


# Többváltozós statisztika elméleti alapjai (BMNPS07500M)

Készítette: Soltész-Várhelyi Klára

Lineáris regresszió

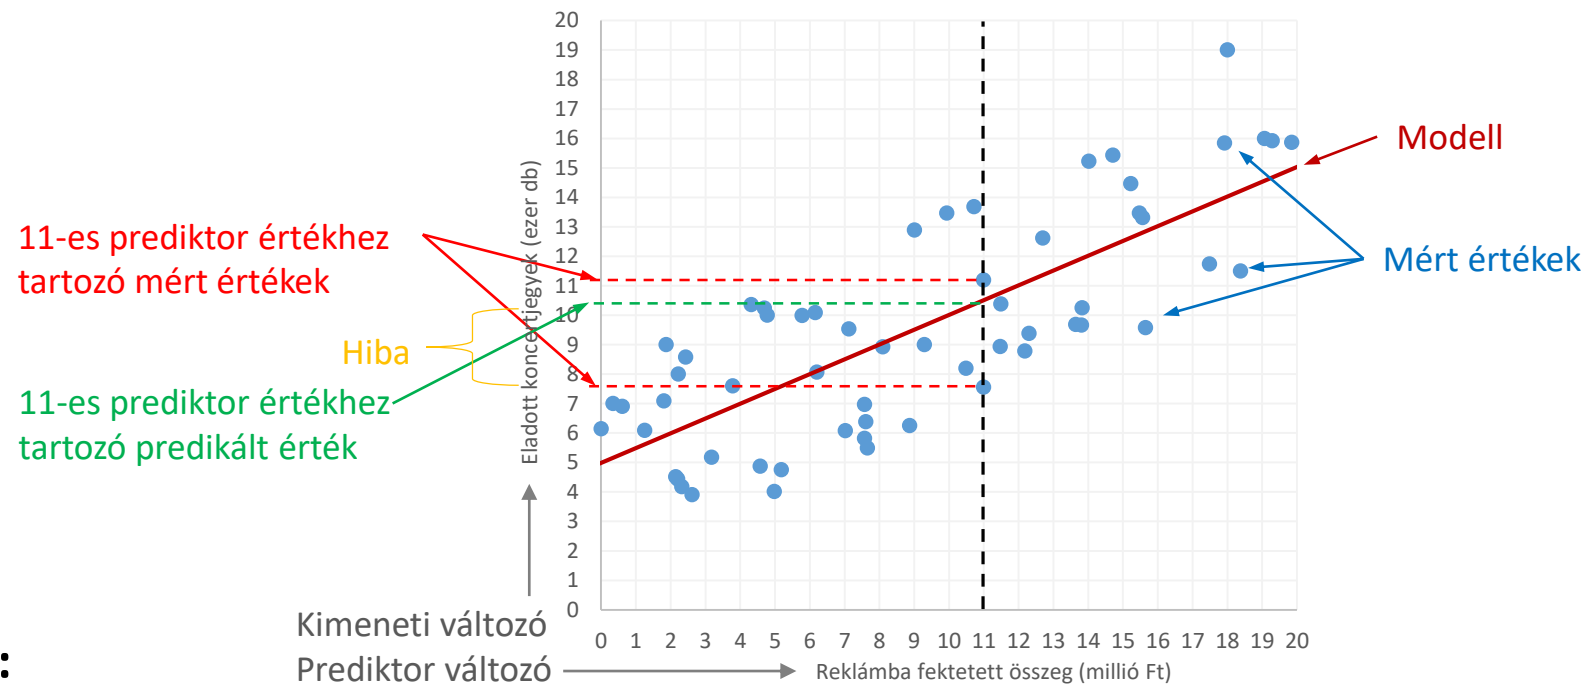
1. Egyszerű lin. reg. elméleti háttere

# Elmélet



# Lineáris Regresszió

- Modellt építünk a mért adatainkra, majd a modell segítségével megpróbáljuk a független változókból bejósolni a függőt
  - **Kimeneti érték** = **Modell** segítségével a **prediktor érték**ből **predikált érték** + **hiba**




- **Típusok:**

- **Egyszerű lineáris regresszió:** egyetlen független (prediktor) változóból próbáljuk megjósolni a függő (kimeneti) változót
- **Többszörös lineáris regresszió** (multiple) – több független változóból jósoljuk meg a függő változót.


# Lineáris Regresszió

- **Lineáris** regresszió – mert a modellünk alapja egy egyenes
  - Egy egyenes két adattal (paraméterrel) írható le – a regressziós elemzésben ezeket a nevezzük a két regressziós együtthatónak (koefficiensnek)
    - **Meredekség (b1)** – egységnyi változás x-ben mekkora változást okoz y-ban
    - **Konstans (b0)** – mi a kezdőpont, hol metszi az egyenes az y tengelyt
  - Egyenlet matekóráról:  $y = b_0 + b_1 * x$

Azonos konstans (b0),  
de eltérő meredekség (b1)



Azonos meredekség (b1),  
de eltérő konstans (b0)



# Lineáris Regresszió


- A lineáris regresszió egyenlete:

- **Predikált értékek** kiszámolhatóak a modell segítségével a prediktor értékekből a következő egyenlettel:

$$Y_{\text{pred},i} = b_0 + b_1 * X_i$$


- A **mért értékek** és **predikált értékek közötti különbséget** nevezzük a predikció vagy a **modell hibájának**:

$$Y_i = Y_{\text{pred},i} + \varepsilon_i = b_0 + b_1 * X_i + \varepsilon_i$$



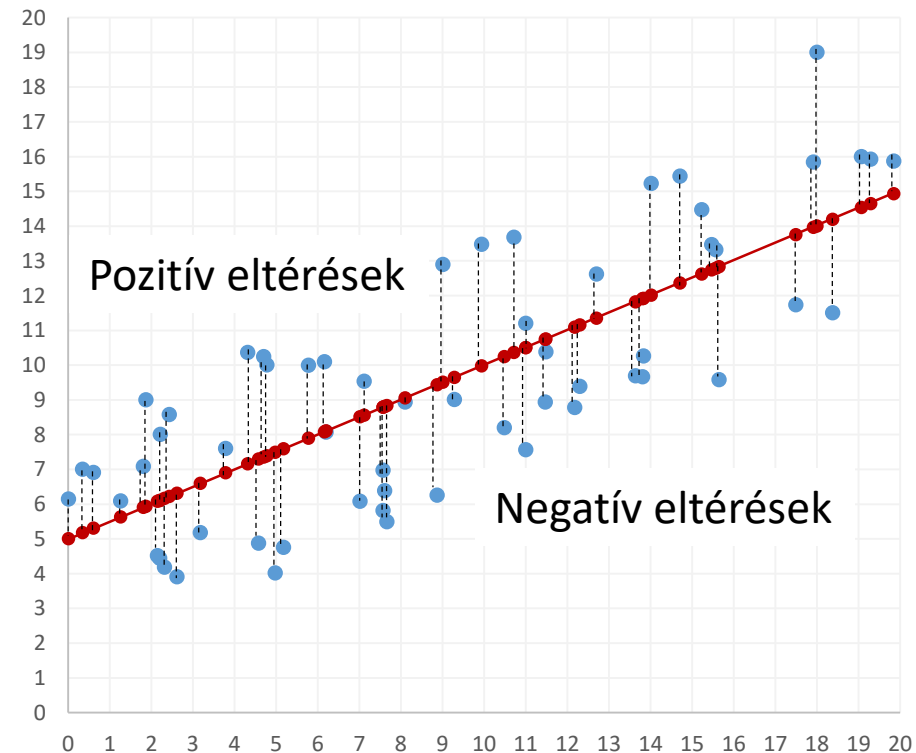
# Legkisebb négyzetek módszere

- Egy adatsorra nagyon sok modell (nagyon sok egyenes) fektethető, ezek közül azt keressük, amelyik legjobban illik az adatokhoz (legjobban leírja azokat)
  - Keressük meg a **pontfelhő középpontját**, ezen biztosan átmegy az egyenes
  - Válasszuk ki az ezen átmenő egyenesek közül azt, mely a **legkisebb hibával jár**
    - Sok becslési mód létezik, de legelterjedtebb közülük a **legkisebb négyzetek módszere** (ordinary least squares, OLS)
      - (a módszert a 24 éves(!) Gauss alkotta meg a Ceres törpebolygó pályájának leírására)



# Legkisebb négyzetek módszere

- Azt a modellt keressük, amelyik legjobban illik az adatokhoz, másként megfogalmazva, ahol a legkisebb a különbség a ténylegesen mért adatok és predikált értékek (ergo az egyenesünk) között
- Eltérés mérése:
  - **Reziduális hiba** (angolul residuals): Eltérés a predikált értékek (egyenes) és a mért adatok között
  - **Reziduális hibák négyzetösszege** (angolul sum of squared residuals,  $SS_R$ ): a predikált és mért értékek távolsága, a pontatlanság mértéke



- **Megtaláltuk a lehető legjobb modellt, de mennyire jó az?**

- **Effect-size:**

- A függő változó értékeit mennyire tudjuk megmagyarázni a prediktor változó(k)kal (a függő változó varianciáját hány százalékban tudjuk magyarázni)
- *A hatás nagyságát írja le*

$$\text{effect size} = \frac{\text{megmagyarázott változatosság}}{\text{teljes változatosság}}$$

- **Statisztikai érték:**

- A hatás és hiba aránya (a modell segítségével megmagyarázható rész és meg nem magyarázható rész aránya)
- *A hatás valószínűségének becsléséhez szükséges*

$$\text{statisztikai érték} = \frac{\text{hatás}}{\text{hiba}}$$


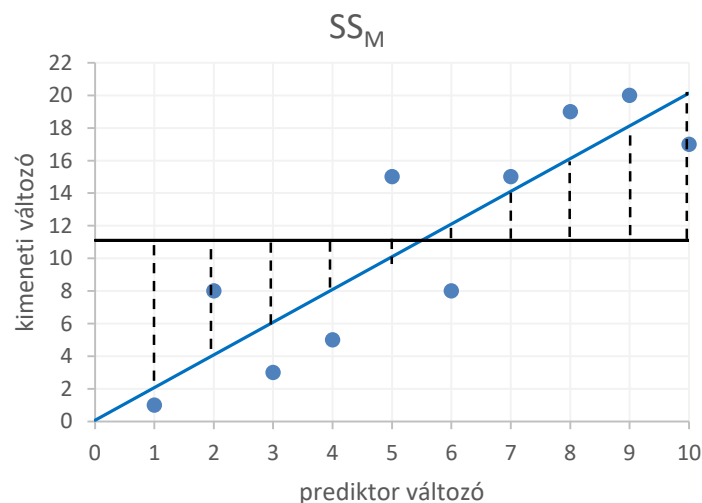


- **Effect-size:**

- A kimeneti változó értékeit milyen mértékben tudjuk megmagyarázni a prediktor változó(k)kal
- a függő változó varianciáját hány százalékban tudjuk magyarázni

$$\text{effect size} = \frac{\text{megmagyarázott változatosság}}{\text{teljes változatosság}} = R^2 = \frac{SS_M}{SS_T}$$

- **SS<sub>M</sub>** = sum of squares of model – a predikált értékek átlagtól való távolsága
- **SS<sub>T</sub>** = sum of squares of total – a mért értékek átlagtól való távolsága





- **Statisztikai érték :**

- A hatás és hiba aránya - a modell segítségével megmagyarázható és nem magyarázható rész aránya




$$\text{statisztikai érték} = \frac{\text{hatás}}{\text{hiba}} = F = \frac{MS_M}{MS_R} = \frac{\frac{SS_M}{df_M}}{\frac{SS_R}{df_R}}$$

- $df_M$  = modell szabadságfoka – modell összetettsége, prediktorok száma
- $df_R$  = hiba szabadságfoka – elemszám minusz becsült paraméterek száma
- $MS_M$  = átlagos hatása egy prediktor változónak – hatás
- $MS_R$  = átlagos pontatlanság a becslés során – hiba



# R<sup>2</sup> és F érték összegzése


- $R^2 = \frac{SS_M}{SS_T}$  és  $F = \frac{MS_M}{MS_R}$
- $SS_M + SS_R = SS_T$  – evidens, a teljes variancia felbontható megmagyarázott és meg nem magyarázott részre
- Egy prediktor esetén  $df_M = 1$ , mert egy prediktor van, és  $df_R = N - 2$ , mert a két becsült paraméter a konstans és a meredekség. Két prediktor esetén  $df_M = 2$ , mert két prediktor van, és  $df_R = N - 3$ , ahol a három paraméter a konstans és a két prediktorhoz tartozó dimenzióban a regressziós egyenes meredeksége
- Itt nem használtuk, de a  $df_T = N - 1$ , ahol az elemszámból kivonjuk az egyetlen összefüggést az átlagot. Az  $MS_T$  a függő változó varianciájával lenne egyenlő – gondold végig miért
- Az elnevezésekből több verzió is van, és szerencsétlenül félreérthetőek:  
 $SS_M = ESS$  (explained sum of squares) =  $SSR$  (sum of squares of regression)  
 $SS_R = RSS$  (residual sum of squares) =  $SSE$  (sum of squares of errors)



# Regressziós együtthatók

- A **b<sub>0</sub> regressziós együttható** megadja, hogy mennyi lenne a kimeneti változó értéke, ha (minden) prediktor értéke 0 lenne, ez az y tengely metszéspontja
- A **b<sub>1</sub> regressziós együttható** megadja, hogy a prediktor változó egységnyi változása mekkora változást hoz létre a kimeneti változóban
  - A meredekségekhez tartozik egy SE érték is, mely megadja a paraméter bizonytalanságát
  - A regressziós egyenes vízszintes lesz (tehát b<sub>1</sub> = 0) akkor, ha a prediktor változó változásának nincs hatása a kimeneti változóra – ergo a legjobb predikció, amit tehetünk, a kimeneti változó átlaga
  - Feltételezhetjük, hogy egy prediktornak hatása van a kimeneti változóra, ha a meredekség szignifikánsan eltér a nullától

- Ezt t-teszttel ellenőrizzük: 
$$t = \frac{b_{mért} - b_{nullhip}}{SE_b} = \frac{b_{mért}}{SE_b}$$



# Regressziós együttthatók

- A  $b_1$  regressziós együtttható megadja, hogy a prediktor változó egységnyi változása mekkora változást hoz létre a kimeneti változóban
  - Ha egy prediktor változó van, a helyzet egyértelmű
  - Több prediktor változó esetén kérdés lehet, melyiknek van nagyobb hatása – ekkor az összehasonlítást a standardizált regressziós koefficiensek mentén lehet elvégezni
- **$b_1$  – standardizálatlan regressziós koefficiens**
  - Ezek segítségével a prediktorok nem hasonlíthatóak össze, hiszen a prediktorok nem feltétlen ugyanolyan skálán mérődnek
  - Pl. reklámba fektetett összeg  $b_1=0,5$  tehát a reklámba fektetett plusz egy millió Forint ötvenezerrel növeli meg az eladott koncertjegyek számát (btw a reklámokba semmitől egészen húszmillióig szoktak pénzt fektetni). A banda népszerűsége  $b_1=1,5$  tehát ha a 6-fokú Likert-skálán a banda népszerűsége eggyel nagyobb, akkor ezerötszázzal több jegy fogy. Melyiknek van nagyobb hatása?
- **$\beta_1$  – standardizált regressziós koefficiens**
  - A meredekség **skála független** mérőszáma – ezek alapján már összehasonlíthatóak a prediktorok
  - Sőt! A meredekségekhez kiszámolt konfidencia intervallumok segítségével az is megállapítható, két prediktor hatása között szignifikáns-e a különbség (gyakorlaton megnézzük, hogyan)


# Regressziós egyenes egyenlete

- A regressziós egyenes képlete:  $Y_{\text{pred},i} = b_0 + b_1 * X_i$  és a kimeneti változó értéke:  $Y_i = Y_{\text{pred},i} + \epsilon_i$
- A regressziós elemzésből tudjuk, hogy  $b_0 = 5$  és  $b_1 = 0,5$

Azonosító	Prediktor (X)	Kimeneti (Y)	Predikált ( $Y_{\text{pred}}$ )	Hiba ( $\epsilon$ )
1	4,78	10	7,39	2,61
2	6,16	10,09	8,08	2,01
3	1,87	9	5,935	3,065
4	15,65	9,575	12,825	-3,25
5	13,81	9,665	11,905	-2,24
6	14,02	15,22	12,01	3,21
7	15,47	13,465	12,735	0,73
8	12,7	12,62	11,35	1,27
9	3,79	7,6	6,895	0,705
10	7,61	6,385	8,805	-2,42
11	7,12	9,53	8,56	0,97
12	0,35	7	5,175	1,825
13	15,57	13,315	12,785	0,53
14	2,62	3,91	6,31	-2,4
15	2,15	4,515	6,075	-1,56
16	...	...	...	...

$$Y_{\text{pred},i} = 5 + 0,5 * X_i$$

$$\epsilon_i = Y - Y_{\text{pred},i}$$




# Regressziós egyenes egyenlete

- A regressziós egyenes képlete:  $Y_{\text{pred},i} = b_0 + b_1 * X_i$  és a kimeneti változó értéke:  $Y_i = Y_{\text{pred},i} + \epsilon_i$
- A regressziós elemzésből tudjuk, hogy  $b_0 = 5$  és  $b_1 = 0,5$

Azonosító	Prediktor (X)	Kimeneti (Y)	Predikált ( $Y_{\text{pred}}$ )	Hiba ( $\epsilon$ )
1	4,78	10	7,39	2,61
2	6,16	10,09	8,08	2,01
3	1,87	9	5,935	3,065
4	15,65	9,575	12,825	-3,25
5	13,81	9,665	11,905	-2,24
6	14,02	15,22	12,01	3,21
7	15,47	13,465	12,735	0,73
8	12,7	12,62	11,35	1,27
9	3,79	7,6	6,895	0,705
10	7,61	6,385	8,805	-2,42
11	7,12	9,53	8,56	0,97
12	0,35	7	5,175	1,825
13	15,57	13,315	12,785	0,53
14	2,62	3,91	6,31	-2,4
15	2,15	4,515	6,075	-1,56
16	...	...	...	...

$$Y_{\text{pred},1} = 5 + 0,5 * 4,78 = 7,39$$

$$\epsilon_1 = Y - Y_{\text{pred},1} = 10 - 7,39 = 2,61$$




# Regressziós egyenes egyenlete

- A regressziós egyenes képlete:  $Y_{\text{pred},i} = b_0 + b_1 * X_i$  és a kimeneti változó értéke:  $Y_i = Y_{\text{pred},i} + \epsilon_i$
- A regressziós elemzésből tudjuk, hogy  $b_0 = 5$  és  $b_1 = 0,5$

Azonosító	Prediktor (X)	Kimeneti (Y)	Predikált ( $Y_{\text{pred}}$ )	Hiba ( $\epsilon$ )
1	4,78	10	7,39	2,61
2	6,16	10,09	8,08	2,01
3	1,87	9	5,935	3,065
4	15,65	9,575	12,825	-3,25
5	13,81	9,665	11,905	-2,24
6	14,02	15,22	12,01	3,21
7	15,47	13,465	12,735	0,73
8	12,7	12,62	11,35	1,27
9	3,79	7,6	6,895	0,705
10	7,61	6,385	8,805	-2,42
11	7,12	9,53	8,56	0,97
12	0,35	7	5,175	1,825
13	15,57	13,315	12,785	0,53
14	2,62	3,91	6,31	-2,4
15	2,15	4,515	6,075	-1,56
16	...	...	...	...

$$Y_{\text{pred},7} = 5 + 0,5 * 15,47 = 12,735$$

$$\epsilon_7 = Y - Y_{\text{pred},7} = 13,465 - 12,735 = 0,73$$





# Regressziós mutatók összegzése

- **Regresszió elemzés** konyhanyelven
  - A prediktor változó(k)ból megpróbáljuk bejósolni a kimeneti változót
  - A prediktorok változó változása részben magyarázza a kimeneti változó változását
- **$R^2$**  – effect size mutató
  - A kimeneti változóban változatosságának mekkora része magyarázható a prediktor változókkal
- **F** – statisztikai érték
  - milyen a hatás és hiba aránya
  - Az F-értékből számolható a szignifikancia értéke
- **b és hozzá tartozó t-próba** – a regressziós egyenes kezdőpontja és meredeksége
  - ha a független változó változása (növekedése/csökkenése) változást okoz a függő változóban (növekedést/csökkenést), akkor az egyenesnek van meredeksége.
  - T-próbával ellenőrizzük, hogy a meredekség szignifikánsan eltér-e a nullától

# Regressziós mutatók az életben

- **Standardizálatlan regressziós együtthatók**

- Ezek adja meg a regressziós egyenesünk kezdőpontját és meredekségét, tehát ez alapján tudjuk kiszámolni a predikcióinkat

- **R<sup>2</sup>, F érték és a hozzá tartozó szignifikanca**

- Ez alapján tudod eldönteni, mennyire megbízható az általad felépített modell, mennyire hihetsz a modell alapján tett predikcióknak

- **Standardizált regressziós együttható és t-próba**

- Több prediktor változó esetén ezek alapján döntesz, hogy melyik prediktor változók a leghasznosabbak számodra, melyek befolyásolják a kimeneti változót jelentős mértékben, melyekből lehet a kimeneti változó értékét leginkább bejósolni.




Két milliót akarok a reklámra fordítani, akkor várhatóan  $5 + 0,5 * 2 = 6$  ezer jegyet fogok eladni. Hmm... akkor a Copper Box a megfelelő méretű helyszín!



A modell elég megbízhatónak tűnik, ezért bátran lefoglalom a Copper Box-ot. Bízok benne, hogy meg fog telni!

A modell túl megbízhatatlan. Ha lefoglalom a CB-t, elég nagyot bukhatok. Kellene néhány jobb prediktor!




Úgy tűnik, ma már nem számít annyira, hányszor említi a zenekart a Metal Hammer, sokkal inkább, hogy hányan nézik meg youtube-on. Akkor az alapján számolom a predikciókat!

# Egyszerű lineáris regresszió



# Egyszerű lineáris regresszió

- Egyszerű lineáris regresszióról beszélünk, ha *egy* prediktor és *egy* kimeneti változó közötti lineáris összefüggést keressük
  - Az egyszerű lineáris regresszió megegyezik a Pearson korrelációs eljárással
- Próbáljuk meg bejósolni a reklámba fektetett összegből azt, hogy hány koncertjegyet sikerült eladni!
  - Feltételek: a lineáris regresszió feltételeit majd többszemponos esetben nézzük át, most elegendő a Pearson korreláció öt feltétele: skála típusú adatok, független kitöltők, normál eloszlás, homoszkedaszticitás (=szóráshomogenitás) és linearitás.




# Egyszerű lineáris regresszió

- A *Model Summary* és *ANOVA* tábla tartalmazza a modell „jóságának” mutatóit. Vesd össze az elméleti részben tanultakkal!

- $R^2 = \frac{SS_M}{SS_T}$  és  $F = \frac{MS_M}{MS_R}$

- $N = 59$



Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,780 <sup>a</sup>	<b>R<sup>2</sup> ,608</b>	,601	2,309072

a. Predictors: (Constant), Reklámba fektetett összeg (millió Forint)

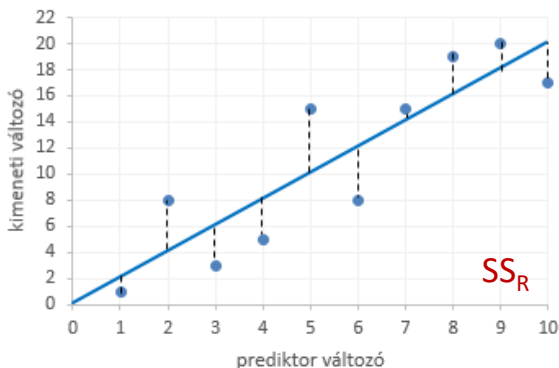


ANOVA<sup>a</sup>

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	<b>SS<sub>M</sub> 471,583</b>	<b>df<sub>M</sub> 1</b>	<b>MS<sub>M</sub> 471,583</b>	<b>F 88,447</b>	<b>,000000000000339<sup>b</sup></b>
	Residual	SS <sub>R</sub> 303,913	df <sub>R</sub> 57	MS <sub>R</sub> 5,332		
	Total	SS <sub>T</sub> 775,496	df <sub>T</sub> 58			

azaz  $\frac{339}{\text{billiárd}}$


a. Dependent Variable: Eladott koncertjegy (1000 db)

b. Predictors: (Constant), Reklámba fektetett összeg (millió Forint)



# Egyszerű lineáris regresszió

- A *Koefficiens* tábla tartalmazza a regressziós egyenes együtthatóit – ezáltal a prediktor változó(k) egyenkénti hatását a kimeneti változóra.  
Vesd össze az elméleti részben tanultakkal!
- A regressziós egyenes egyenlete:  $Y_{\text{predikált}} = b_0 + b_1 * x$
- A **b0** (a táblázatban a konstanshoz tartozó B érték) az  $x=0$ -hoz tartozó értéket adja meg (ahol az y tengelyt metszi az egyenes).
- A **b1** (a táblázatban a prediktor(ok)hoz tartozó B érték) az egyenes meredekségét adja meg standardizálatlan formában (a prediktor egységnyi változására kimeneti változóban bekövetkező változást)
- A b1-hez tartozó **SE** az egyenes meredekségének bizonytalanságát jelzi.



Coefficients<sup>a</sup>


Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	<b>B0</b> 4,983	,565		8,817	,00000000000307
	Reklámba fektetett összeg (millió Forint)	<b>B1</b> ,502	,053	,780	9,405	,00000000000339

a. Dependent Variable: Eladott koncertjegy (1000 db)

Többszemponos elemzésnél minden prediktor itt lesz felsorolva

# Egyszerű lineáris regresszió

- A *Koefficiens* tábla tartalmazza a regressziós egyenes együtthatóit – ezáltal a prediktor változó(k) egyenkénti hatását a kimeneti változóra.  
Vesd össze az elméleti részben tanultakkal!
- A  $\beta$  (táblázatban Beta) a standardizált meredekség, mely alapján több prediktor hatása összehasonlítható.
- A **t-próbával** és a hozzá tartozó szignifikanciával ellenőrizhetjük, hogy a meredekség szignifikánsan eltér-e nullától, azaz a prediktornak van-e szignifikáns hatása a kimeneti változóra



Coefficients<sup>a</sup>


Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	<b>B0</b> 4,983	,565		8,817	,000000000000307
	Reklámba fektetett összeg (millió Forint)	<b>B1</b> ,502	,053	,780	9,405	,0000000000000339

a. Dependent Variable: Eladott koncertjegy (1000 db)

Többszemponos elemzésnél minden prediktor itt lesz felsorolva

# Egyszerű lineáris regresszió

- Néhány megjegyzés:
  - Kapcsolat korrelációval
    - A *Model Summary* tábla R értéke megegyezik a Pearson-korrelációból kapható r-értékkal, hiszen az egyprediktoros lineáris regresszió „csupán” egy Pearson korreláció.
    - Az *ANOVA* tábla szignifikancia értéke is azonos a Pearson korreláció 2-tailed szignifikanciájával.
  - Kapcsolat F-érték és a b1 koefficiens között
    - Az *ANOVA* táblában a prediktorhoz tartozó t-próba t-értékének négyzete megegyezik az F értékkel, hiszen a  $df_M = 1$ .
    - Ennek gyakorlati jelentése az, hogy a kimeneti változó varianciájának modellel megmagyarázható részének egészéért az egy darab prediktor változó felelős.
    - Ez többszemponos elemzésben már nem lesz igaz – ott több prediktor hatásának eredője lesz a regressziós egyenes, melyhez az F-érték tartozik.



Correlations

		Eladott koncertjegy (1000 db)
Reklámba fektetett összeg (millió Forint)	Pearson Correlation	,780**
	Sig. (2-tailed)	,000000000000339
	N	59

\*\* . Correlation is significant at the 0.01 level (2-tailed).



# Gyakorló példák

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,469 <sup>a</sup>	,220	,186	7,32620

a. Predictors: (Constant), pred1

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	347,355	1	347,355	6,472	,018 <sup>b</sup>
	Residual	1234,485	23	53,673		
	Total	1581,840	24			


a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred1

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	25,175	4,471		5,631	,000
	pred1	,199	,078	,469	2,544	,018

a. Dependent Variable: kimeneti



# Gyakorló példák

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,673 <sup>a</sup>	,453	,429	6,13531

a. Predictors: (Constant), pred2

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	716,075	1	716,075	19,023	,000 <sup>b</sup>
	Residual	865,765	23	37,642		
	Total	1581,840	24			


a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred2

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	54,131	4,352		12,438	,000
	pred2	-,286	,066	-,673	-4,362	,000

a. Dependent Variable: kimeneti



# Gyakorló példa

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,580 <sup>a</sup>	,337	,226	8,70704

a. Predictors: (Constant), pred3

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	231,125	1	231,125	3,049	,131 <sup>b</sup>
	Residual	454,875	6	75,813		
	Total	686,000	7			


a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred3

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	19,375	9,735		1,990	,094
	pred3	5,375	3,078	,580	1,746	,131

a. Dependent Variable: kimeneti



# Gyakorló példák

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,229 <sup>a</sup>	,052	,043	8,21597

a. Predictors: (Constant), pred4

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	366,180	1	366,180	5,425	,022 <sup>b</sup>
	Residual	6615,210	98	67,502		
	Total	6981,390	99			


a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred4

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	30,536	2,361		12,936	,000
	pred4	,130	,056	,229	2,329	,022

a. Dependent Variable: kimeneti



# Gyakorló példák

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,673 <sup>a</sup>	,453	,430	6,13142

a. Predictors: (Constant), pred5

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	717,170	1	717,170	19,077	,000 <sup>b</sup>
	Residual	864,670	23	37,594		
	Total	1581,840	24			


a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred5

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	19,496	3,955		4,929	,000
	pred5	,259	,059	,673	4,368	,000

a. Dependent Variable: kimeneti



# Gyakorló példák

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,745 <sup>a</sup>	,555	,547	5,71458

a. Predictors: (Constant), pred6

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2158,739	1	2158,739	66,105	,000 <sup>b</sup>
	Residual	1730,789	53	32,656		
	Total	3889,527	54			


a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred6

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	17,999	2,279		7,898	,000
	pred6	,296	,036	,745	8,130	,000

a. Dependent Variable: kimeneti



# Gyakorló példák

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,285 <sup>a</sup>	,081	,041	7,95030

a. Predictors: (Constant), pred7

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	128,074	1	128,074	2,026	,168 <sup>b</sup>
	Residual	1453,766	23	63,207		
	Total	1581,840	24			


a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred7

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	29,805	4,581		6,506	,000
	pred7	,162	,114	,285	1,423	,168

a. Dependent Variable: kimeneti



# Gyakorló példák

**Model Summary**

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,749 <sup>a</sup>	,560	,552	5,68013

a. Predictors: (Constant), pred8

**ANOVA<sup>a</sup>**

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2179,539	1	2179,539	67,553	,000 <sup>b</sup>
	Residual	1709,988	53	32,264		
	Total	3889,527	54			

a. Dependent Variable: kimeneti

b. Predictors: (Constant), pred8

**Coefficients<sup>a</sup>**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	59,591	3,037		19,622	,000
	pred8	-,285	,035	-,749	-8,219	,000

a. Dependent Variable: kimeneti

