

# Többváltozós statisztika, ANOVA és adatredukciós módszerek (BMNPS07700M)

Előadó: Soltész-Várhelyi Klára

## Főkomponens elemzés & faktor elemzés

Első rész

Elmélet

# Mire használjuk?


- **Látens változó:**

- olyan változó, melyet közvetlenül nem tudunk mérni
- Több általunk mérhető változóra van hatással / fejeződik ki benne
  - Extraverziót nem tudjuk mérni, de azt igen, hogy mennyire szereti a társaságot, mennyire szereti a szereplést, mennyire keresi az izgalmakat...

- **Három használati mód:**

- 1) megtalálni több tulajdonság mögött meghúzódó látens változót
  - Pl. BigFive dimenziók megtalálása
- 2) kérdőívkészítés & kérdőívadaptálás
  - Pl. ellenőrizhető, hogy a kialakított kérdőívben tényleg úgy csoportosulnak-e az itemek, ahogy az elmélet alapján gondolnánk vagy adaptálás esetén ahogy az eredeti nyelven csoportosultak
- 3) adatredukció
  - Sok változó helyett statisztika a kevés faktoron
  - Regresszióanalízisben multikollinearitás problémájára megoldás (bizonyos beállításokkal elérhető, hogy a létrejövő faktorok korrelálatlanok legyenek egymással, így a regresszióba egymástól teljesen független prediktorok kerülhetnek)

Általános elméleti bevezető



# Konceptuális alap

- **Korrelációs mátrix**

- Korrelációs tábla az itemek között.
- Azok a változók, melyek között nagy a korreláció, alegységet, csoportot alkotnak.
- Megkeressük az itemek olyan lehető legkisebb számú csoportosítását, hogy az egy csoportba tartozó itemek közt nagy legyen korreláció, míg a különböző csoportba tartozók között kicsi.

	Szeretem az embereket	Szeretek egyedül lenni	Sok barátom van	Szeretem a tömeget	Kiállok az ismerőseimért	Pontos vagyok	Szétszórtnak mondanak	Betartom az ígéreteim	Ritkán dühít fel valami
Szeretem az embereket	1,000								
Szeretek egyedül lenni	-,867	1,000							
Sok barátom van	,663	-,564	1,000						
Szeretem a tömeget	,414	-,332	,361	1,000					
Kiállok az ismerőseimért	,599	-,556	,458	,149	1,000				
Pontos vagyok	,059	-,036	,028	-,123	,528	1,000			
Szétszórtnak mondanak	-,098	,105	-,033	,066	-,535	-,876	1,000		
Betartom az ígéreteim	,102	-,128	,003	-,037	,408	,709	-,632	1,000	
Ritkán dühít fel valami	,035	-,044	,095	,172	-,104	-,175	,130	-,086	1,000

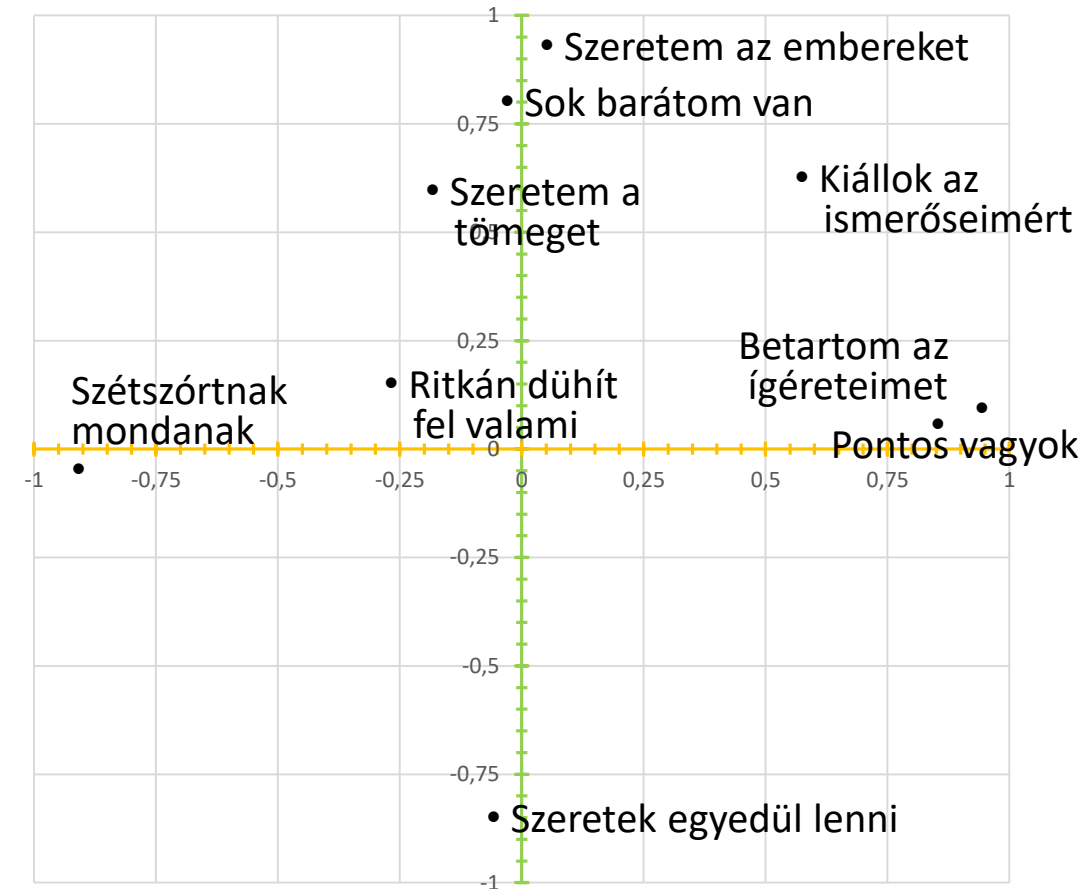
# Tengelyek (faktorok, komponensek) és itemek töltései ezeken

- Az előbbi „csoportok” tulajdonképpen a **faktorok** faktorelemzésben illetve **komponensek** főkomponens elemzésben, vagy általános néven a **tengelyek**. (Az általános elméleti részben komponenst fogok írni).
  - Az elemzés eredménye elképzelhető annyi dimenziós térként, ahány komponens van
  - Hogy a komponensek hogyan jönnek létre, az a különböző elemzési módszerekben eltérő, és a koncepció megértéséhez most még nem is kell, így elég róla egyelőre annyi, hogy ez



- **Komponenstöltés (ill. faktortöltés, loadings, jelölése:  $b_s$ )**

- Az item és a komponens közötti Pearson korreláció (tehát értéke -1 és +1 között mozog)
- A tengelyek mentén az itemek elhelyezhetők aszerint, hogy mennyire korrelálnak a komponenssel, így a töltések az itemek koordinátái lesznek
- Minden item minden komponensre tölt valamilyen mértékben, de jó esetben egy-egy item egy komponensre tölt erősen, a többire pedig csak gyengén.
- A példában a „Kiállok az ismerőseimért” nem igazán jó item, mert mindkét tengelyre viszonylag erősen tölt, és a „Ritkán dühít fel valami” sem jó item, mert egyik tengelyre sem tölt erősen. Hogy ezekkel mit érdemes kezdeni, később megbeszéljük.



# Töltés mátrix

- **Komponenstöltés (ill. faktortöltés) mátrix**


- A töltések mátrixba rendezésével kapjuk, jelölése  $b_s$
- Oszlopok jelölik a tengelyeket, sorok jelölik a változókat

- A tengelyek **jelentés**ének meghatározása a töltések alapján

- A töltések mátrixos és/vagy grafikus megjelenítése segítségével az elemzést végző személy pszichológiai tudása alapján dönt a tengelyek jelentéséről.
- Mi lehet a két tengely jelentése?

- **Barátságosság** és **Lelkiismeretesség**

	Tengely1	Tengely2	
Töltés: $b_s =$	.931	.068	Szeretem az embereket
	-.878	-.076	Szeretek egyedül lenni
	.803	-.021	Sok barátom van
	.574	-.202	Szeretem a tömeget
	.630	.595	Kiállok az ismerőseimért
	.010	.946	Pontos vagyok
	-.063	-.910	Szétszórtnak mondanak
	.058	.811	Betartom az ígéreteimet
	.141	-.274	Ritkán dühít fel valami



# Melyik itemek tartozzanak bele egy tengelyhez?

- Amikor értelmezzük a tengelyeket, el kell döntenünk, milyen erősségű töltéstől számítunk egy itemet az adott tengelyhez tartozónak. (Pl. a „Szeretem a tömeget” még értelmezzük-e a Tengely1-hez?)
  - Megbízhatóság szempontjából minta nagyságától függ.  $\alpha = .01$  szig. szinten
    - 50 .722
    - 100 .512
    - 200 elemszámú mintán .364 -nél nagyobb töltésű változókat (abszolút értékben)
    - 300 .298
    - 600 .210
    - 1000 .162
  - De így nagy mintán sokszor értelmezhetetlenül sok változó tölt egy tengelyre
- Magyarázóerő szempontjából a nagyméretű mintán a(z abszolút értékben vett) .400-nál nagyobb töltésű változókat érdemes értelmezni (ez 16% megmagyarázott varianciát jelent) (Stevens, 2012)
- Tehát, ha egy 100 fős mintán néztük az előző elemzést, akkor
  - A Barátságosság: Szeretem az embereket, Szeretek egyedül lenni, Sok barátom van, Szeretem a tömeget, Kiállok az ismerőseimért
  - Lelkiismeretesség: Pontos vagyok, Szétszórtnak mondanak, Betartom az ígéreteimet, Kiállok az ismerőseimért

Tengely1Tengely2

.931	.068	Szeretem az embereket
-.878	-.076	Szeretek egyedül lenni
.803	-.021	Sok barátom van
.574	-.202	Szeretem a tömeget
.630	.595	Kiállok az ismerőseimért
.010	.946	Pontos vagyok
-.063	-.910	Szétszórtnak mondanak
.058	.811	Betartom az ígéreteimet
.141	-.274	Ritkán dühít fel valami

# Számolható értékek

- Most már tudjuk, hogy a kérdőívnek van egy Barátságosság és egy Lelkiismeretesség tengelye. Jó lenne kiszámolni az emberek Barátságosság és Lelkiismeretesség pontszámát. Hogyan tehetjük ezt meg?
  - **1.** A tengelyhez tartozó **itemek pontjainak összeadásával** vagy átlagolásával (egyszerű, de **kevésbé jó** módszer)
    - Barátságosság: Szeretem az embereket, Szeretek egyedül lenni (fordított), Sok barátom van, Szeretem a tömeget, Kiállok az ismerőseimért
    - Lelkiismeretesség: Pontos vagyok, Szétszórtnak mondanak (fordított), Betartom az ígéreteimet, Kiállok az ismerőseimért

Emberek	Egyedül	Barát	Tömeg	Kiállok	Pontos	Szétszórt	Ígéret	Dühít	Barátságosság	Lelkiismeretesség
5	2-> 4	5	5	4	2	3-> 3	3	1	5+4+5+5+4 = 23	2+3+3+4 = 12
2	3-> 3	2	2	2	2	3-> 3	4	1	2+3+2+2+2 = 11	2+3+4+2 = 11
4	2-> 4	3	3	3	5	2-> 4	3	2	4+4+3+3+3 = 17	5+4+3+3 = 15

- A módszer hátrányai:
  - A különböző itemszámú skálák értékei nem összehasonlíthatók egymással (nem mondhatom, hogy a harmadik személy Barátságossága magasabb, mint a Lelkiismeretessége, mert a Barátságosság több itemet tartalmaz)
  - A módszer csak azonos skálán mérődő itemek esetén használható (pl. nem lenne létrehozható az Egészségesség skála a „Hetente hányszor sportol?“, „Milyen gyakran iszik alkoholt?“, „Dohányzik?“, „Mennyire figyel a kiegyensúlyozott étkezésre?“ itemekből, mert más a mértékegységük.
  - Nem súlyozza az itemeket, a „Szeretem az embereket“ és a „Szeretem a tömeget“ egyforma súllyal szerepel.



- **2. Komponens érték** (component score illetve faktor érték – factor score) számolásával
  - Az itemek összeadásánál **súlyozzuk az itemeket** a faktorelemzésből számolt **fontosságuk alapján**
  - Ehhez tudnunk kell az itemek fontosságát, amit a Komponens érték együttható ad majd meg
- **Komponens érték együttható** (component score coefficient) illetve faktorelemzésnél faktor érték együttható.
  - Jelölése B
  - Az itemek töltéséből indul ki, de figyelembe veszi az itemek közötti korrelációt is, így a komponens és az item közötti egyedi kapcsolatot méri. Ez lesz a súly, ami alapján megmondhatjuk, hogy egy-egy item mennyire fontos a Barátságosság és Lelkiismeretesség szempontjából
  - Például Barátságosság szempontjából a „Szeretem az embereket” lesz a legfontosabb, a „Szeretem a tömeget” kevésbé fontos, és a „Pontos vagyok” egyáltalán nem lesz fontos.
  - Egy item együtthatója mindig alacsonyabb, mint a töltése, hiszen nem tartalmazza azt a varianciát, melyet az adott item mellett más itemek is képesek megmagyarázni a tengelyből. (Hasonlóképp, ahogy a többszörös lineáris regresszióban egy prediktor magyarázó ereje alacsonyabb volt, mint amikor korrelációval néztük a kimeneti változóval való kapcsolatát.)

	Barátságosság	Lelkiismeretesség	
B=	.310	-.025	Szeretem az embereket
	-.292	-.019	Szeretek egyedül lenni
	.272	-.050	Sok barátom van
	.204	-.102	Szeretem a tömeget
	.181	.180	Kiállok az ismerőseimért
	-.046	.338	Pontos vagyok
	.027	-.322	Szétszórtnak mondanak
	-.023	.287	Betartom az ígéreteimet
	.062	-.105	Ritkán dühít fel valami

- A komponensek pontszámának számolása előtt még egy lépés van vissza: **az itemeket standardizáljuk**, ennek köszönhetően akár különböző mértékegységű itemeket is be lehet vonni az elemzésbe.

Emberek	Egyedül	Barát	Tömeg	Kiállok	Pontos	Szétszórt	Ígéret	Dühít
5 -> 1,397	2 -> -0,928	5 -> 1,631	5 -> 1,681	4 -> 1,097	2 -> -0,819	3 -> 0,196	3 -> -0,368	1 -> -1,370
2 -> -0,809	3 -> 0,039	2 -> -1,213	2 -> -0,654	2 -> -1,188	2 -> -0,819	3 -> 0,196	4 -> 0,600	1 -> -1,370
4 -> 0,662	2 -> -0,928	3 -> -0,265	3 -> 0,125	3 -> -0,046	5 -> 1,281	2 -> -0,694	3 -> -0,368	2 -> -0,660

- Megjegyzések a standardizálással kapcsolatban:
  - Standardizálással minden itemet olyanná alakítunk, ahol az itemen a minta átlaga 0, szórása pedig 1. Például az Emberek itemen az első személy standardizált értéke pozitív, tehát ő az átlagosnál jobban szereti az embereket, a második személy standardizált értéke negatív, tehát ő az átlagosnál kevésbé szereti az embereket.
  - Főkomponens elemzést nem csak korrelációs táblákat használva, hanem kovariancia táblákat használva is lehet végezni. Kovarianciák elemzése során az itemeket nem standardizáljuk, csak centralizáljuk.
  - Itt nem az egész adatbázist látod, csak annak első három sorát.

- Most már ismerjük a súlyokat, a komponens szempontjából fontos itemek nagy súllyal, a nem fontos itemek kis súllyal fognak a pontszámba beszámítani, valamint egységesítettük az itemeket is, nincs más hátra mint kiszámolni a komponens értékeket!

Emberek	Egyedül	Barát	Tömeg	Kiállok	Pontos	Szétszórt	Ígéret	Dühít
1,397	-0,928	1,631	1,681	1,097	-0,819	0,196	-0,368	-1,370
-0,809	0,039	-1,213	-0,654	-1,188	-0,819	0,196	0,600	-1,370
0,662	-0,928	-0,265	0,125	-0,046	1,281	-0,694	-0,368	-0,660

Barátság		Lelkiismeret	
.310	-.025		Szeretem az embereket
-.292	-.019		Szeretek egyedül lenni
.272	-.050		Sok barátom van
.204	-.102		Szeretem a tömeget
.181	.180		Kiállok az ismerőseimért
-.046	.338		Pontos vagyok
.027	-.322		Szétszórtnak mondanak
-.023	.287		Betartom az ígéreteimet
.062	-.105		Ritkán dühít fel valami

- Egy komponens értékét úgy kapjuk meg, hogy az itemek standardizált értékét az item adott komponensen lévő súlyával megszorozzuk, és ezeket összeadjuk.

A Barátságosság szempontjából fontos itemek nagy súllyal szerepelnek

Minél kevésbé fontos egy item, annál kisebb a súlya

$$\text{Barátság} = .310 * \text{Emberek} - .292 * \text{Egyedül} + .272 * \text{Barát} + .204 * \text{Tömeg} + .181 * \text{Kiállok} - .046 * \text{Pontos} + .027 * \text{Szétszórt} - .023 * \text{Ígéret} + .062 * \text{Dühít}$$

A Barátságosság szempontjából negatívan megfogalmazott itemek negatív súllyal szerepelnek, így nem kell őket külön megforgatni

A Barátságosság szempontjából lényegtelen itemek olyan kis súllyal szerepelnek, hogy szinte mindegy is, hogy ott vannak

$$\text{Lelkiismeret} = -.025 * \text{Emberek} - .019 * \text{Egyedül} - .050 * \text{Barát} - .102 * \text{Tömeg} + .180 * \text{Kiállok} + .338 * \text{Pontos} - .322 * \text{Szétszórt} + .287 * \text{Ígéret} - .105 * \text{Dühít}$$

A képletbe behelyettesítve az első személy barátságosság és lelkiismeretesség értéke:

$$\text{Barátság} = .310 * 1.397 - .292 * (-0.928) + .272 * 1.631 + .204 * 1.681 + .181 * 1.097 - .046 * (-0.819) + .027 * 0.196 - .023 * (-0.368) + .062 * (-1.370) = 1.656$$

$$\text{Lelkiismeret} = -.025 * 1.397 - .019 * (-0.928) - .050 * 1.631 - .102 * 1.681 + .180 * 1.097 + .338 * (-0.819) - .322 * 0.196 + .287 * (-0.368) - .105 * (-1.370) = -0.410$$

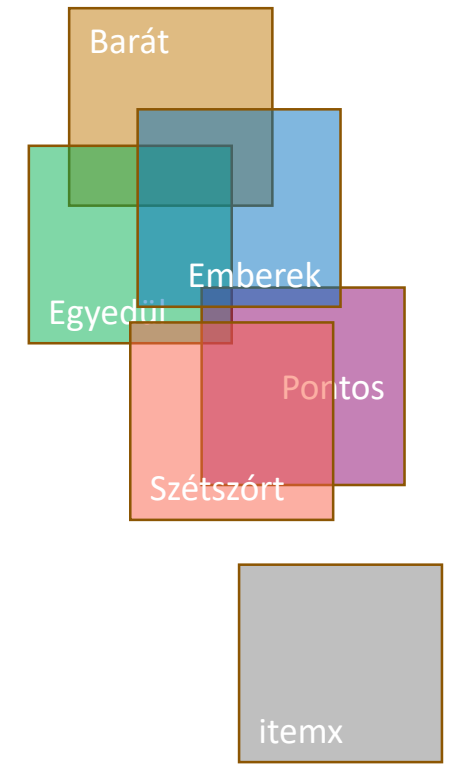
- Megjegyzések a komponens értékhez
  - Kérdőívekben a komponenseket szokás skáláknak vagy alskáláknak is nevezni, tehát mondhatjuk, hogy létrehoztuk a Barátságosság és Lelkiismeretesség alskálákat, és kiszámoltuk az emberek pontszámát ezeken.
  - A komponens érték használatakor NEM kell az itemeket megforgatni, a negatív itemek (pl. „Szeretek egyedül lenni”) egyszerűen negatív súllyal számolódnak
  - A létrejövő skálaérték standardizált formában van, tehát átlaga 0, szórása 1 a skáláknak
  - A pozitív skálaérték azt jelenti, hogy a személy az átlagnál magasabb értéket vesz fel a skálán (pl. az első személy az átlagnál barátságosabb, de kevésbé lelkiismeretes)
  - A személyek összehasonlíthatók egymással (pl. az első személy barátságosabb, mint a második)
  - Egy személy különböző skálapontszámait összehasonlítható egymással (pl. a harmadik személy barátságossága magasabb, mint lelkiismeretessége)
  - Az előzőekben bemutatott rengeteg számolást nem kell neked elvégezni, azt a skálapontszámok mentésével kérheted majd a főkomponens elemzés során.

Emberek	Egyedül	Barát	Tömeg	Kiállok	Pontos	Szétszórt	Ígéret	Dühít	Barátságosság	Lelkiismeretesség
5	2	5	5	4	2	3	3	1	1.656	-0.410
2	3	2	2	2	2	3	4	1	-0.996	-0.088
4	2	3	3	3	5	2	3	2	0.311	0.578

- **Megerősítő (konfirmátoros) faktoranalízis (CFA – confirmatory factor analysis)**
  - látens változók struktúrájáról a kutató fejében már létezik egy modell, és ezt a meglévő modellt ellenőrzi
  - bonyolult összefüggérendszer modellezésére alkalmas
  - AMOS vagy Mplus
- **Feltáró (exploratív) faktoranalízis (EFA – exploratory factor analysis)**
  - adatok mögött rejtőző struktúra feltárása és a megtalált faktorok általánosítása a populációra
  - Másik mintán ellenőrizni kell
  - Többfajta matematikai megoldás (Főfaktor analízis, Maximum likelihood elemzés, stb.)
- **Főkomponens elemzés (PCA - principal component analysis)**
  - Legegyszerűbb módszer
  - Az adatok átrendezése úgy, hogy az itemek varianciáját (az általuk kifeszített teret) a lehető legkevesebb új dimenzióval írjuk le a lehető legkevesebb veszteséggel
  - „csak” merőleges transzformációk sorozata, mely az adatokat egy új koordináta rendszerbe transzformálja, de ha mögöttes összefüggérendszer feltárására nem alkalmas
  - gyakorlatban a kérdőívek struktúrájának feltárásához általában megelégszünk vele, de egy új személyiségmodellt ne főkomponens elemzés alapján alkoss!

# Kommunalitás

- A főkomponens elemzés és faktorelemzés összehasonlítása előtt tudnunk kell még:
- Több item összefüggésének vizsgálatakor egy item **teljes variáciája** két részből áll:
  - **Közös variancia** – más változókkal közös
  - **Egyedi variancia** – csak az adott változóhoz tartozik (az egyedi variancia része a random variancia – hiba is, de ezzel nem tudunk számolni)
- **Kommunalitás:**
  - megadja, hogy egy item variációjának mekkora része közös
  - 1, ha az egész; 0-ha semennyi (a többi itemtől teljesen független az adott item)
- Faktoranalízis az itemek közös variációjával dolgozik
  - Minden változóra többszörös lineáris regresszió– az  $R^2$ -ekből becsüljük - faktoranalízis
- Főkomponens elemzés az itemek teljes variációjával dolgozik
  - Kezdetben a kommunalitást 100%-nak tekinti



Az ő kommunalitása 0 lenne, ez azt is jelenti, hogy egyik itemmel sem korrelál

# Faktor analízis / főkomponens analízis

Faktor analízis	Főkomponens elemzés
Itemek közös varianciáját modellezi	Itemek teljes varianciáját elemzi
Kommunalitást lineáris regresszióval számolja	Kommunalitást 100%-nak tekinti
Faktorok matematikai modell alapján	Az eredeti adatot lineáris változók összességére bontja
Alkalmas látens változók vizsgálatára	Az adatokban meglévő lineáris komponenseket találja meg
Rengeteg feltétel (pl. hozza a többszörös regresszió minden feltételét)	egyszerű
30 változó felett magas kommunalitással nagyon hasonló eredményt hoznak	
Kevés változó, alacsony kommunalitás esetén nagy különbségek lehetnek, a főkomponens elemzés eredménye nem biztos, hogy értelmezhető	


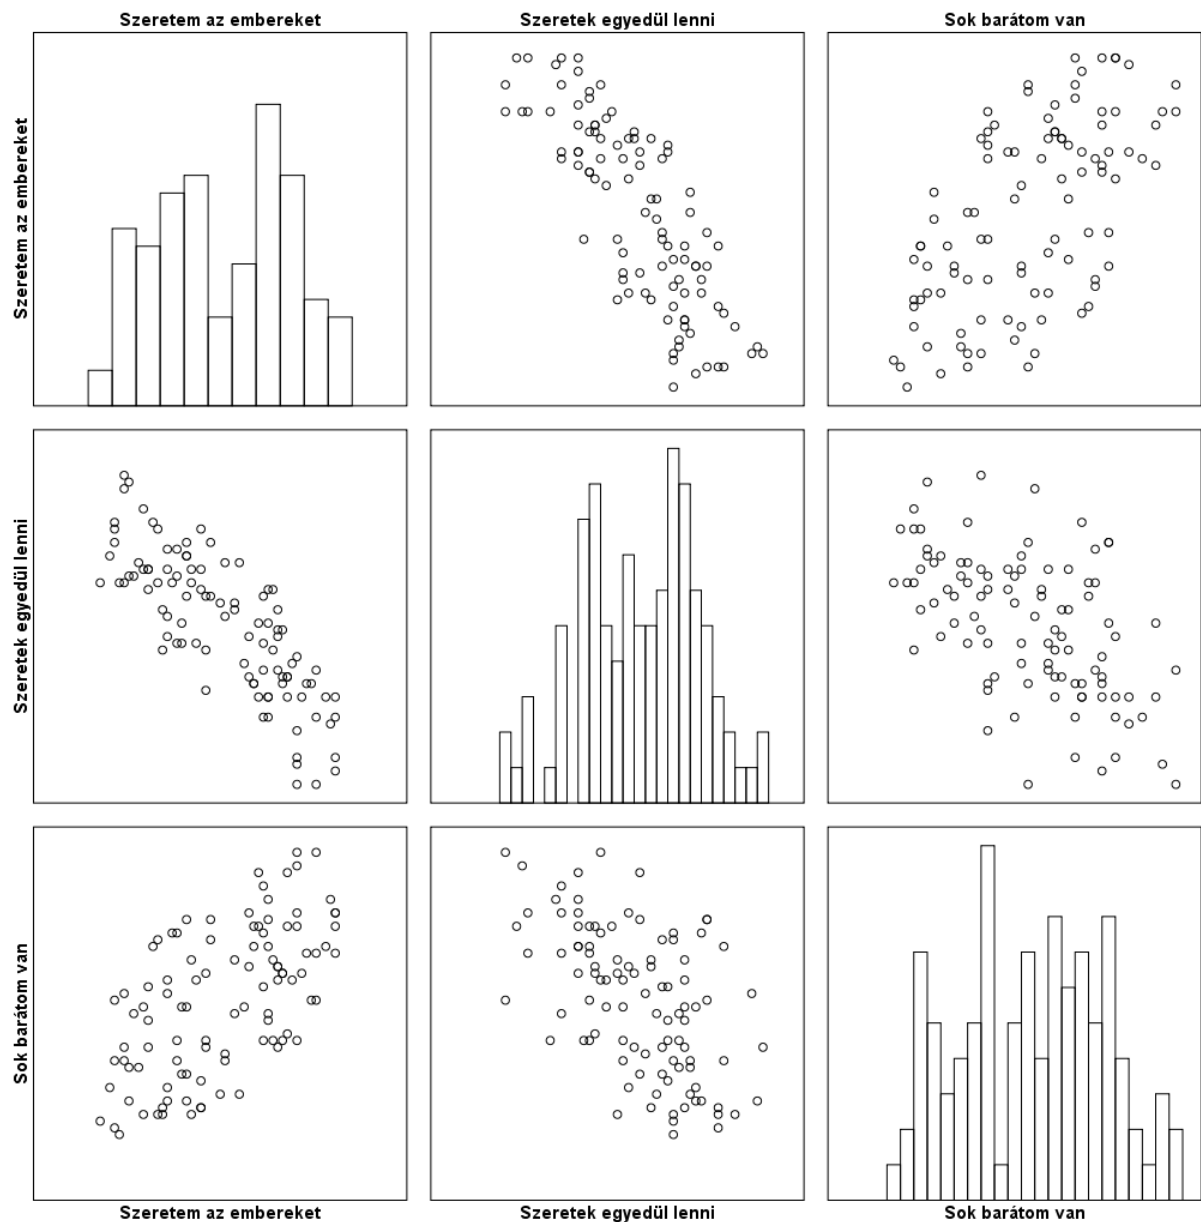
# A komponensek megtalálása

(azaz hogyan történik a varázslat)




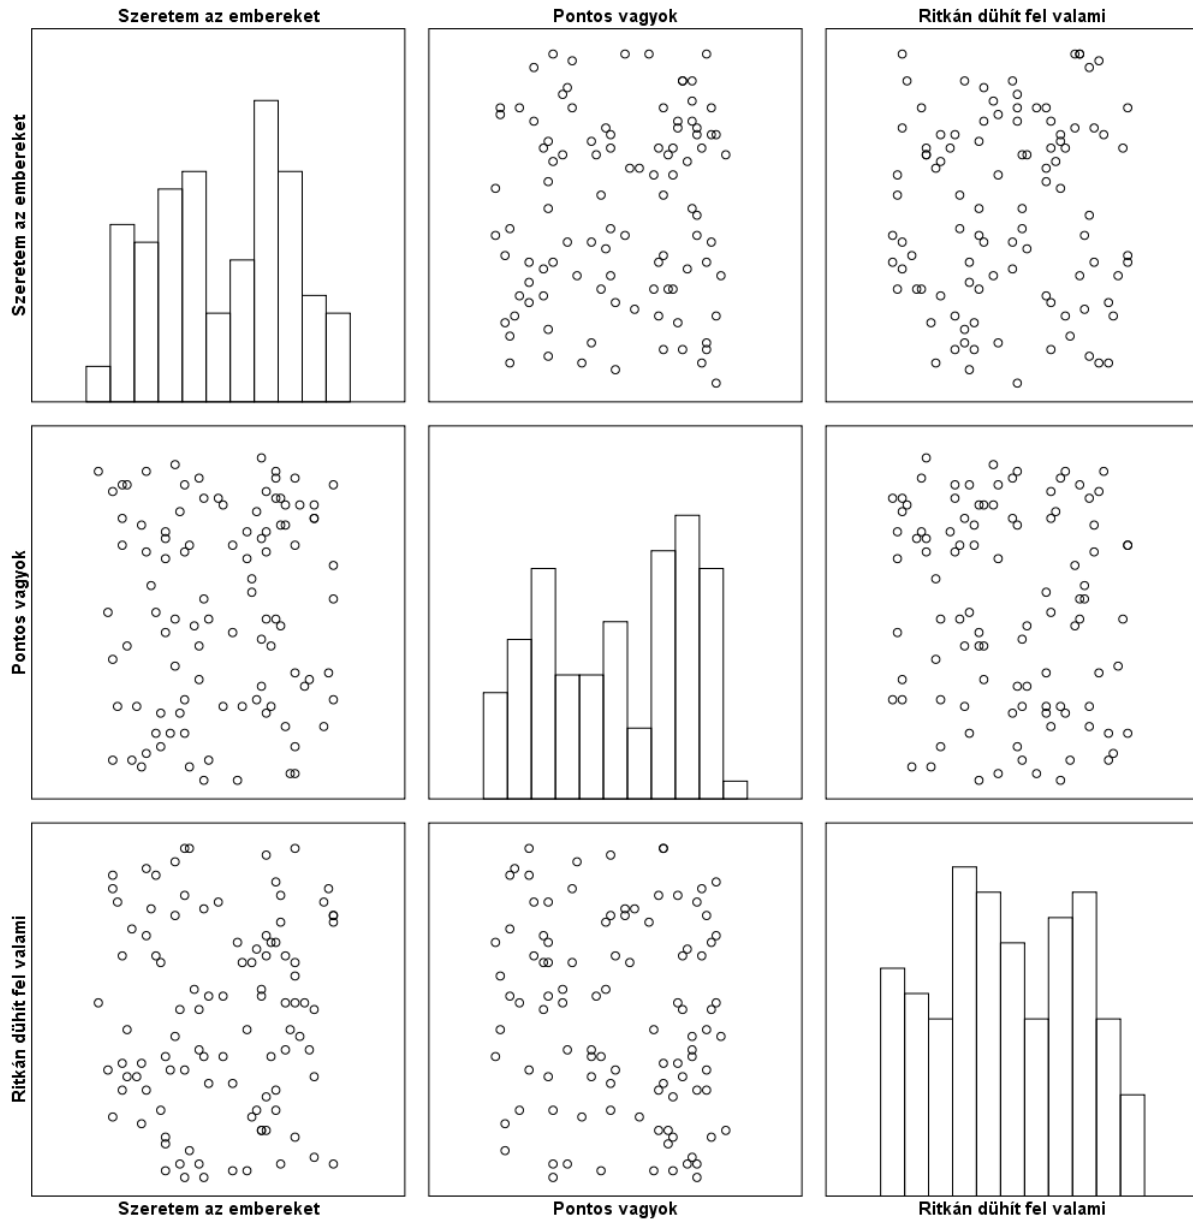


# Hogy néz ki egy többdimenziós térben, ha az itemek korrelálnak?

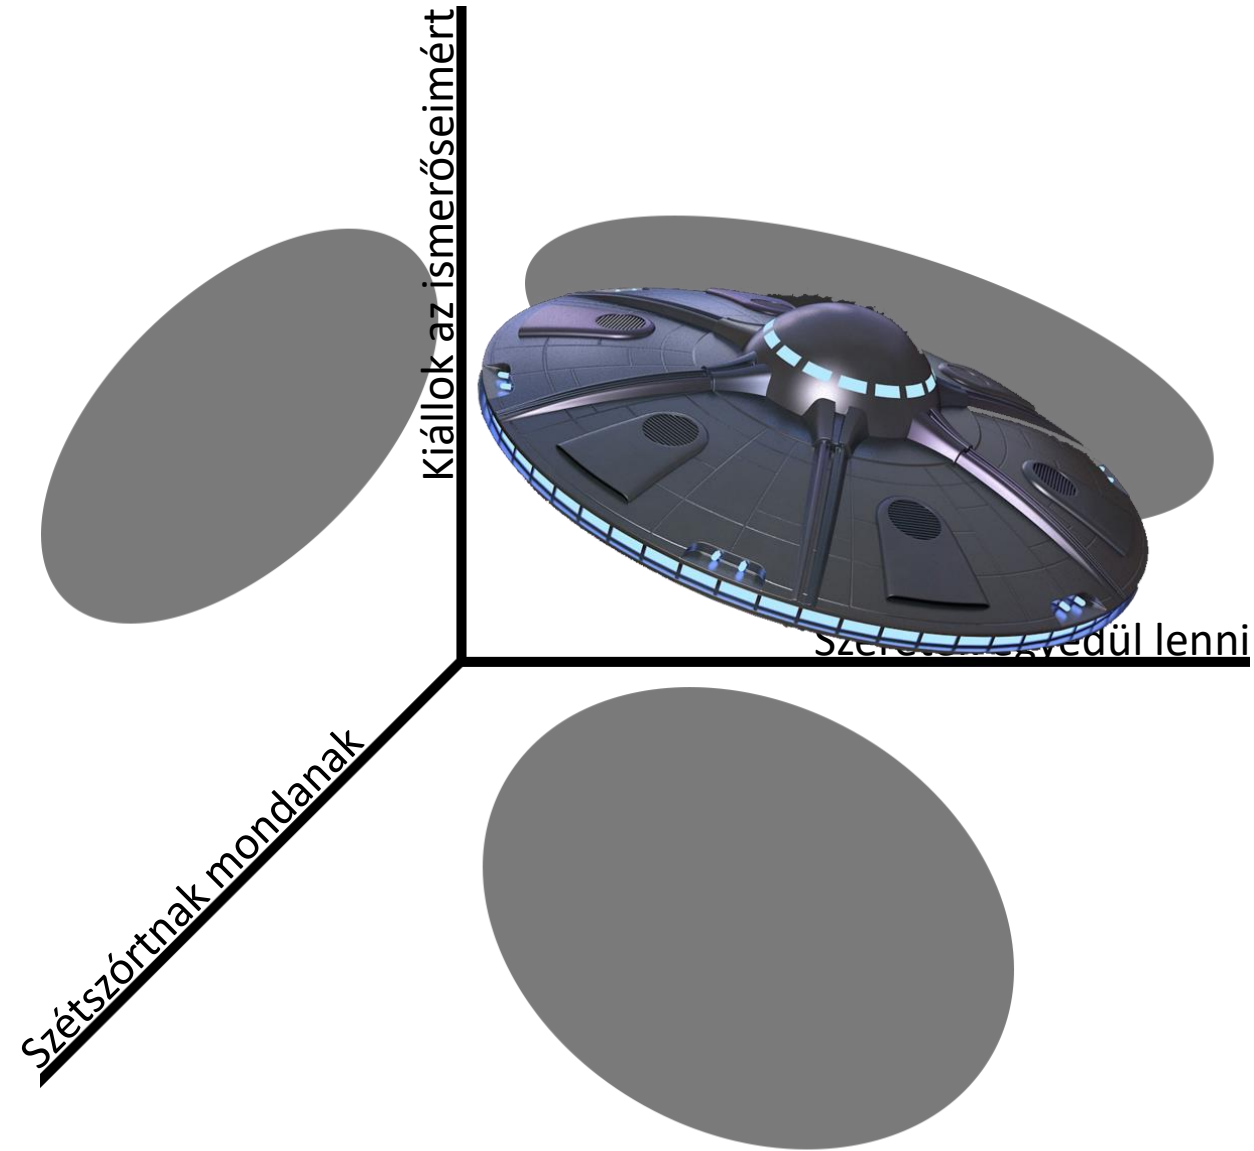
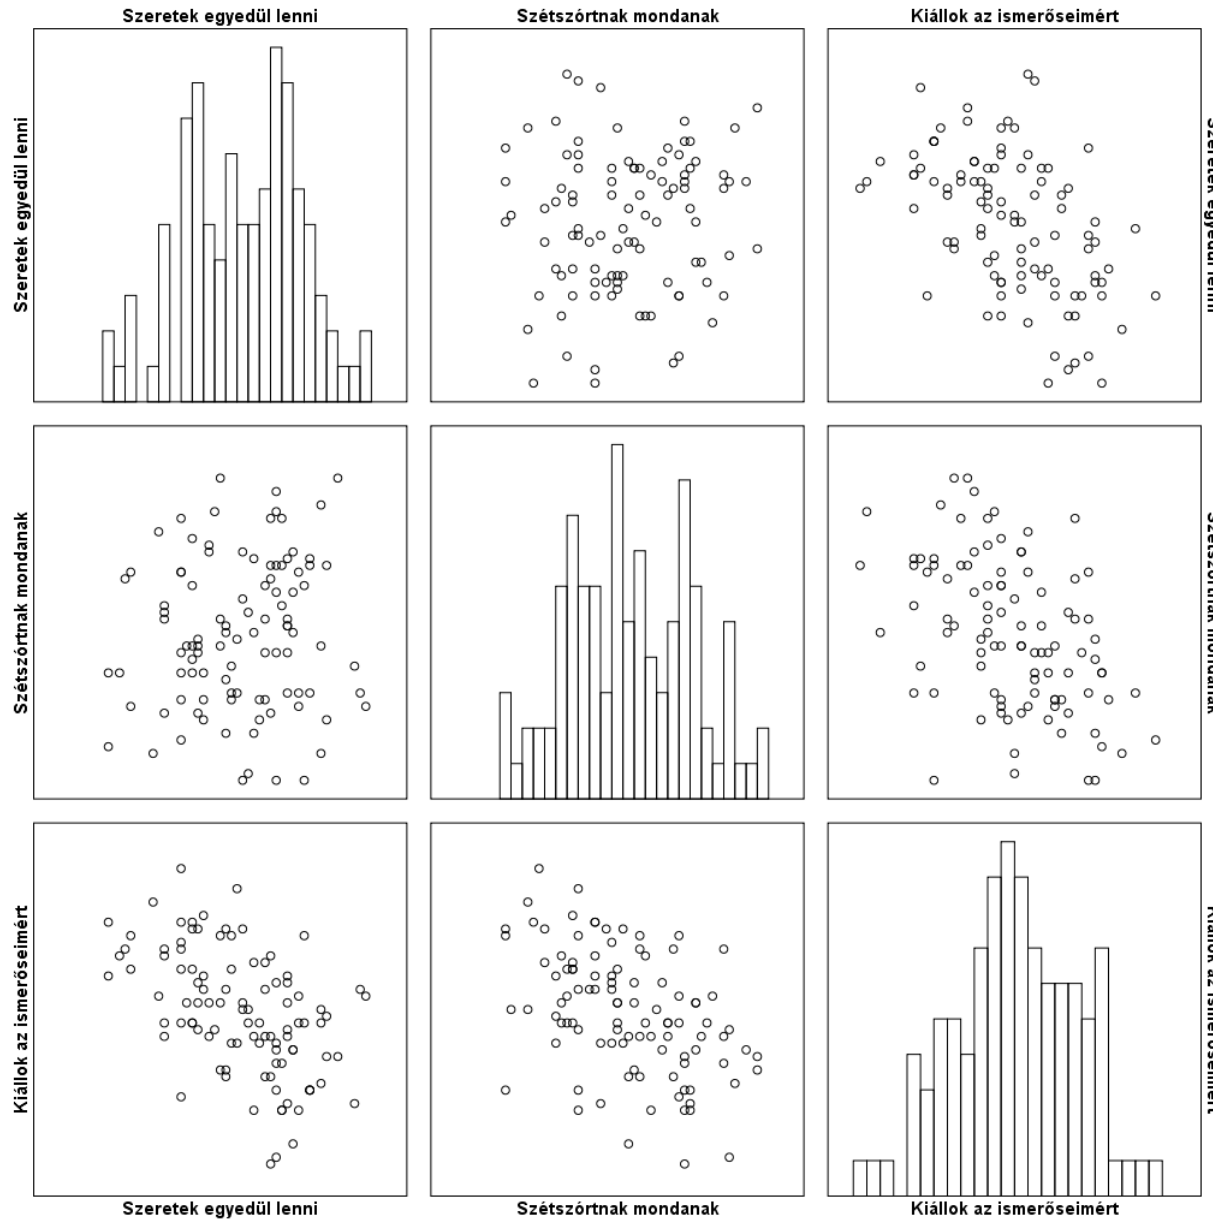


(a könnyebb átláthatóság kedvéért a Likert-skálás itemekhez zajt adtam)

# Hogy néznek ki, ha nem korrelálnak?




# Hogy néznek ki különböző erősségű korrelációk?




# Főkomponens analízis



- Lépései
  - Az  $n$  darab item kifeszít egy  $n$  dimenziós teret, a pontfelhő ebben az  $n$  dimenziós térben helyezkedik el
  - Megkeressük azt az egyenest (első főkomponenst), mely az adatok varianciájának legnagyobb részét magyarázza. Azaz azt az egyenest, mely mentén legjobban szóródnak az adatok, ahol a pontfelhő a legvastagabb
  - Majd megkeressük az az egyenest (további főkomponensek), mely az előző egyenesekkel korrelálatlan / merőleges rá / független tőle, és a maradék varianciának legnagyobb részét magyarázza
  - Ezt addig folytatjuk, amíg marad meg nem magyarázott variancia
  - Ennek eredményeként annyi komponenst (új dimenziót) kapunk, ahány dimenziós a tér eredetileg volt, tehát 2 item leírható egy két dimenziós térrel, és ebben két komponens található
  - A komponensek sorba vannak rendezve aszerint, hogy mennyit magyaráznak a pontfelhő varianciájából: az első a legtöbbet, az utolsó a legkevesebbet.





- Az új komponensek mentén ugyanúgy meg lehet határozni egy személy értékét, mint az eredeti itemek segítségével
- A pirossal jelölt személy az eredeti tengelyen  $X=57$ ;  $Y=77$  értékeket vette fel, az új tengelyeken pedig  $PCA1 = 0.4$ ;  $PCA2 = -0.1$  (emlékeztető a főkomponens tengelyek z-értékekben skálázódnak)
- Ha minden tengelyt megtartunk, akkor az adatokban lévő variációt 100%-ban magyarázni tudjuk vele, tehát mindenkinek pontosan meg tudjuk adni a helyét a többdimenziós térben a főkomponens elemzésből származó tengelyekkel.



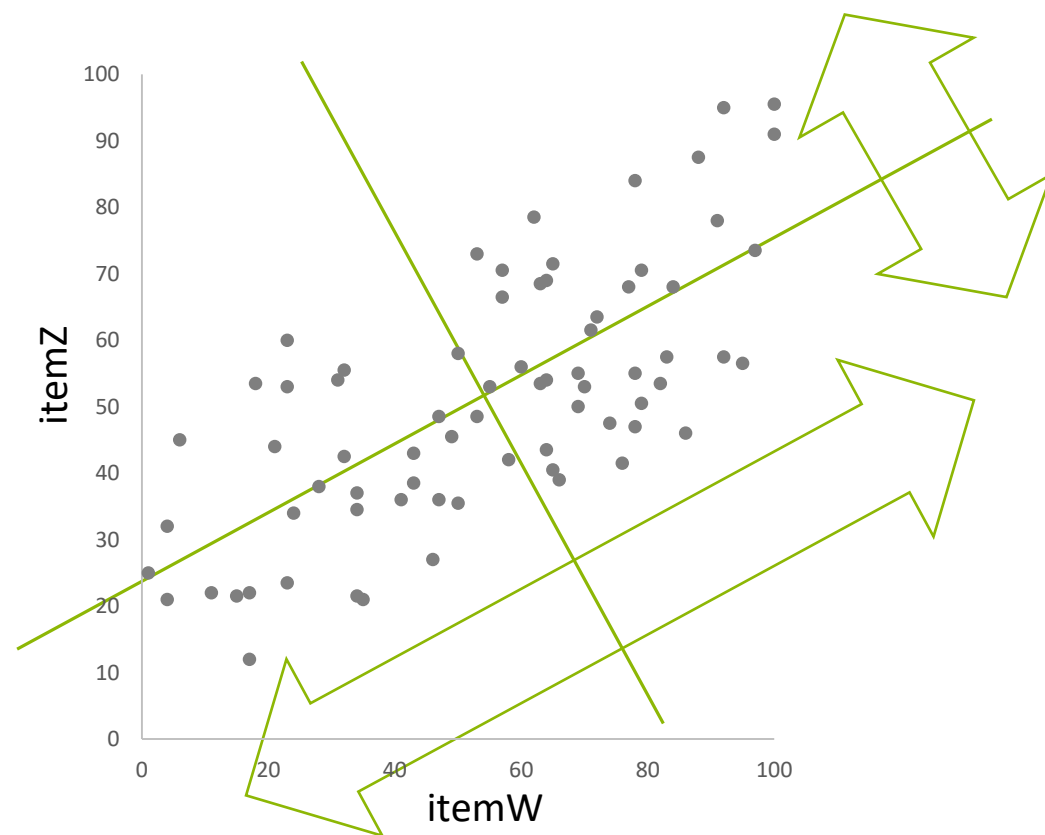

- Abban bízunk, hogy az adatok variációjának nagy részét néhány főkomponenssel le lehet írni, azaz a többi főkomponens magyarázó ereje kicsi.
- A kis magyarázóerővel bíró komponensek viszonylag kis veszteséggel kidobhatók az elemzésből, ezáltal az adatok leírásához szükséges dimenziók (változók) száma csökkenthető.



- Demonstráció az előzőhöz. Az animációkat amoeba készítette Matlabbal, innen szedtem le őket: <http://stats.stackexchange.com/questions/2691/making-sense-of-principal-component-analysis-eigenvectors-eigenvalues>. Érdeemes a linket megnézni, mert zseniális választ ad a „Hogyan magyarázd el a PCA-t a nagymamádnak” kérdésre!



- Ha nem mondhatom egy dimenzióra, hogy jelentéktelen, akkor megmarad. Például a jobb oldali pontfelhő leírásához szükség van mind a két komponensre, mert a második komponens kidobása túl nagy információvesztést jelentene. Itt nem sikerült a dimenziók számát csökkenteni (kettő volt, kettő maradt), azaz nincsen adatredukció.





- **Vissza az eredeti példánkhoz! Mivel 9 itemből áll a kérdőívünk, ezért létrejött 9 komponens. De hány komponenst tartunk meg?**
- **Sajátérték (eigenvalue)**
  - Az adathalmaznak van valamennyi varianciája. Ebből a varianciából az első komponens 37,818%-ot magyaráz, a második 27,699%-ot, stb. Vedd észre, hogy, ha összeadod a megmagyarázott varianciákat, akkor megkapod a 100%-ot, azaz a 9 komponens megmagyarázza a 9 eredeti item teljes változatosságát.
  - A megmagyarázott varianciák átlaga 11,111%. Ezt megkapod úgy is, ha átlagolod őket, de úgy is, hogy  $100\%/9$ -cel (azaz a komponensek számával)
  - A **sajátérték** az komponens által megmagyarázott variancia és az átlagos variancia aránya. Például az első komponensnél ez  $37,818/11,111=3.404$ . Jelentése, hogy az első komponens az átlagosnál háromszor több varianciát magyaráz meg. Látjuk, azt is, hogy a harmadik komponens majdnem pont az átlagból van, a harmadiktól felfele, pedig már átlagosnál gyengébb komponenseket látunk.

Komponens sorszáma	Hány százalékát magyarázza a komponens az adatok varianciájának?	Komponens sajátértéke
1	37,818	3,404
2	27,699	2,493
3	11,089	,998
4	7,876	,709
5	5,545	,499
6	4,454	,401
7	3,022	,272
8	1,397	,126
9	1,099	,099

- **Hány főkomponenst hagyjunk az elemzésben?**

- Csak azokat, melyek a varianciából még elég sokat magyaráznak

- **Kaiser kritérium**


- Azokat, melyeknek a sajátértéke 1 fölött van (az átlagosnál többet magyaráznak a teljes varianciából)
- Spss-ben ez történik alapból
- Hátránya, hogy sok item esetén viszonylag sok komponenst „enged át”

- **Scree plot (könyök ábra)**


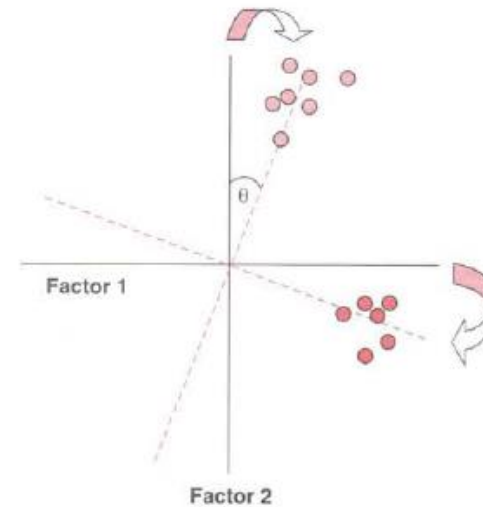
- Ha ábrázoljuk, hogy az egyes főkomponenseknek mennyi a sajátértéke, tipikus lefutást kapunk  
Néhány erős főkomponens után sok gyenge jön  
Ez a grafikonon a vonal töréseként (könyökeként) jelenik meg.
- Azokat a főkomponenseket hagyjuk meg, melyek a töréspont előtt vannak

- **Paralel elemzés**

- Azokat tartsuk meg, melyek a véletlenül generált adatokból származó sajátértékek 95%-nál magasabbak.



- A létrejövő faktorok elforgatása, hogy minél inkább igaz legyen, a változók egy csoportja egy faktorra sokat tölt, a többire keveset
- Két rotációs módszer:
  - **Ortogonalis**: megtartja a faktorok között a derékszöget / függetlenséget
  - **Ferde**: nem tartja meg a derékszöget / függetlenséget
    - Kutatói döntés: lehetséges, hogy a faktorok, melyeket találtam, tényleg nem függetlenek egymástól?
- **SPSS-ben**
  - **Ortogonalis**:
    - **varimax**: a töltést egyenletesen szétosztja a faktorok között
    - **Quartimax**: kevés faktorra nagy töltést tesz
    - **Equamax**: kettő között
  - **Ferde**:
    - **Promax**: gyors, nagy adatállományokra tervezve
    - **Direct oblimin**: ha elméletileg várható a faktorok korrelációja



Ábra Andy Field könyvéből

# Fogalom-összefoglaló

- **Itemek & korreláció**
  - Az elemzésbe bevett itemek egy  $n$  dimenziós teret feszítenek ki ( $n$  = itemek száma). Ha az itemek korrelálatlanok lennének, akkor a többdimenziós térben a személyek válaszai egyenletes pontfelhőt alkotnának. Helyette az itemek korrelálnak egymással, a pontfelhőben elnyúlások/sűrűsödések vannak
- **Komponens**
  - Az itemek közötti korrelációt kihasználva az  $n$  dimenziós pontfelhőnkét írjuk le kevesebb dimenzióval (tengellyel), ezeket nevezzük komponensnek. Mivel egy  $n$  dimenziós teret kevesebb dimenzióval próbálunk leírni, természetesen valamennyi információt veszünk a redukcióval.
- **Saját érték**
  - Megadja, hogy egy komponens mennyit magyaráz a többdimenziós pontfelhő varianciájából. A komponens „erősségét” írja le, ez alapján döntjük el, melyik komponenset tartjuk meg, melyiket dobjuk ki
- **Komponens töltés**
  - Megadja, egy item mennyire korrelál egy tengellyel (komponenssel), az item komponenssel való kapcsolatát írja le. Ez alapján döntjük el, melyik itemeket érdemes egy komponens értelmezésekor figyelembe venni
- **Forgatás**
  - Ha megvannak a tengelyeink (komponenseink), úgy forgatjuk őket, hogy minél inkább igaz legyen, hogy a tengelyre néhány item nagyon tölt, más itemek meg egyáltalán nem. Így könnyebb a őket értelmezni
- **Komponens érték**
  - A személy pontszáma az adott komponensen, skálán.
- **Komponens érték együttható**
  - Korrigált komponens töltés, a komponens érték kiszámolásakor ezzel súlyozzuk az itemeket, hogy a tengely szempontjából „fontosabb” tételek nagyobb hangsúllyal kerüljenek be a skála értékébe