

TÉRSTATISZTIKA

Dr. Sipos Tibor
Dr. Török Ádám
Szabó Zsombor



KUKG



BUDAPESTI MŰSZAKI ÉS GAZDASÁGTUDOMÁNYI EGYETEM
Közlekedésmérnöki és Járműmérnöki Kar

Tartalom

Térstatisztika



Térbeli interakciók



Gravitációs modell



Tartalom

Térstatisztika



Térbeli interakciók



Gravitációs modell



Térbeli egységek statisztikai elemzése

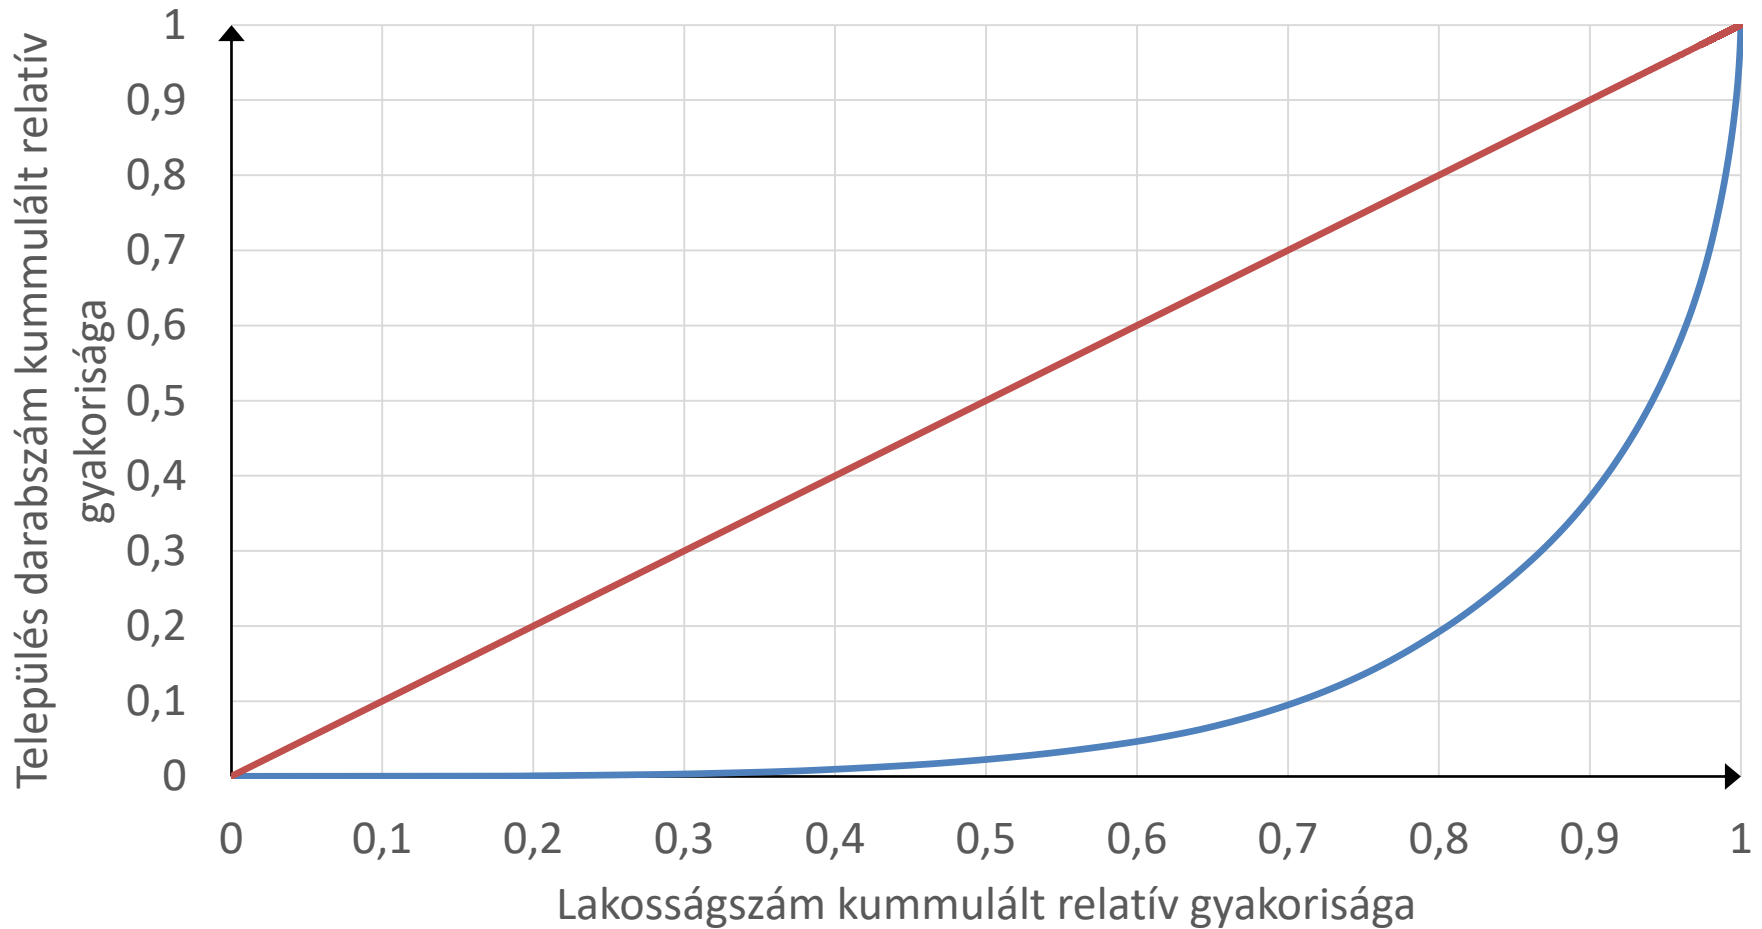
- A térbeli egységekre ugyanúgy alkalmazhatók a statisztikából megismert módszerek
- Legtöbbször azonban ezen adatok nem normális eloszlást követnek
- Normáleloszlás esetén
 $\bar{x} = E(x) = x_{MO} = x_{ME}$

Magyarország lakosság száma


Várható érték	3099,3252
Standard hiba	576,025573
Medián	799
Módusz	183
Szórás	32355,0031
Minta varianciája	1046846228
Csúcsosság	2695,92513
Ferdeség	50,1646485
Tartomány	1749726
Minimum	8
Maximum	1749734
Összeg	9778371
Darabszám	3155



Lorentz görbe egységnyi település mellett



Lorentz görbe terület alapon




Lakosság szám

- Felix Auerbach (1856-1933)
német fizikus (1917)
 - Egy adott területen ideális esetben ha sorba rendezzük lakosság szám szerint a településeket, akkor az n . település lakosság száma pontosan $1/n$ része a legnagyobbknak
- Ez a Zipf-eloszlás egy kitüntetett esete
- Később bebizonyosodott, hogy az $1/n^{1,07}$ jobban leírja a települések viszonyát




- Különböző városstruktúrák
 - Auberbach tétele alapján jelenlegi budapesti lakosságszámmal
 - Auberbach tétele alapján 10000000 összlakossággal
 - Jelenlegi magyar helyzet




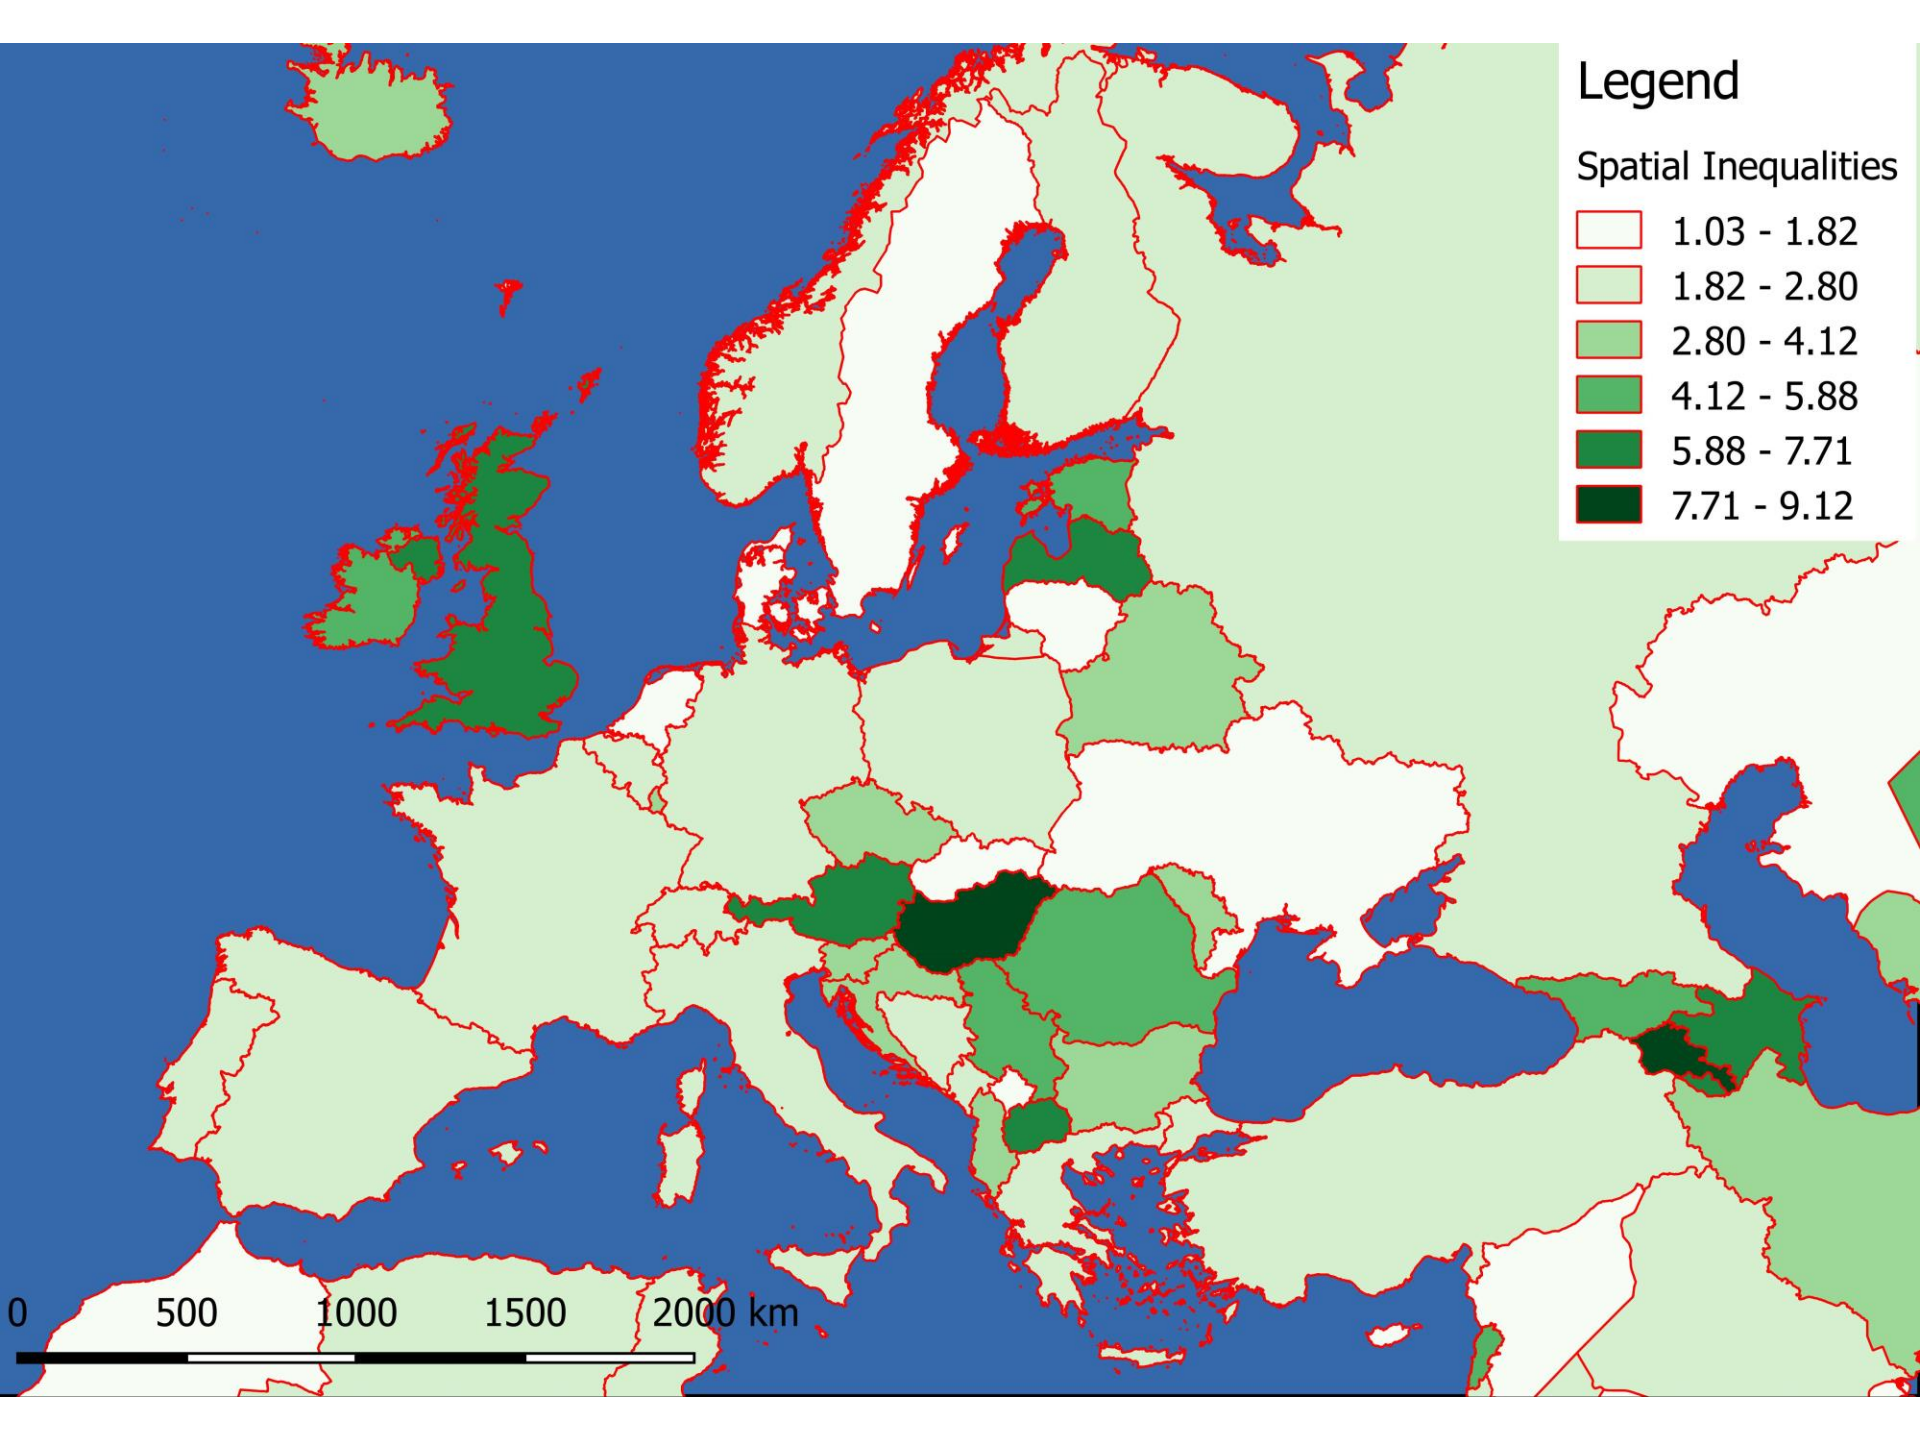
Auerbach tétele

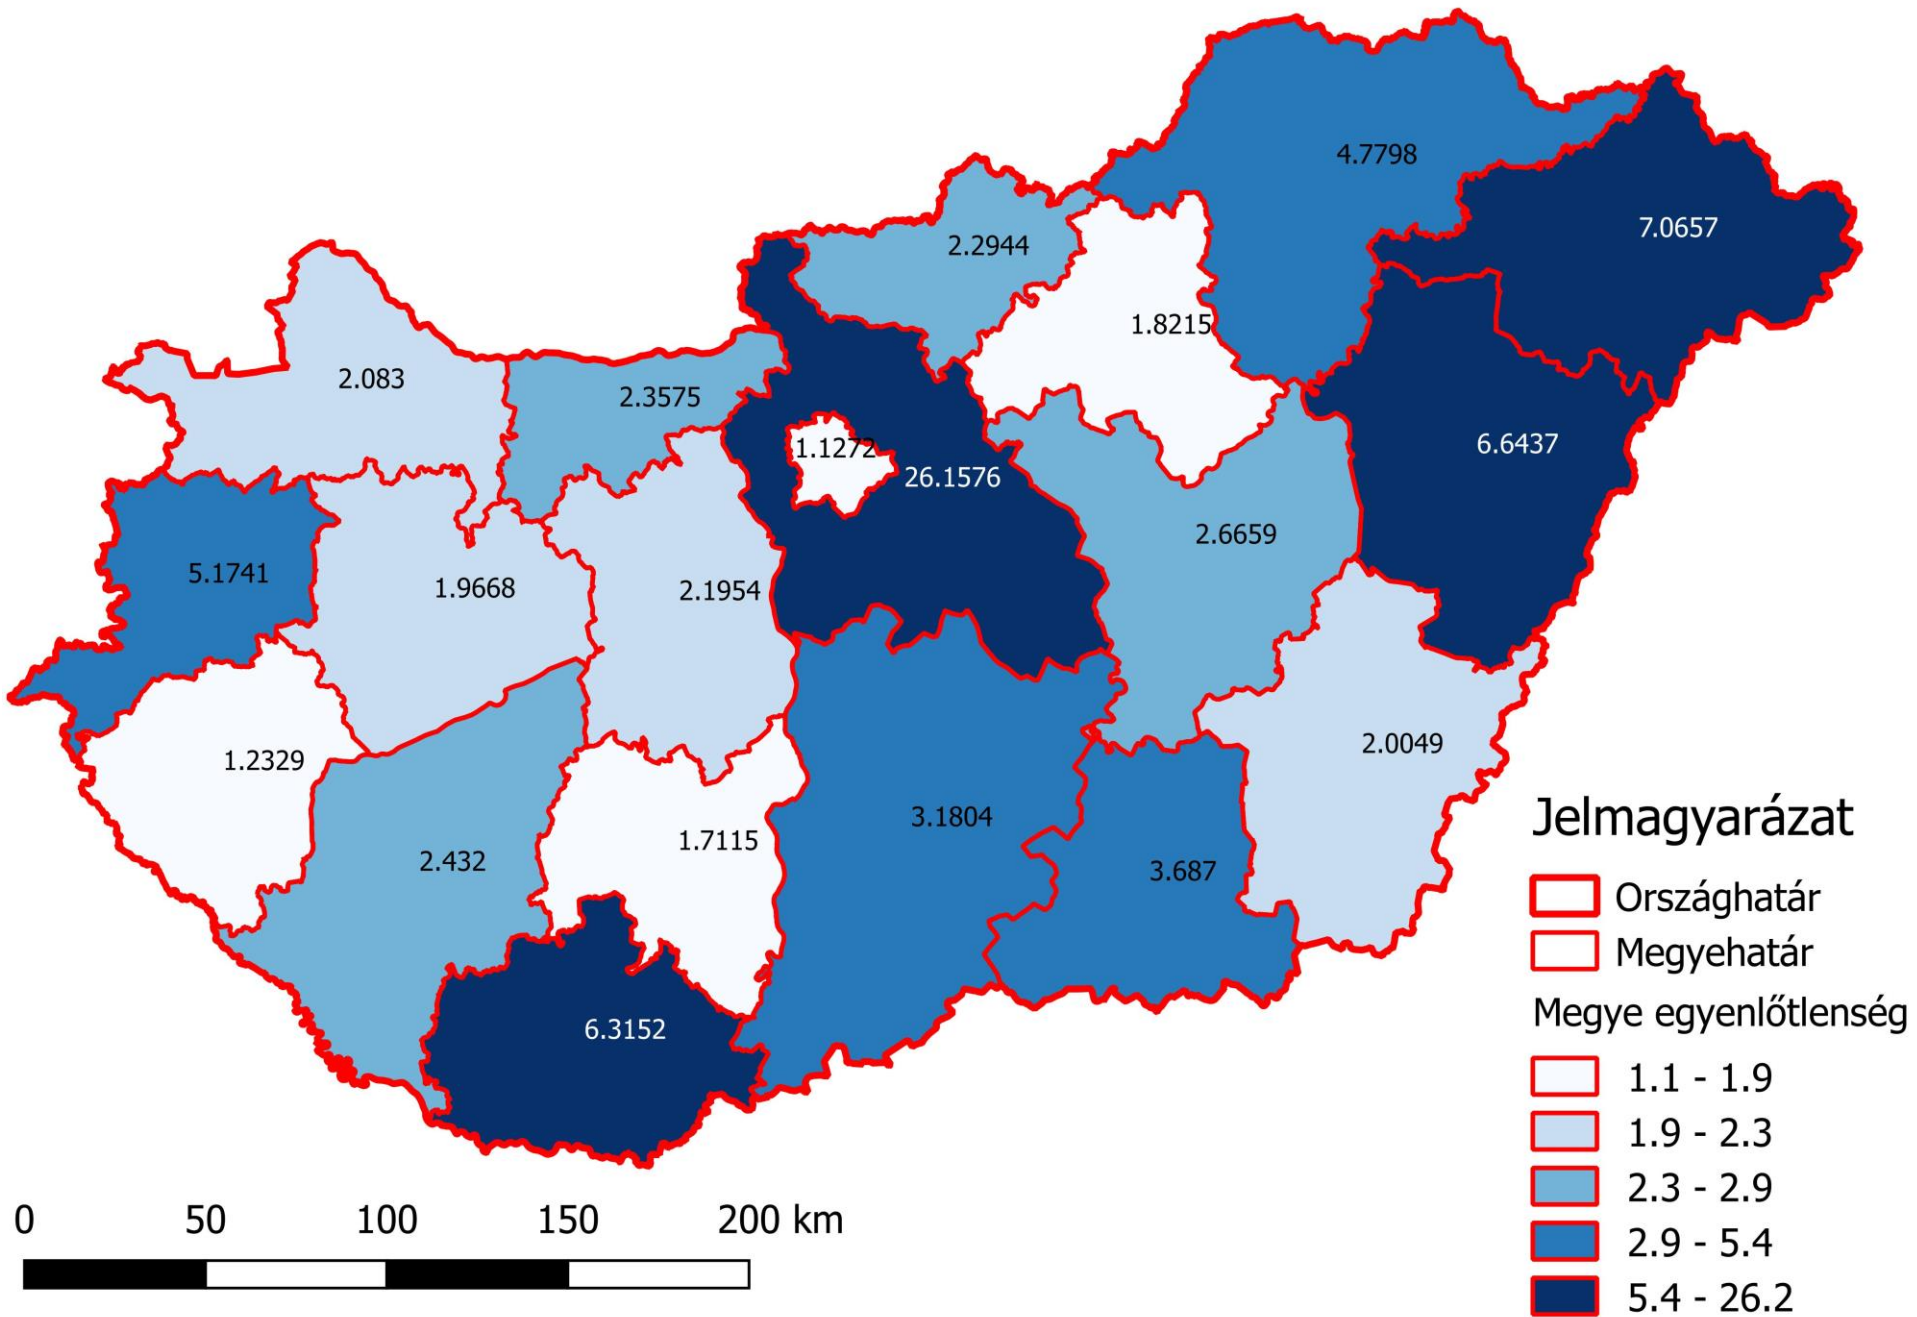
- Auerbach tétele alapján definiálható egy viszonyszám, amely a legnagyobb és a második legnagyobb település lakosságának az aránya (nevezzük egyszerűen arányszámnak)
- Ez mintegy „vízfejségi mutató” jelenhetne meg egy adott területre



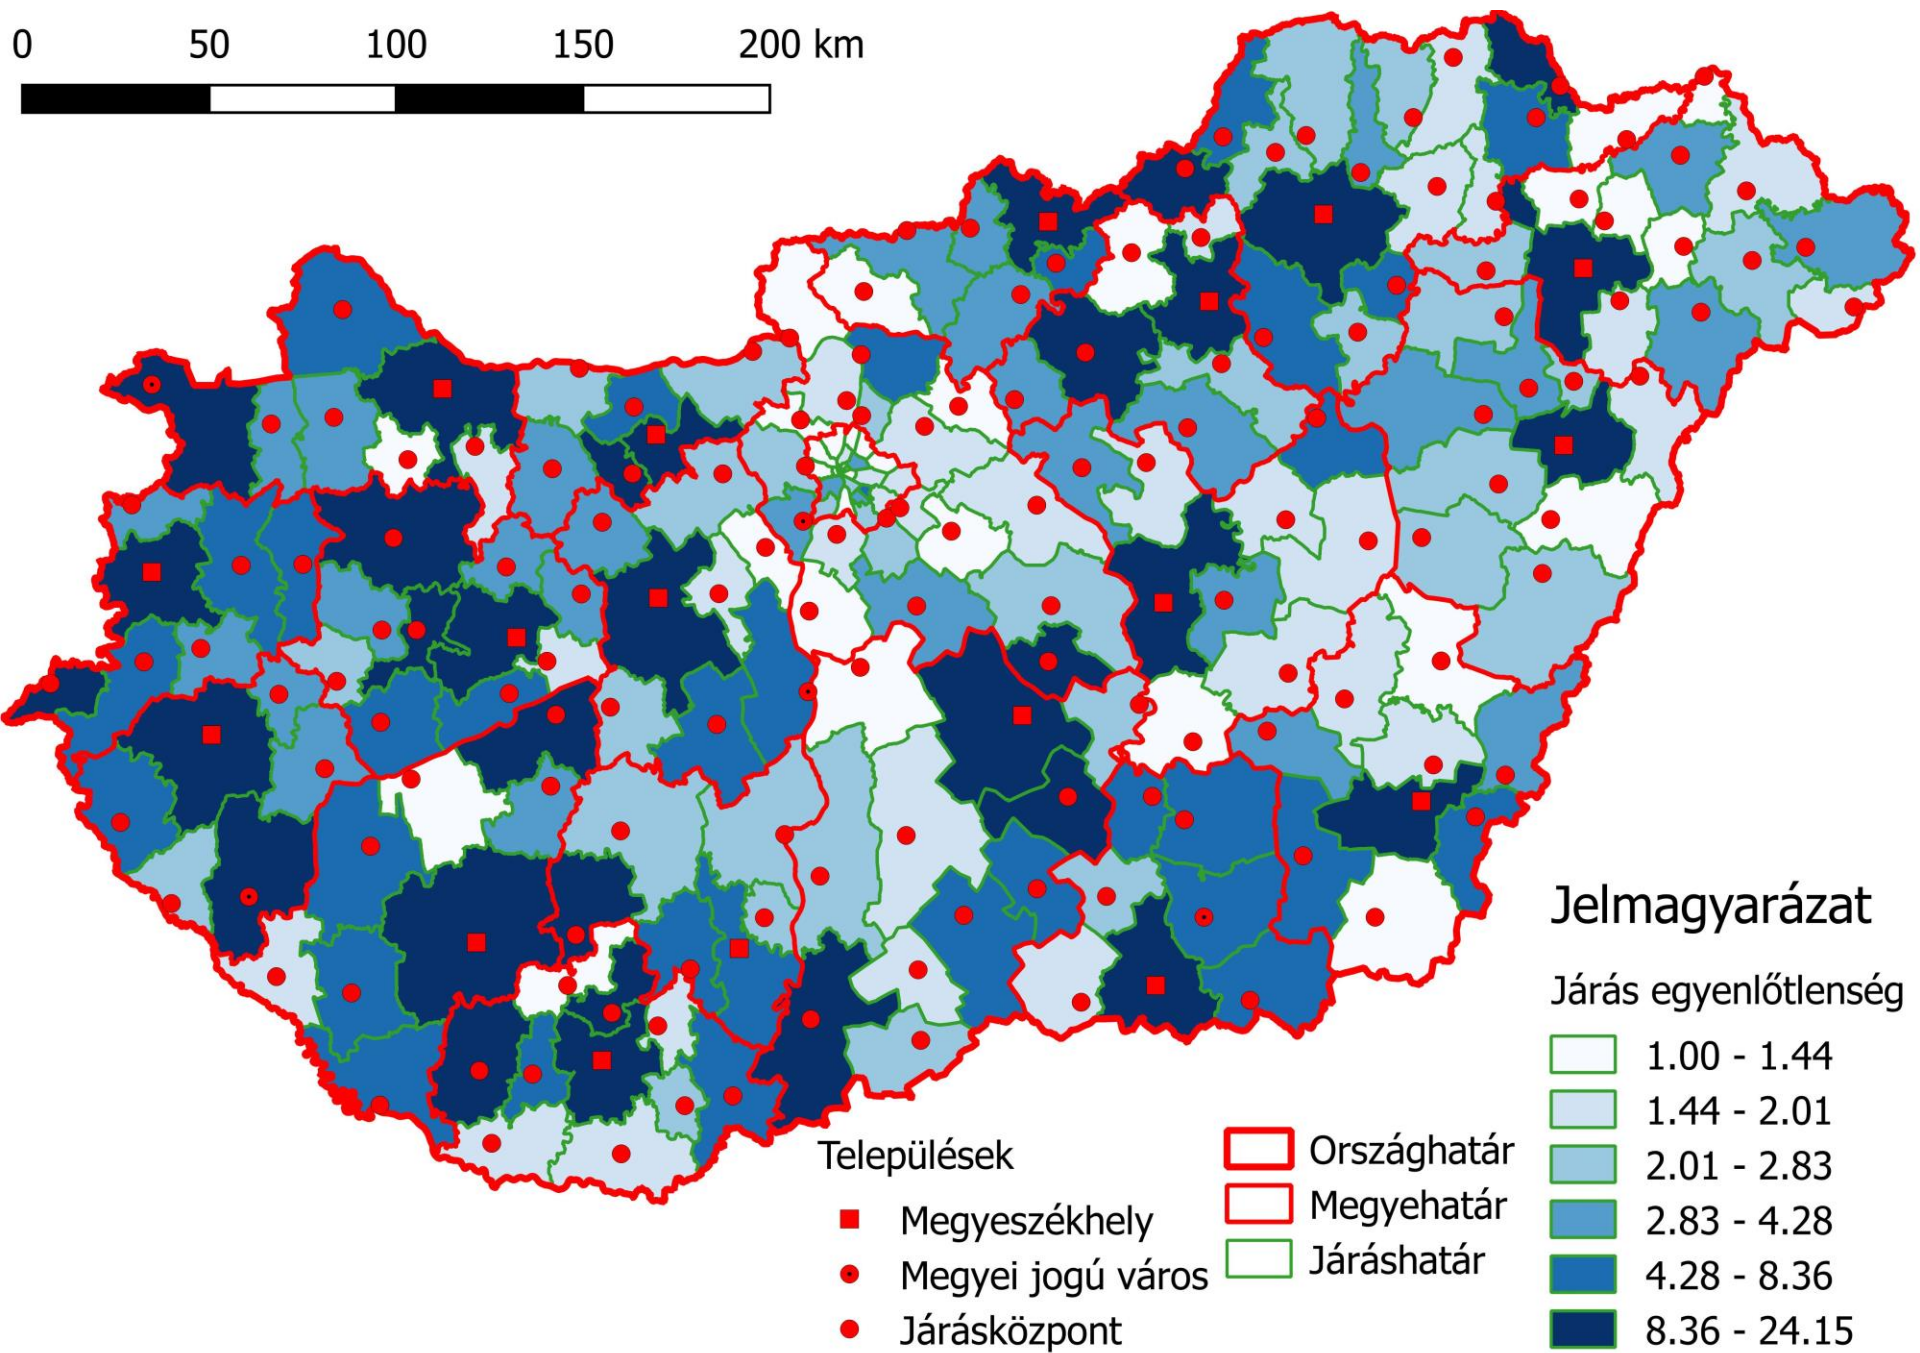








0 50 100 150 200 km



Nem normális eloszlás következményei

- u-próba -> Mann-Whitney próba
- t-próba -> Wilcoxon-próba
- F-próba -> Levene-próba



Térbeli koncentráció és szegregáció

- A térbeli egységek esetében fontos szerepe van a különböző koncentrációt és szegregációt mérő indexeknek
- Koncentráció: területi eloszlások egyenlőtlenségeit jelzik
 - Hirschmann–Herfindahl-index (Simpson-index)
 - Gini-mutató
 - Theil-index
- Szegregáció: két területi eloszlás különbözőségét mérik
 - Hoover-index



Simpson-index

$$HI = \sum_{i=1}^n \left(\frac{y_i}{\sum y_i} \right)^2$$

- Értéke:
 - $\frac{1}{n}$ a teljes egyenlőség esetén
 - 1 a tökéletes koncentrálttság esetén
- Mivel az értéke függ n értékétől ezért létezik normalizált alakja

$$HI^* = \frac{HI - \frac{1}{n}}{1 - \frac{1}{n}} \in [0; 1]$$



Gini-mutató

$$G = 1 - \sum [(f'_{r_i} - f'_{r_{i-1}})(Z'_{r_i} + Z'_{r_{i-1}})]$$

- $G \in [0..1]$
 - $G = 0$ – teljes egyenlőség
 - $G = 1$ – teljes egyenlőtlenség
 - $G \geq 0,4$ – jelentősebb egyenlőtlenség



Theil-index

- A Theil-index az általános entrópia index egy speciális esete

$$T = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i}{\bar{y}} \ln \frac{y_i}{\bar{y}} \right)$$

- Ha $T = 0$, ha teljes egyenlőség van
- Ha $T = \ln n$, akkor tökéletes koncentrálttság áll fenn



Hoover-index

- Számos neve van
 - Schutz-index
 - Robin Hood-index (Rózsa Sándor-index)
 - Duncan-index
 - Krugman-index (2-vel osztás nélkül)
- Jelentése: az y ismérv hány százalékát kell átcsoportosítani, hogy megegyezzen az x területegységével

$$H = \frac{\sum_{i=1}^n \left| \frac{x_i}{\sum x_i} - \frac{y_i}{\sum y_i} \right|}{2}$$




A Lorenz-görbe, a Hoover-index és a Gini-együttható összefüggése

A Lorenz-görbe, a Hoover-index és a Gini-index grafikus interpretációja és a közöttük lévő kapcsolat

Gini-index

(A Lorenz-görbe és az átló közötti terület és a fél négyzet



Lorenz-görbe

(Az összevetett jellemzőknek az x_i/f_i arány növekvő sorrendjében kumulált eloszlásgörbéje)

x_i


Hoover-index

(A Lorenz görbe és az átló közötti maximális függőleges távolság hossza)




ABC elemzés

- A logisztika területén alkalmazott mutató
- Alapja a Pareto-elv, vagyis hogy a következmények 80%-a az okok 20%-ra vezethetőek vissza
- Az egyes „termékek” három csoportba oszthatók:
 - A: Ide tartozik a forgalom 80%-a, míg az egyedek 20%-a
 - B: Ide tartozik a forgalom 15%-a, míg az egyedek 30%-a
 - C: Ide tartozik a forgalom 5%-a, míg az egyedek 50%-a




<http://sim.uw.hu/keszletgazdalkodas/index.html?page=16>





■ A ■ B ■ C



Jelmagyarázat

ABC-elemzés

A

B

C

Tartalom

Térstatisztika



Térbeli interakciók



Gravitációs modell



Geográfia első tétele

- Waldo R. Tobler (1930-2018) amerikai-svájci geográfus (1970)
 - Everything is related to everything else, but near things are more related than distant things
 - A világon minden mindennel összefügg, de a közelebbi dolgok jobban hatnak egymásra



Geográfia második tétele

- Waldo R. Tobler (1930-2018) amerikai-svájci geográfus (1999)
 - The phenomenon external to an area of interest affects what goes on inside
 - Egy adott területen belül lévő folyamatokra hatnak a területen kívüli folyamatok



Távolságszámítás

- Egyedek adottak a koordinátáik alapján ($A(A_1; A_2)$, $B(B_1; B_2)$)

- Pitagorasz-tétel megkötései

- Gömbi koszinusz-tétel:

$$\cos c = \cos a \cos b + \sin a \sin b \cos \gamma$$

- Gömbháromszög – két csúcsa a két pont, a harmadik az északi sark

$$a = 90^\circ - B_1$$


$$b = 90^\circ - A_1$$

$$\gamma = |A_2 - B_2|$$


- A két pont távolsága: $d(i, j) = cR$, ahol $R = 6380km$




Hálózati távolság és légvonaltávolság



Időtávolság és hálózati távolság



Időtávolság és légvonaltávolság



Legközelebbiszomszéd-index

- Területi index amely a települések mintázatát hasonlítja össze egy elméleti véletlenszerű eloszlással

$$R = \frac{D_{obs}}{D_{exp}}$$

– ahol:

- D_{obs} : az összes város, és a hozzá legközelebb lévő város távolságának az átlaga
- $D_{exp} = \frac{1}{2\sqrt{A}}$ várható átlagos távolság véletlenszerű eloszlás esetén, ahol A az 1 km²-re jutó városok száma, tehát $[A] = \text{város}/\text{km}^2$

- Ha

- $R = 0$ akkor minden város egy pontban koncentrálódik
- $R = 1$ akkor a települések véletlenszerűen oszlanak el
- $R < 1$ akkor koncentrált elhelyezkedés figyelhető meg
- $R > 1$ akkor szétszórt vagy szabályos elhelyezkedésről beszélhetünk



Távolság-hanyatlás görbék

- A geográfia első törvényéből adódik, hogy a kölcsönhatás erőssége a távolság növekedésével csökken
- Ezen kapcsolat leírására szolgál a Pareto-függvény


$$F = aD^{-b}$$

– Ahol

- F : kölcsönhatás erőssége
- D : távolság
- a és b : együtthatók
- A legérdekesebb kérdés b értéke
- Gyakorlatban $b = 2$ alkalmazandó leggyakrabban
- Svéd kutatók migráció elemzése során $b \in [0,4..3,3]$ értéket tapasztaltak 1,94 középpértékkel
- Példa: Debrecenbe naponta ingázók száma az egyes településekből Hajdú-Bihar, valamint a szomszédos megyékből



Debrecenbe ingázók aránya az elingázókon belül
(logaritmikus skála)



Távolság kilométerben illetve percben (logaritmikus skála)

- Távolság [km]
- Távolság [min]
- Hatvány (Távolság [km])
- Hatvány (Távolság [min])

Tartalom

Térstatisztika



Térbeli interakciók



Gravitációs modell



Bevezetés

- A gravitációs modellek esetében a távolsághanyatlás görbéknél megismert a paramétert vizsgáljuk tovább
- Ehhez bevonjuk a vizsgálatba a két végpontot, vagyis a kiinduló, valamint a célállomást
- Az elemzés alapja pedig egy fizikai törvényszerűség



Gravitációs modellek

- A távolság-hanyatlás görbéknél láthattuk, hogy a kapcsolat kitevőjének középértéke 2 körül alakul (1,94)
- Ez azért érdekes, mert összhangban van a Newton-féle gravitációs összefüggéssel

$$\mathbf{F} = -\gamma \frac{m_1 m_2}{r^3} \mathbf{r}$$

- \mathbf{F} : tömegvonzási erő
- m_1, m_2 : a két test tömege
- r : a két test közti távolság (\mathbf{r} értelemszerűen a távolságvektor, amely ellentétes irányú a tömegvonzási erő vektorával)
- γ : Newton-féle gravitációs együttható
($\gamma = 6,67259 * 10^{-11} \frac{Nm^2}{kg^2}$)



Gravitációs modellek

- Gyakorlatban, ha nem vektorokkal, csak a nagyságukkal számolunk, akkor

$$F = \gamma \frac{m_1 m_2}{r^2} = \gamma m_1 m_2 r^{-2}$$

- Ezt általánosíthatjuk
 - Valamilyen kölcsönhatást, vagy térbeli igényt feltételezünk (legyen U) (például utazási igény)
 - Valamilyen térbeli egységre (i) jellemző súlyt definiálunk (m_i) (például lakosság szám, GDP)
 - Valamilyen távolságot definiálunk (r) (például légvonalbeli, közúti, eljutási idő)
 - Adódik egy együttható (legyen γ)



Gravitációs modellek

- Háromféle megközelítés alkalmazható
 - Csak az együttható értékét becsüljük, a többi adottnak tekintjük
 - Ekkor $y = bx$ konstans tag nélküli lineáris függvényt kell becsülni
 - Az együtthatót és a távolság kitevőjét becsüljük
 - Ebben az esetben a kölcsönhatás iránya nem számít
$$U = \gamma(m_1 m_2)^{\beta_1} r^{\beta_2} \rightarrow \ln U = \ln \gamma + \beta_1 \ln(m_1 m_2) + \beta_2 \ln r$$
 - A nyíl utáni egyenlet lineáris regresszióként becsülhető
 - Mindent becsülünk
 - Ebben az esetben a kölcsönhatás iránya számít
 - Logaritmizálás után a következő egyenlet adódik, mely lineáris regresszióként becsülhető
$$\ln U = \ln \gamma + \beta_1 \ln m_1 + \beta_2 \ln m_2 + \beta_3 \ln r$$



Egyéb tényezők figyelembevétele

- A klasszikus felírásból kiindulva megfigyelhető, hogy a modell alakja zárt, nehéz más tényezők figyelembevétele
- Azonban az együttható alkalmazása lehetővé tesz egyéb magyarázóváltozók (x_4, x_5 stb.) figyelembevételét

- $! U = \gamma m_1^{\beta_1} m_2^{\beta_2} r^{\beta_3}$

- $! x_4$ és x_5 két magyarázóváltozó amely döntően befolyásolja U értékét

$$\ln U = \alpha + \beta_1 \ln m_1 + \beta_2 \ln m_2 + \beta_3 \ln r + \beta_4 x_4 + \beta_5 x_5$$

- Ebben az esetben

$$\gamma = f(\alpha, x_4, x_5) = e^\alpha x_4^{\beta_4} x_5^{\beta_5}$$



Gyakorlati példa – Velencei-tó

- Projekt – Velencei-tó környezetében megfigyelhető napi ingázás
- Népszámlálási adatokból tudjuk a járásközpontokba (Bicske, Szfv., Gárdony, Martonvásár) valamint Budapestre ingázók számát
- Ebből teljes OD mátrixot becslünk kétféle becselőmodellel



Modellek

$$U = e^{\alpha} (m_1 m_2)^{\beta_1} r^{\beta_2} c^{\beta_3} h^{\beta_4} j^{\beta_5}$$

$$\ln U = \alpha + \beta_1 \ln(m_1 m_2) + \beta_2 \ln r + \beta_3 \ln c + \beta_4 \ln h + \beta_5 \ln j$$

$$U = e^{\alpha} m_1^{\beta_1} m_2^{\beta_2} r^{\beta_3} c^{\beta_4} h^{\beta_5} j^{\beta_6}$$

$$\ln U = \alpha + \beta_1 \ln m_1 + \beta_2 \ln m_2 + \beta_3 \ln r + \beta_4 \ln c + \beta_5 \ln h + \beta_6 \ln j$$

- Ahol:

- U : ingázók száma
- m_1 : kiinduló település lakosság száma
- m_2 : érkező település lakosság száma
- c : a kiinduló és az érkező település rangjának hányadosa
- h : érintett megyék száma
- j : érintett járások száma




Paraméterbecslés

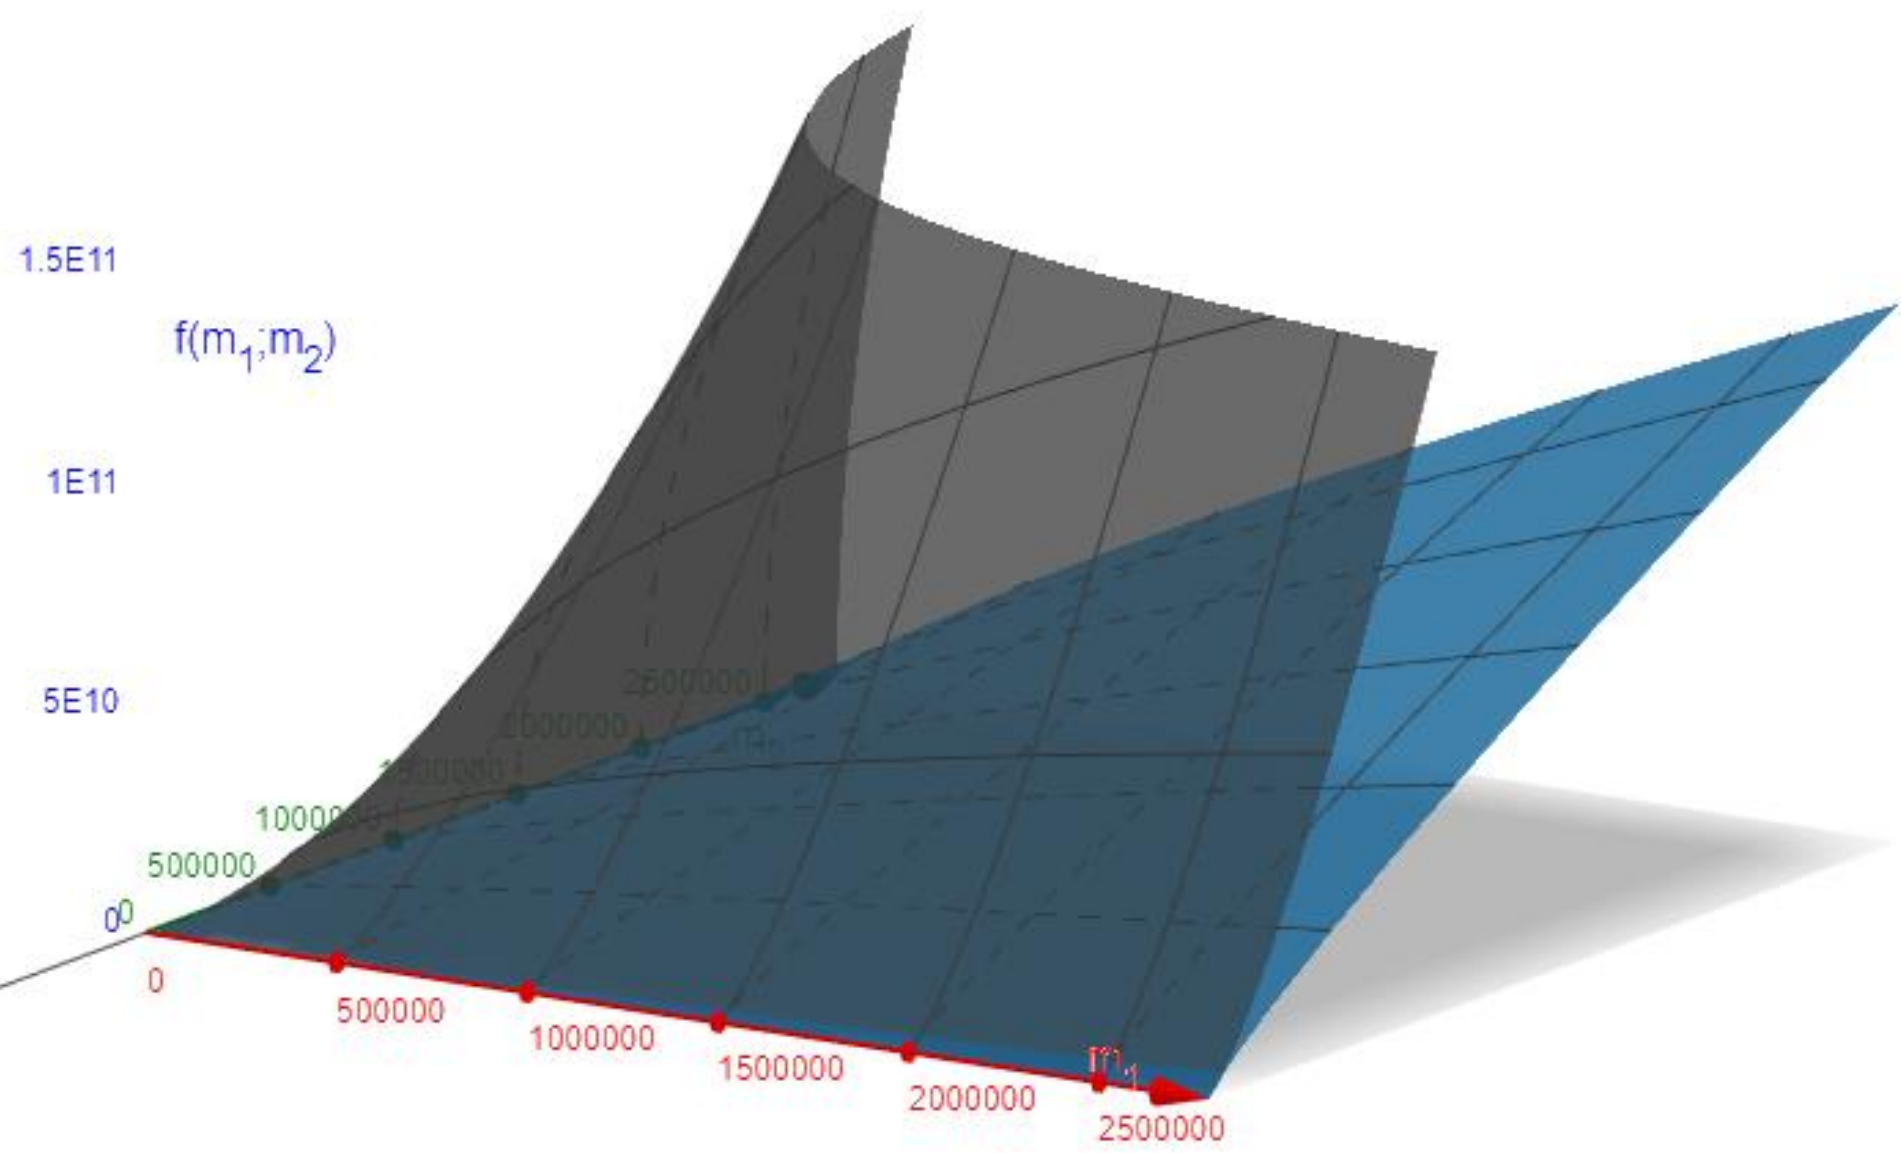
Tengelymetszet	-3,9847 [-2,4811] *
$\ln(m_1 m_2)$	0,8598 [12,8762] ***
$\ln r$	-1,9787 [-8,0645] ***
$\ln c$	0,9401 [5,6546] ***
$\ln j$	-1,3894 [-3,9133] ***
$\ln h$	-1,9247 [-3,0264] **
R-négyzet	0,8079
Standard hiba	0,9449
F-próba	[91,7085] ***

Tengelymetszet	-5,1249 [-3,2970] *
$\ln m_1$	0,5372 [4,9362] ***
$\ln m_2$	1,2872 [9,6573] ***
$\ln r$	-2,0220 [-8,6816] ***
$\ln c$	-0,5910 [-1,3170]
$\ln j$	-1,3588 [-4,0356] ***
$\ln h$	-1,8762 [-3,1112] **
R-négyzet	0,8290
Standard hiba	0,8958
F-próba	[87,2461] ***



Modellenkénti BETA mutatók





Ellenőrző kérdések

- Milyen statisztikai szempontú fenntartásaink lehetnek a téradatokkal kapcsolatosan?
- Milyen következményei vannak az adatok nem normális eloszlásának?
- Mit mond ki a geográfia első tétele?
- Mi a gravitációs modell? Hogy lehet az együtthatókat becsülni, és mi ennek az oka?



KÖSZÖNÖM A MEGTISZTELŐ FIGYELMÜKET!

Dr. Sipos Tibor
Dr. Török Ádám
Szabó Zsombor



KUKG



BUDAPESTI MŰSZAKI ÉS GAZDASÁGTUDOMÁNYI EGYETEM
Közlekedésmérnöki és Járműmérnöki Kar