtinc	Debt to income ratio (x100)	Scale
creddebt	Credit card debt in thousands	Scale
othdebt	Other debt in thousands	Scale
default	Previously defaulted	Nominal
preddef1	Predicted default, model 1	Scale
preddef2	Predicted default, model 2	Scale
preddef3	Predicted default, model 3	Scale

age (ügyfél életkora),
ed (ügyfél iskolázottsága),
employ (ügyfél hány éve van alkalmazásban jelenlegi munkaadójánál),
address (ügyfél jelenlegi lakcíme),
income (ügyfél háztartásának évi jövedelme ezer USD-ban),
debtinc (ügyfél által felvett hitel aránya a jövedelméhez),
creddebt (ügyfél hitelkártya tartozása ezer USD-ban),
othdebt (ügyfél egyéb tartozása ezer USD-ban),
default (ügyfél korábban megtagadta-e már a törlesztést).

2012. 03. 13. Dr Ketskemény László előadása 60



Példa a főkomponens analízisre

Communalities

	Initial	Extraction
Age in years	1,000	,695
Years with current employer	1,000	,653
Years at current address	1,000	,519
Household income in thousands	1,000	,680
Debt to income ratio (x100)	1,000	,771
Credit card debt in thousands	1,000	,753
Other debt in thousands	1,000	,819

Extraction Method: Principal Component Analysis.

2012. 03. 13.

Dr Ketskemény László előadása

64



Példa a főkomponens analízisre

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	3,269	46,700	46,700	3,269	46,700	46,700	2,631	37,591	37,591
2	1,622	23,174	69,874	1,622	23,174	69,874	2,260	32,282	69,874
3	,856	12,236	82,109						
4	,442	6,315	88,424						
5	,361	5,164	93,589						
6	,225	4,843	98,232						
7	,124	1,768	100,000						

Extraction Method: Principal Component Analysis.

2012. 03. 13.

Dr Ketskemény László előadása

65



Példa a főkomponens analízisre

Component Matrix^a

	Component	
	1	2
Age in years	,699	-,453
Years with current employer	,739	-,328
Years at current address	,520	-,498
Household income in thousands	,809	-,161
Debt to income ratio (x100)	,342	,809
Credit card debt in thousands	,748	,440
Other debt in thousands	,796	,432

Extraction Method: Principal Component Analysis.

a. 2 components extracted.

Rotated Component Matrix^a

	Component	
	1	2
Age in years	,830	,080
Years with current employer	,782	,203
Years at current address	,718	-,066
Household income in thousands	,733	,377
Debt to income ratio (x100)	-,236	,846
Credit card debt in thousands	,311	,810
Other debt in thousands	,354	,833

Extraction Method: Principal Component Analysis.

Rotation Method: Varimax with Kaiser Normalization.

a. Rotation converged in 3 iterations.

Component Transformation Matrix

Component	1	2
1	,783	,622
2	-,622	,783

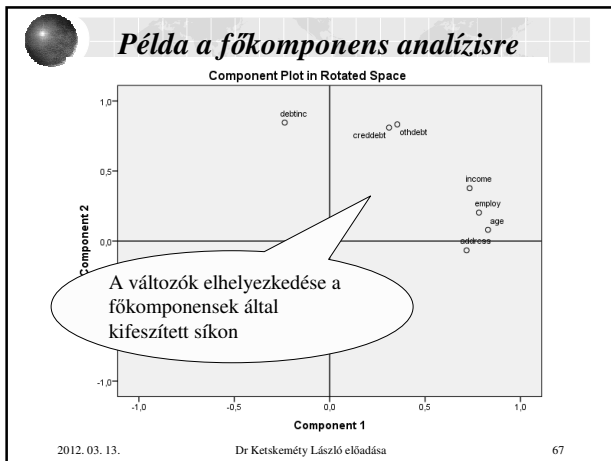
Extraction Method: Principal Component Analysis.


Rotation Method: Varimax with Kaiser Normalization.

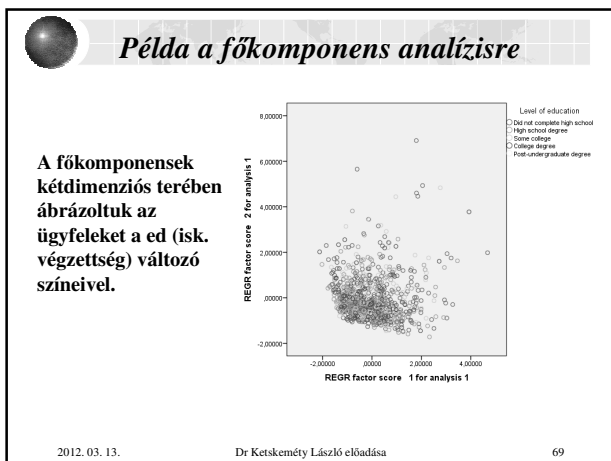
2012. 03. 13.

Dr Ketskemény László előadása

66










Példa a főkomponens analízisre

A főkomponensek kétdimenziós terében ábrázoltuk az ügyfeleket a korkategória színeivel.
1: harminc alatti
2: harminc és negyven közötti
3: negyven feletti



2012. 03. 13.

Dr Ketskeméty László előadása

70
