



MATEKING.HU

Képletgyűjtemény

ANALÍZIS 3 NJE tantárgy

Kiadás dátuma: 2026. 10. 08.

Tartalomjegyzék

Paraméteres görbék.....	2
Síkbeli és térbeli leképezések és mátrixaik.....	5
Vektormezők, görbementi és felületi integrálok.....	9
Kettős és hármas integrál, térfogati integrál.....	10
Divergencia és rotáció.....	12
Valszám alapok, Kombinatorika.....	15
Teljes valószínűség tétele, Bayes tétel.....	16
Eloszlás, eloszlásfüggvény, sűrűségfüggvény.....	17
Geometriai valószínűség, Binomiális tétel.....	20
Várható érték és szórás.....	21
Markov és Csebisev egyenlőtlenségek.....	22
Nevezetes diszkrét és folytonos eloszlások.....	23
Kétváltozós eloszlások.....	26
Becslések.....	28
Hipotézisvizsgálat.....	34

Paraméteres görbék

A ciklois egyenlete:

$$x = R(-\sin u + u) \quad y = R(-\cos u + 1)$$

$$u = \frac{4}{R}t$$

[Megnézem a kapcsolódó epizódot](#)

A paraméteres görbe egyenlete a görbén mozgó pont pillanatnyi koordinátáit írja le.

$$x = x(t) \quad y = y(t)$$

A paraméteres görbe deriválásával kapjuk a $v(t)$ sebességvektort, ami minden időpillanatban megadja a görbén mozgó P pont sebességének irányát és nagyságát:

$$v(t) = (x'(t), y'(t)) \quad |v(t)| = \sqrt{(x'(t))^2 + (y'(t))^2}$$

[Megnézem a kapcsolódó epizódot](#)

A görbe ívhossza a t_0 és t_1 időpillanatokhoz tartozó pontok között:

$$L = \int_{t_0}^{t_1} \sqrt{(x'(t))^2 + (y'(t))^2} dt$$

[Megnézem a kapcsolódó epizódot](#)

Az $r(t)$ paraméteres görbe első deriváltja a görbe érintővektora vagy más néven sebességvektora.

Hogyha ezt elosztjuk a saját hosszával, akkor egy egységnyi hosszú vektort kapunk, amit $\underline{T}$ -vel jelölünk.

$$\underline{T} = \frac{r'(t)}{|r'(t)|}$$

[Megnézem a kapcsolódó epizódot](#)

Az $r(t)$ paraméteres görbe második deriváltja a görbe gyorsulásvektora. Ha ezt elosztjuk a saját hosszával:

$$\underline{N}(t) = \frac{r''(t)}{|r''(t)|}$$

Az így keletkező egységnyi hosszú vektor a görbe főnormálisvektora.

[Megnézem a kapcsolódó epizódot](#)

Binormálisvektornak nevezzük a görbe sebességvektorával és gyorsulásvektorával alkotott szorzatot:

$$\underline{B}(t) = \underline{T}(t) \times \underline{N}(t)$$

[Megnézem a kapcsolódó epizódot](#)

A $\underline{T}(t)$, $\underline{N}(t)$ és $\underline{B}(t)$ [vektorok](#) együttes elnevezése kísérő triéder.

[Megnézem a kapcsolódó epizódot](#)

Az $\underline{r}(t)$ paraméteres görbe második deriváltja a gyorsulást írja le. Ezek a [vektorok](#) egy síkot feszítenek ki, ezt a síkot a görbe simulósíkjának nevezzük. A simulósík normálvektora éppen $\underline{r}'(t) \times \underline{r}''(t)$.

[Megnézem a kapcsolódó epizódot](#)

A görbület azt írja le, hogy a simulósíkon belül milyen erősen kanyarodik a görbe. A térgörbék azonban nem csak a simulósíkon belül kanyarodnak, hanem közben ki is csavarodnak abból. Azt, hogy egy térgörbe éppen milyen ütemben csavarodik ki a simulósíkjából, a torzió írja le.

Hogyha egy görbe minden pontjában nulla a torzió, az annak a jele, hogy ez a görbe egy síkgörbe. Egy görbe akkor tud kilépni a simulósíkjából, ha a torzió legalább egy pontban nem nulla. Vagyis olyankor, ha a görbe elmozdul a binormális vektor irányában is. A torzió kiszámításához szükségünk van a görbe harmadik deriváltjára:

$$\tau = \frac{(\underline{r}'(t) \times \underline{r}''(t)) \cdot \underline{r}'''(t)}{|\underline{r}'(t) \times \underline{r}''(t)|^2} = \frac{\det \begin{bmatrix} x'(t) & y'(t) & z'(t) \\ x''(t) & y''(t) & z''(t) \\ x'''(t) & y'''(t) & z'''(t) \end{bmatrix}}{\left| \det \begin{bmatrix} \underline{i} & \underline{j} & \underline{k} \\ x'(t) & y'(t) & z'(t) \\ x''(t) & y''(t) & z''(t) \end{bmatrix} \right|^2}$$

[Megnézem a kapcsolódó epizódot](#)

Az $\underline{r}(t) = (x(t), y(t))$ paraméteres görbe görbülete:

$$\kappa = \frac{|\underline{r}'(t) \times \underline{r}''(t)|}{|\underline{r}'(t)|^3} = \frac{|x'(t) \cdot y''(t) - y'(t) \cdot x''(t)|}{\sqrt{(x'(t))^2 + (y'(t))^2}^3}$$

[Megnézem a kapcsolódó epizódot](#)

Hogyha a görbének egy P pontjában létezik nem nulla görbülete, akkor azt a kört, amely P -ben érinti a görbét és a görbülete megegyezik a görbe P -beli görbületével és a középpontja a görbe konkáv részében található, a görbe P pontbeli simulókörének nevezzük.

A simulókör sugarát a görög ró betűvel jelöljük, és

$$\rho = \frac{1}{\kappa}$$

[Megnézem a kapcsolódó epizódot](#)

A simulókörok középpontjai által kirajzolt alakzatot evolutának hívjuk.

[Megnézem a kapcsolódó epizódot](#)

Ha az ellipszis fél-nagy tengelyének hossza a , fél-kis tengelyének hossza b , akkor egyenlete:

$$\frac{x^2}{a^2} + \frac{y^2}{b^2} = 1$$

[Megnézem a kapcsolódó epizódot](#)

Ha a hiperbola fél-nagy tengelyének hossza a , fél-kis tengelyének hossza b , akkor egyenlete:

$$\frac{x^2}{a^2} - \frac{y^2}{b^2} = 1$$

[Megnézem a kapcsolódó epizódot](#)

Síkbeli és térbeli leképezések és mátrixaik

A φ leképezést lineáris leképezésnek nevezzük, ha bármely $\underline{v}_1, \underline{v}_2 \in V_1$ vektorokra és $\lambda \in R$ számra teljesül, hogy

$$\varphi(\underline{v}_1 + \underline{v}_2) = \varphi(\underline{v}_1) + \varphi(\underline{v}_2)$$

$$\varphi(\lambda \cdot \underline{v}) = \lambda \cdot \varphi(\underline{v})$$

[Megnézem a kapcsolódó epizódot](#)

A $V_1 \rightarrow V_2$ lineáris leképezésnél V_2 -nek azt a részét, amely a leképezés során előáll, a leképezés képterének nevezzük és $Im\varphi$ -vel jelöljük.

[Megnézem a kapcsolódó epizódot](#)

A nullvektorból minden lineáris leképezés nullvektort csinál, vagyis $\underline{0}$ képe mindig $\underline{0}$, de előfordulhat, hogy más V_1 -beli [vektorok](#) képe is nullvektor lesz. Ezen [vektorok](#) halmazát nevezzük a leképezés magterének és $Ker\varphi$ -vel jelöljük.

[Megnézem a kapcsolódó epizódot](#)

A képtér és a magtér dimenziója összesen éppen kiadja V_1 dimenzióját.

Ezt az összefüggést dimenziótételnek nevezzük:

$$\dim(Ker\varphi) + \dim(Im\varphi) = \dim(V_1)$$

[Megnézem a kapcsolódó epizódot](#)

Minden lineáris leképezést jellemezhetünk egy mátrixszal. Valójában mindegyiket végtelen sok mátrixszal jellemezhetjük, ezek a [mátrixok](#) pedig úgy keletkeznek, hogy veszünk egy tetszőleges bázist V_1 -ben és a bázis[vektorok](#) képeit egymás mellé írjuk.

[Megnézem a kapcsolódó epizódot](#)

A φ leképezésben minden vektor képét így kapjuk:

$$\varphi(\underline{v}) = (\varphi)_b \cdot \underline{v}$$

[Megnézem a kapcsolódó epizódot](#)

Egy leképezésnek pontosan akkor létezik inverze, ha a $(\varphi)_b$ mátrixnak létezik inverze, és az inverz leképezés mátrixa:

$$\varphi^{-1} \text{ mátrixa } (\varphi)_b^{-1}$$

[Megnézem a kapcsolódó epizódot](#)

A $\varphi \circ \mu$ leképezés mátrixa:

$$(\varphi \circ \mu)_b = (\varphi)_b \cdot (\mu)_b$$

[Megnézem a kapcsolódó epizódot](#)

Az x tengelyre tükrözés mátrixa:

$$\begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$$

Az y tengelyre tükrözés mátrixa:

$$\begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix}$$

Az $y=x$ tengelyre tükrözés mátrixa:

$$\begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az origón átmenő $\underline{a}$ normálvektorú egyenesre tükrözés mátrixa:

$$R = I - 2 \cdot \frac{\underline{a} \cdot \underline{a}^T}{\underline{a}^T \cdot \underline{a}}$$

[Megnézem a kapcsolódó epizódot](#)

Az α szögű forgatás mátrixa:

$$\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az origóra való középpontos tükrözés egy 180° -os forgatásnak felel meg, így mátrixa:

$$\begin{pmatrix} \cos 180^\circ & -\sin 180^\circ \\ \sin 180^\circ & \cos 180^\circ \end{pmatrix} = \begin{pmatrix} -1 & 0 \\ 0 & -1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az i és j koordinátatengelyek síkjában történő Givens forgatás mátrixát úgy kapjuk, hogy arra a négy helyre ahol az egység mátrix i -edik és j -edik sora és oszlopa metszi egymást beírjuk szépen az α szögű forgatás mátrixának elemeit.

$$G = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & \cos \alpha & 0 & -\sin \alpha & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & \sin \alpha & 0 & \cos \alpha & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az origón átmenő síkokra való tükrözést Householder-tükrözésnek nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Hogyha egy origón átmenő sík normálvektora az $\underline{a}$ vektor, akkor az erre a síkra tükrözés mátrixa:

$$H = I - 2 \cdot \frac{\underline{a} \cdot \underline{a}^T}{\underline{a}^T \cdot \underline{a}}$$

[Megnézem a kapcsolódó epizódot](#)

Az x tengelyre merőleges vetítés mátrixa:

$$P_x = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}$$

Az y tengelyre merőleges vetítés mátrixa:

$$P_y = \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az x tengelyre merőleges vetítés mátrixa:

$$P_x = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}$$

Az y tengelyre merőleges vetítés mátrixa:

$$P_y = \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

A $\underline{v}$ irányvektorú origón átmenő egyenesre történő merőleges vetítés mátrixa:

$$P = \frac{\underline{v} \cdot \underline{v}^T}{\underline{v}^T \cdot \underline{v}}$$

[Megnézem a kapcsolódó epizódot](#)

A projekció mátrixa:

$$P = I - \frac{\underline{a} \cdot \underline{a}^T}{\underline{a}^T \cdot \underline{a}}$$

[Megnézem a kapcsolódó epizódot](#)

Vektormezők, görbementi és felületi integrálok

A vektormező egy olyan függvény, ami egy tér pontjaihoz vektort rendel.

[Megnézem a kapcsolódó epizódot](#)

A $v(x, y)$ vektormezőnek az $r(t) = (x(t), y(t))$ görbe mentén vett integrálja t_1 és t_2 között:

$$\int_r v(x, y) ds = \int_{t_1}^{t_2} v(x(t), y(t)) \cdot (x'(t), y'(t)) dt$$

[Megnézem a kapcsolódó epizódot](#)

A fluxus azt mondja meg, hogy egy adott felületen mekkora az átáramló anyag vagy energia.

A fluxust a vektormező vektorainak és a felület normálvektorainak skaláris szorzata adja.

$$\int_S v(x, y, z) ds = \int_A v(x, y, z) \cdot \underline{n} dA$$

[Megnézem a kapcsolódó epizódot](#)

A $v(x, y, z)$ vektormezőnek az $S(t, u) = (x(t, u), y(t, u), z(t, u))$ felületi integrálja:

$$\int_S v(x, y, z) ds = \int_{t_1}^{t_2} \int_{u_1}^{u_2} v(x(t, u), y(t, u), z(t, u)) \cdot S'_t \times S'_u du dt$$

ahol

$$S'_t \times S'_u = \det \begin{bmatrix} \underline{i} & \underline{j} & \underline{k} \\ \frac{dx(t, u)}{dt} & \frac{dy(t, u)}{dt} & \frac{dz(t, u)}{dt} \\ \frac{dx(t, u)}{du} & \frac{dy(t, u)}{du} & \frac{dz(t, u)}{du} \end{bmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

A $v(x, y, z)$ vektormezőnek az $r(t) = (x(t), y(t), z(t))$ görbe mentén vett integrálja:

$$\int_r v(x, y, z) ds = \int_{t_1}^{t_2} v(x(t), y(t), z(t)) \cdot (x'(t), y'(t), z'(t)) dt$$

[Megnézem a kapcsolódó epizódot](#)

Kettős és hármas integrál, térfogati integrál

A kétváltozós függvények úgy működnek, hogy két valós számhoz rendelnek hozzá egy harmadik valós számot. Az értelmezési tartomány minden pontjához hozzárendelve ezt a harmadik, magasság koordinátáit, kirajzolódik az x, y sík felett a függvény, ami egy felület.

A kétváltozós függvények határozott integrálja így egy test térfogata.

$$\int_c^d \int_a^b f(x, y) \, dx dy$$

[Megnézem a kapcsolódó epizódot](#)

A kettősintegrálok segítségével különböző felületek alatti térfogatokat tudunk kiszámolni.

A legegyszerűbb eset, amikor egy téglalapon integrálunk. Ilyenkor az integrálás határai valamilyen számok.

$$\int_a^b \int_c^d f(x, y) \, dy dx = \int_c^d \int_a^b f(x, y) \, dx dy$$

A sorrend megcserélhető: mindegy, hogy először az x szerinti határokat adjuk meg és utána az y szerintit vagy fordítva.

[Megnézem a kapcsolódó epizódot](#)

A polárkoordinátás helyettesítés egy olyan helyettesítés, ami remekül alkalmazkodik a kör tulajdonságaihoz. A dolog lényege, hogy a körben a hagyományos x és y koordináták helyett új koordinátákat vezetünk be.

Az egyik azt mondja meg, hogy milyen távol vagyunk a kör középpontjától és ezt r -nek nevezzük.

A másik pedig egy forgásszög, és jele θ .

Az új koordinátákat polárkoordinátáknak nevezzük, a módszert pedig polárkoordinátás helyettesítésnek. A kapcsolat a régi és az új koordináták között a következő:

$$x = r \cos \theta \quad y = r \sin \theta$$

A polárkoordinátás helyettesítés elvégzése után az integrálásban drasztikus változások lesznek. A helyettesítést ezzel a képlettel végezzük:

$$\int \int_D f(x, y) \, dy dx = \int \int_D f(r \cos \theta, r \sin \theta) r \, dr d\theta$$

[Megnézem a kapcsolódó epizódot](#)

A henger-koordináták:

$$x = r \cos \theta \quad y = r \sin \theta \quad z = z$$

A henger-koordinátás helyettesítés elvégzése után az integrálásban drasztikus változások lesznek.

A helyettesítést ezzel a képlettel végezzük:

$$\int \int \int_D f(x, y, z) \, dx dy dz = \int \int \int_D f(r \cos \theta, r \sin \theta, z) r \, dr d\theta dz$$

[Megnézem a kapcsolódó epizódot](#)

A polárkoordináták háromdimenziós változatát gömbi koordinátáknak nevezzük.

Az r azt mondja meg, hogy milyen távol vagyunk az origótól, a φ és θ pedig két forgás-szög.

A régi x, y, z és az új [gömbi koordináták](#) közti kapcsolat:

$$x = r \sin \varphi \cos \theta \quad y = r \sin \varphi \sin \theta \quad z = r \cos \varphi$$

A gömb koordinátás helyettesítés:

$$\int \int \int_D f(x, y, z) \, dx dy dz = \int \int \int_D f(r \sin \varphi \cos \theta, r \sin \varphi \sin \theta, r \cos \varphi) r^2 \sin \varphi \, dr d\theta d\varphi$$

[Megnézem a kapcsolódó epizódot](#)

Divergencia és rotáció

A vektormező divergenciája egy olyan függvény, amely a vektormező minden pontjában megméri, hogy ott mennyi anyag áramlik a rendszerbe vagy épp mennyi tűnik el.

A képlete:

$$\operatorname{div}(v(x, y)) = \frac{\delta v_1(x, y)}{\delta x} + \frac{\delta v_2(x, y)}{\delta y}$$

[Megnézem a kapcsolódó epizódot](#)

A rotáció a vektormező örvénylését írja le.

$$\operatorname{rot}(v(x, y)) = \frac{\delta v_2(x, y)}{\delta x} - \frac{\delta v_1(x, y)}{\delta y}$$

Azokban a pontokban, ahol $x = y$ a rotáció épp nulla.

Ha $x > y$ akkor a rotáció pozitív, és ha $x < y$ akkor negatív.

$\mathbb{R}^3 \rightarrow \mathbb{R}^3$ vektormező esetén:

$$\operatorname{rot}(v) = \left(\frac{\delta v_3}{\delta y} - \frac{\delta v_2}{\delta z} \right) \cdot \underline{i} + \left(\frac{\delta v_1}{\delta z} - \frac{\delta v_3}{\delta x} \right) \cdot \underline{j} + \left(\frac{\delta v_2}{\delta x} - \frac{\delta v_1}{\delta y} \right) \cdot \underline{k} = \det \begin{bmatrix} \underline{i} & \underline{j} & \underline{k} \\ \frac{\delta}{\delta x} & \frac{\delta}{\delta y} & \frac{\delta}{\delta z} \\ v_1 & v_2 & v_3 \end{bmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Egy vektormező akkor forrásmentes, ha nincs benne forrás, vagyis nincs benne olyan pont, amelynek pozitív a divergenciája.

[Megnézem a kapcsolódó epizódot](#)

Egy vektormező akkor örvénymentes, ha a vektormező rotációja mindenütt nulla.

[Megnézem a kapcsolódó epizódot](#)

A konzervatív vektormezőre több különböző definíció van forgalomban attól függően, hogy fizikusok vagy matematikusok alkották-e meg magát a definíciót.

#0 A $v(x, y, z)$ egyszeresen összefüggő tartományon értelmezett vektormező pontosan akkor konzervatív, ha bármely pontjában a rotáció nulla.

#1 A $v(x, y, z)$ vektormező konzervatív, ha létezik primitív függvénye. Ezt a függvényt potenciál-függvénynek nevezzük, és íme, itt is van:

$$F(x, y, z) \quad v(x, y, z) = \left(\frac{\delta F}{\delta x}, \frac{\delta F}{\delta y}, \frac{\delta F}{\delta z} \right)$$

#2 A $v(x, y, z)$ vektormező konzervatív, ha tetszőleges A és B pontjára igaz, hogy bármely A és B közti görbén ugyanakkora a vektormező integrálja:

$$\int_{\substack{r_1(t) \\ A \rightarrow B}} v(x, y) \, ds = \int_{\substack{r_2(t) \\ A \rightarrow B}} v(x, y) \, ds$$

#3 A $v(x, y, z)$ vektormező konzervatív, ha bármely zárt görbén a vektormező integrálja nulla.

$$\oint_{r(t)} v(x, y) \, ds = 0$$

[Megnézem a kapcsolódó epizódot](#)

A vektormező akkor konzervatív, ha létezik F primitív függvénye. Ez az F függvény a vektormező potenciál-függvénye.

A potenciál-függvény egy vektor-skalár függvény, és azt tudja, hogy a vektormező minden pontjához hozzárendel egy számot.

[Megnézem a kapcsolódó epizódot](#)

Green-tétel #1 (zárt görbén vett örvénylés):

$$\oint_{r(t)} v(x, y) \, ds = \int_D \text{rot}(v) \, dydx$$

Az első Green-tétel azt írja le a rotáció segítségével, hogy mekkora egy vektormező örvénylése a zárt görbén.

Green-tétel #2 (zárt görbén vett fluxus)

A második Green-tétel pedig azt írja le a divergencia segítségével, hogy mekkora egy vektormező fluxusa a zárt görbén.

$$\oint_{r(t)} v(r(t)) \cdot n(t) \, dt = \int_D \text{div}(v) \, dydx$$

[Megnézem a kapcsolódó epizódot](#)

A második Green-tétel térbeli változata azt mondja, hogy egy vektormező integrálja az S kifelé irányított zárt felületen egyenlő a divergencia integráljával a felület által határolt D tartományon.

$$\oint_{S(t,u)} v(S(t,u)) \cdot S'_t \times S'_u \, dudt = \int_D \operatorname{div}(v) \, dxdydz$$

Ezt a tételt divergencia-tételnek vagy másként Gauss-Ostrogradszkij-tételnek nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Az első Green-tétel térbeli megfelelője azt mondja, hogy a vektormező örvénylése egy zárt görbén kiszámolható úgy is, ha a görbe által határolt S felületen integráljuk a vektormező rotációját.

$$\oint_{r(t)} v(x,y,z) \, ds = \int_S \operatorname{rot}(v) \cdot \underline{n} \, ds$$

Ráadásul teljesen mindegy, hogy melyik felületen.

Az első Green-tétel térbeli változatát Stokes-tételnek nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Valszám alapok, Kombinatorika

Eseményeknek nevezzük a valószínűségi kísérlet során bekövetkező lehetséges kimeneteket.

Megkülönböztetünk elemi eseményeket, ilyen például, hogy egy dobókockával 1-est dobunk. Vannak azonban olyan események is amik több elemi eseményből épülnek fel, ilyen például az, hogy párosat dobunk.

Az eseményeket az ABC nagybetűivel jelöljük.

[Megnézem a kapcsolódó epizódot](#)

A valószínűség kiszámításának klasszikus modelljét akkor alkalmazhatjuk, ha egy kísérletnek véges sok kimenetele van és ezek valószínűsége egyenlő. Ekkor az [esemény](#) valószínűségét úgy kaphatjuk meg, hogy megszámloljuk hány elemi eseményből áll és ezt elosztjuk az összes [elemi esemény](#) számával.

[Megnézem a kapcsolódó epizódot](#)

Az A és B eseményt egymástól függetlennek nevezzük, ha teljesül rájuk, hogy

$$P(A \cap B) = P(A) \cdot P(B)$$

[Megnézem a kapcsolódó epizódot](#)

Az A és B eseményt kizárónak nevezünk, ha

$$A \cap B = \emptyset$$

[Megnézem a kapcsolódó epizódot](#)

Az A [esemény valószínűsége](#), ha tudjuk, hogy a B [esemény](#) biztosan bekövetkezik:

$$P(A | B) = \frac{P(A \cap B)}{P(B)}$$

[Megnézem a kapcsolódó epizódot](#)

$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$

$$P(A \cap B) = P(A) + P(B) - P(A \cup B)$$

$$P(A \setminus B) = P(A) - P(A \cap B)$$

$$P(\bar{A}) = 1 - P(A)$$

[Megnézem a kapcsolódó epizódot](#)

Teljes valószínűség tétele, Bayes tétel

Ha B_1, B_2 és így tovább B_n teljes eseményrendszer, valamint A tetszőleges [esemény](#), akkor

$$P(A) = P(A | B_1)P(B_1) + P(A | B_2)P(B_2) + \dots + P(A | B_n)P(B_n)$$

[Megnézem a kapcsolódó epizódot](#)

A Bayes tételt akkor használjuk, ha egy korábban bekövetkezett (B_k) [esemény](#) valószínűségét akarjuk kiszámolni egy később bekövetkezett (A) tükrében.

Ha B_1, B_2 és így tovább B_n teljes eseményrendszer, valamint A tetszőleges [esemény](#), akkor bármely B_k eseményre

$$P(B_k | A) = \frac{P(A|B_k)P(B_k)}{P(A|B_1)P(B_1) + P(A|B_2)P(B_2) + \dots + P(A|B_n)P(B_n)}$$

[Megnézem a kapcsolódó epizódot](#)

Eloszlás, eloszlásfüggvény, sűrűségfüggvény

Folytonosnak nevezzük azokat a valószínűségi változókat, amik folytonos mennyiségeket mérnek, ilyen például az idő, a távolság. Ebben az esetben az [eloszlás](#) függvény is mindig folytonos függvény lesz.

[Megnézem a kapcsolódó epizódot](#)

Diszkrétnek nevezzük azokat a valószínűségi változókat, amik megszámlálhatóan sok értéket vesznek fel. Ez azt jelenti, hogy vagy véges sokat, vagy végtelent, de úgy, hogy fel tudjuk sorolni az értékeit.

[Megnézem a kapcsolódó epizódot](#)

Az X [valószínűségi változó](#) eloszlásfüggvénye:

$$F(x) = P(X < x)$$

Ha az X [valószínűségi változó](#) diszkrét és értékei $X = a, X = b, X = c$ meg ilyenek, akkor az [eloszlásfüggvény](#) mindig egy lépcsőzetes függvény, ami minden számnál pontosan akkorát ugrik, mint az adott szám valószínűsége, amíg el nem érjük az 1-et.

$$F(x) = \begin{cases} 0 & \text{ha } x \leq a \\ P(X = a) & \text{ha } a < x \leq b \\ P(X = a) + P(X = b) & \text{ha } b < x \leq c \\ \vdots & \\ 1 & \end{cases}$$

Ha az X [valószínűségi változó](#) folytonos, akkor az a és b számok között bármilyen valós értéket fölvehet. Ilyenkor az [eloszlásfüggvény](#) is folytonos, ami a -ig nullát vesz föl, a és b közt növekszik és b után végig egyet vesz föl. Vagyis ahol az X [valószínűségi változó](#) működik, ott a függvény életre kel, előtte és utána pedig hibernált állapotban van.

[Megnézem a kapcsolódó epizódot](#)

A [sűrűségfüggvény](#) úgy működik, hogy a valószínűségeket a görbe alatti területek adják meg. Az [eloszlásfüggvény](#) jele $F(x)$ volt, a [sűrűségfüggvény](#) jele $f(x)$. Az $a < X < b$ valószínűség éppen a görbe alatti terület a -tól b -ig.

$$P(a < X < b) = \int_a^b f(x) dx$$

Ha az $X < a$ valószínűséget szeretnénk kiszámolni:

$$P(X < a) = \int_{-\infty}^a f(x) dx$$

Ha a $b < X$ valószínűséget:

$$P(b < X) = \int_b^{+\infty} f(x) dx$$

Ha ezt a három területet összeadjuk, akkor éppen a teljes görbe alatti területet kapjuk, ami a 100%-ot jelenti, így hát ez a terület éppen 1.

A [sűrűségfüggvény](#) tulajdonságai:

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

nem negatív

[Megnézem a kapcsolódó epizódot](#)

$$1. \lim_{-\infty} F(x) = 0$$

$$2. \lim_{\infty} F(x) = 1$$

3. monoton nő

4. balról folytonos

[Megnézem a kapcsolódó epizódot](#)

$$1. \int_{-\infty}^{\infty} f(x) dx = 1$$

2. nem negatív

[Megnézem a kapcsolódó epizódot](#)

$$P(X < a) = F(a) = \int_{-\infty}^a f(x) dx$$

$$P(b < X) = 1 - F(b) = \int_b^{+\infty} f(x) dx$$

$$P(a < X < b) = F(b) - F(a) = \int_a^b f(x) dx$$

[Megnézem a kapcsolódó epizódot](#)

Az X [valószínűségi változó](#) $F(x)$ eloszlásfüggvényéből úgy kapjuk meg az $f(x)$ sűrűségfüggvényét, hogy az $F(x)$ eloszlásfüggvényt deriváljuk, azaz:

$$F'(x) = f(x)$$

Ha az X [valószínűségi változó](#) $f(x)$ sűrűségi függvényét ismerjük, és meg akarjuk adni az $F(x)$ eloszlásfüggvényét, akkor azt pedig így tehetjük:

$$F(x) = \int_{-\infty}^x f(t) dt$$

[Megnézem a kapcsolódó epizódot](#)

Geometriai valószínűség, Binomiális tétel

$$(a + b)^n = \sum_{k=0}^n \binom{n}{k} a^{n-k} b^k$$

[Megnézem a kapcsolódó epizódot](#)

[Binomiális](#) tétel:

$$(a + b)^n = \sum_{k=0}^n \binom{n}{k} a^{n-k} b^k = \binom{n}{0} a^n + \binom{n}{1} a^{n-1} b + \binom{n}{2} a^{n-2} b^2 + \dots + \binom{n}{n} b^n$$

[Megnézem a kapcsolódó epizódot](#)

Várható érték és szórás

A [várható érték](#) jele $E(X)$.

Diszkrét esetben úgy kell kiszámolni, hogy

$$E(X) = \sum X_i P(X_i)$$

[Megnézem a kapcsolódó epizódot](#)

A szórás azt mutatja meg, hogy a [várható érték](#) körül milyen nagy ingadozásra számíthatunk.

Jele: $D(X)$

Kiszámításának módja diszkrét esetben:

$$D(X) = \sqrt{E(X^2) - E^2(X)}$$

[Megnézem a kapcsolódó epizódot](#)

Folytonos [valószínűségi változók](#) esetén a [várható érték](#):

$$E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx$$

[Megnézem a kapcsolódó epizódot](#)

Folytonos [valószínűségi változó](#) esetén a szórást ugyanúgy kell számolni, mint diszkrét [valószínűségi változó](#) esetén:

$$D(X) = \sqrt{E(X^2) - E^2(X)}$$

[Megnézem a kapcsolódó epizódot](#)

Markov és Csebisev egyenlőtlenségek

A Markov-egyenlőtlenség egy nagyon egyszerű dolgot állít. Az, hogy az X [valószínűségi változó](#) sokkal nagyobb legyen a várható értéknél nem túl valószínű:

$$P(X \geq t \cdot E(X)) \leq \frac{1}{t}$$

[Megnézem a kapcsolódó epizódot](#)

A [Csebisev egyenlőtlenség](#) arról szól, hogy a várható értéktől való eltérés nem lehet túl nagy.

Ha ez az eltérés nagyobb, mint a szórás t -szerese, akkor ennek a valószínűsége kicsi:

$$P(|X - E(X)| \geq t \cdot D(X)) \leq \frac{1}{t^2}$$

Ha az eltérés kisebb, mint a szórás t -szerese, akkor ennek valószínűsége nagy:

$$P(|X - E(X)| < t \cdot D(X)) > 1 - \frac{1}{t^2}$$

[Megnézem a kapcsolódó epizódot](#)

Ha egy [esemény](#) bekövetkezésének elméleti valószínűsége p , akkor minél többször végezzük el a kísérletet, a relatív gyakoriság és az elméleti valószínűség eltérése annál kisebb lesz.

$$P\left(\left|\frac{X}{n} - p\right| < \epsilon\right) \geq 1 - \frac{p(1-p)}{n\epsilon^2} \quad P\left(\left|\frac{X}{n} - p\right| > \epsilon\right) < \frac{p(1-p)}{n\epsilon^2}$$

[Megnézem a kapcsolódó epizódot](#)

Nevezetes diszkrét és folytonos eloszlások

A [hipergeometriai eloszlás](#) egy diszkrét [eloszlás](#).

Ismert, hogy mennyi az összes elem és az összes selejt, vagyis N , K és n .

$$P(X = k) = \frac{\binom{K}{k} \binom{N-K}{n-k}}{\binom{N}{n}}$$

A [hipergeometriai eloszlás](#) várható értéke:

$$E(X) = n \frac{K}{N}$$

A [hipergeometriai eloszlás](#) szórása:

$$D(X) = \sqrt{n \frac{K}{N} \left(1 - \frac{K}{N}\right) \frac{N-n}{N-1}}$$

[Megnézem a kapcsolódó epizódot](#)

A [binomiális eloszlás](#) egy diszkrét [eloszlás](#).

Csak valami %-os izé ismert, a [várható érték](#), az átlag, az arány, a valószínűség, továbbá X korlátos diszkrét [valószínűségi változó](#).

$$P(X = k) = \binom{n}{k} p^k (1-p)^{n-k}$$

A [binomiális eloszlás](#) várható értéke:

$$E(X) = np$$

A [binomiális eloszlás](#) szórása:

$$D(X) = \sqrt{np(1-p)}$$

[Megnézem a kapcsolódó epizódot](#)

A [Poisson eloszlás](#) egy diszkrét [eloszlás](#), ahol előre ismert a [várható érték](#), és a [valószínűségi változó](#) nem korlátos, vagyis tetszőlegesen bármilyen nagy érték is lehet.

Például valamilyen anyagban a hibák száma, vagy egy adott idő alatt bekövetkező események száma. A [Poisson](#) eloszlásos feladatokban általában valamilyen százalék vagy arány vagy [várható érték](#) vagy átlag vagy valószínűség van megadva. Mondjuk egy könyvben az oldalak 80%-ában nincs hiba, vagy az 20 méter hosszú ruhaszövetek harmadában nincs hiba, vagy egy üzletben óránként várhatóan 13 vevő érkezik, vagy egy bankban percenként átlag 24 tranzakció történik, vagy 0,2 a valószínűsége, hogy 10 perc alatt nem érkezik segélyhívás. Ezek mind Poisson eloszlások, ahol az X nem korlátos diszkrét [valószínűségi változó](#).

$$P(X = k) = \frac{\lambda^k}{k!} e^{-\lambda}$$

A [Poisson eloszlás](#) várható értéke:

$$E(X) = \lambda$$

A [Poisson eloszlás](#) szórása:

$$D(X) = \sqrt{\lambda}$$

[Megnézem a kapcsolódó epizódot](#)

Az [exponenciális eloszlás](#) egy folytonos [eloszlás](#).

Eloszlásfüggvénye:

$$F(x) = \begin{cases} 0 & \text{ha } x \leq 0 \\ 1 - e^{-\lambda x} & \text{ha } 0 < x \end{cases}$$

Sűrűségfüggvénye:

$$f(x) = \begin{cases} 0 & \text{ha } x \leq 0 \\ \lambda e^{-\lambda x} & \text{ha } 0 < x \end{cases}$$

Az [exponenciális eloszlás](#) várható értéke:

$$E(X) = \frac{1}{\lambda}$$

Az [exponenciális eloszlás](#) szórása:

$$D(X) = \frac{1}{\lambda}$$

[Megnézem a kapcsolódó epizódot](#)

Az [egyenletes eloszlás](#) egy folytonos [eloszlás](#).

Eloszlásfüggvénye:

$$F(x) = \begin{cases} 0 & \text{ha } x \leq A \\ \frac{x-A}{B-A} & \text{ha } A < x \leq B \\ 1 & \text{ha } B < x \end{cases}$$

Sűrűségfüggvénye:

$$f(x) = \begin{cases} \frac{1}{B-A} & \text{ha } A < x \leq B \\ 0 & \text{különben} \end{cases}$$

Az [egyenletes eloszlás](#) várható értéke:

$$E(X) = \frac{A+B}{2}$$

Az [egyenletes eloszlás](#) szórása:

$$D(X) = \frac{B-A}{\sqrt{12}}$$

[Megnézem a kapcsolódó epizódot](#)

A [normális eloszlás](#) egy folytonos [eloszlás](#).

Eloszlásfüggvénye:

$$F(x) = \Phi\left(\frac{x-\mu}{\sigma}\right)$$

Sűrűségfüggvénye:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

A [normális eloszlás](#) várható értéke:

$$E(X) = \mu$$

A [normális eloszlás](#) szórása:

$$D(X) = \sigma$$

[Megnézem a kapcsolódó epizódot](#)

Kétváltozós eloszlások

X és Y együttes eloszlása egy táblázat, amelyben szerepel X és Y összes lehetséges értéke és a hozzájuk tartozó valószínűségek.

Ha a táblázat sorait összeadjuk, akkor Y peremeloszlását kapjuk. Ha az oszlopokat adjuk össze, akkor X peremeloszlását kapjuk.

[Megnézem a kapcsolódó epizódot](#)

A [korreláció](#) X és Y valószínűségi változók közötti kapcsolatot írja le.

$$COV(X, Y) = E(X \cdot Y) - E(X)E(Y)$$

$$R(X, Y) = \frac{COV(X, Y)}{D(X)D(Y)}$$

[Megnézem a kapcsolódó epizódot](#)

X és Y kétváltozós [eloszlás](#) esetén...

X peremeloszlásfüggvénye:

$$F_X(x) = P(X < x) = \lim_{y \rightarrow \infty} F(x, y)$$

Y peremeloszlásfüggvénye:

$$F_Y(y) = P(Y < y) = \lim_{x \rightarrow \infty} F(x, y)$$

[Megnézem a kapcsolódó epizódot](#)

X és Y valószínűségi változók együttes eloszlásfüggvénye:

$$F(x, y) = P(X < x, Y < y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) dv du$$

[Megnézem a kapcsolódó epizódot](#)

Az együttes [eloszlás](#) sűrűségfüggvénye:

$$f(x, y) = F'$$

ahol

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y f(u, v) dv du$$

Az együttes [eloszlásfüggvény](#).

[Megnézem a kapcsolódó epizódot](#)

X perem-sűrűségfüggvénye:

$$f_X(x) = F'_X(x)$$

ahol

$$F_X(x) = \int_{-\infty}^{\infty} f(u) du$$

az X perem-eloszlásfüggvénye.

Y perem-sűrűségfüggvénye:

$$f_Y(y) = F'_Y(y)$$

ahol

$$F_Y(y) = \int_{-\infty}^{\infty} f(v) dv$$

az Y perem-eloszlásfüggvénye.

[Megnézem a kapcsolódó epizódot](#)

X és Y kétváltozós [eloszlás](#) esetén...

X peremeloszlásfüggvénye:

$$F_X(x) = P(X < x) = \lim_{y \rightarrow \infty} F(x, y)$$

Y peremeloszlásfüggvénye:

$$F_Y(y) = P(Y < y) = \lim_{x \rightarrow \infty} F(x, y)$$

[Megnézem a kapcsolódó epizódot](#)

Becslések

Olyan esetekben, amikor valamiért nem tudjuk vagy nem akarjuk a teljes sokaságot megvizsgálni, hogy meghatározzuk a fontosabb statisztikai mutatóit, becslést alkalmazunk. A becslés lényege, hogy egy minta alapján próbálunk ezekre a mutatókra következtetni.

[Megnézem a kapcsolódó epizódot](#)

A megbízhatósági szintet konfidencia szintnek nevezzük. A konfidencia szint szokásos jelölése $1 - \alpha$.

[Megnézem a kapcsolódó epizódot](#)

Az $1 - \alpha$ megbízhatósági szinthez, vagy másként konfidencia szinthez tartozó konfidencia intervallumok azok az intervallumok, amik a sokasági átlagot $1 - \alpha$ valószínűséggel tartalmazzák.

A konfidencia intervallum végpontjai:

$$\bar{x} \pm Z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \text{ ahol}$$

$\bar{x}$ = a minta átlaga

n = a minta elemszáma

σ = a teljes [sokaság](#) szórása

$Z_{1-\frac{\alpha}{2}}$ pedig a [standard normális eloszlás](#) $1 - \frac{\alpha}{2}$ -höz tartozó Z értéke.

[Megnézem a kapcsolódó epizódot](#)

$$\bar{x} \pm Z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \text{ ahol}$$

$\bar{x}$ = a minta átlaga

n = a minta elemszáma

σ = a teljes [sokaság](#) szórása

$Z_{1-\frac{\alpha}{2}}$ pedig a [standard normális eloszlás](#) $1 - \frac{\alpha}{2}$ -höz tartozó Z értéke.

[Megnézem a kapcsolódó epizódot](#)

A FAE minta azt jelenti, hogy a [mintavétel](#) során bármely mintaelemet azonos eséllyel választunk ki. Ilyen a visszatevéses [mintavétel](#), vagy pedig abban az esetben ha az alap [sokaság](#) elemszáma nagyon nagy, akkor a visszatevés nélküli [mintavétel](#) is.

[Megnézem a kapcsolódó epizódot](#)

$$\bar{x} \pm t_{1-\frac{\alpha}{2}} \cdot \frac{s}{\sqrt{n}} \text{ ahol}$$

$1 - \alpha =$ konfidencia szint

$\bar{x} =$ a minta átlaga

$n =$ a minta elemszáma

$s =$ a teljes [sokaság](#) szórása, a sokasági szórás nem ismert

$t_{1-\frac{\alpha}{2}}$ pedig a [t-eloszlás](#) $1 - \frac{\alpha}{2}$ -höz tartozó értéke.

[Megnézem a kapcsolódó epizódot](#)

$$\bar{p} \pm Z_{1-\frac{\alpha}{2}} \cdot \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \text{ ahol}$$

$1 - \alpha =$ konfidencia szint

$\bar{p} =$ a minta alapján kapott valószínűség

$n =$ a minta elemszáma

$Z_{1-\frac{\alpha}{2}}$ pedig a [standard normális eloszlás](#) $1 - \frac{\alpha}{2}$ -höz tartozó Z értéke.

[Megnézem a kapcsolódó epizódot](#)

$$\frac{(n-1) \cdot s^2}{\chi^2_{1-\frac{\alpha}{2}}(v)} < \sigma^2 < \frac{(n-1) \cdot s^2}{\chi^2_{\frac{\alpha}{2}}(v)} \text{ ahol}$$

$1 - \alpha =$ konfidencia szint

$\bar{p} =$ a minta alapján kapott valószínűség

$n =$ a minta elemszáma

$s =$ a minta szórása, a sokasági szórás nem ismert

$\chi^2(v)$ pedig a khi-négyzet [eloszlás](#) megfelelő értéke

[Megnézem a kapcsolódó epizódot](#)

Az EV-minta abban különbözik a FAE-mintától, hogy a kiválasztott mintaelemek nem függetlenek egymástól.

Ez olyankor fordulhat elő, ha a teljes [sokaság](#) mérete viszonylag kicsi a minta elemszámához képest. EV-minták esetén tehát a minta fontos jellemzőjévé válik, hogy mekkora a teljes [sokaság](#), amelynek elemszámát N jelöli.

[Megnézem a kapcsolódó epizódot](#)

$$\bar{x} \pm t_{1-\frac{\alpha}{2}} \cdot \frac{s}{\sqrt{n}} \cdot \sqrt{1 - \frac{n}{N}} \text{ ahol}$$

$1 - \alpha =$ konfidencia szint

$\bar{x} =$ a minta átlaga

$n =$ a minta elemszáma

$N =$ a teljes [sokaság](#) elemszáma

$s =$ a minta szórása

$t_{1-\frac{\alpha}{2}}$ pedig a [t-eloszlás](#) $1 - \frac{\alpha}{2}$ -höz tartozó értéke.

[Megnézem a kapcsolódó epizódot](#)

$$\bar{p} \pm Z_{1-\frac{\alpha}{2}} \cdot \sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \cdot \sqrt{1 - \frac{n}{N}} \text{ ahol}$$

$1 - \alpha =$ konfidencia szint

$\bar{p} =$ a minta alapján kapott valószínűség

$n =$ a minta elemszáma

$N =$ a teljes [sokaság](#) elemszáma

$Z_{1-\frac{\alpha}{2}}$ pedig a [standard normális eloszlás](#) $1 - \frac{\alpha}{2}$ -höz tartozó Z értéke.

[Megnézem a kapcsolódó epizódot](#)

Ha a teljes sokaságot felosztjuk viszonylag homogén rétegekre, és a mintát is ezen a rétegek szerint vizsgáljuk, a variancia csökkenthető.

$$\hat{\bar{x}}_R \pm Z_{1-\frac{\alpha}{2}} \cdot s_{\hat{\bar{X}}_R}$$

$1 - \alpha$ = konfidencia szint

$\bar{x}$ = a minta átlaga

n = a minta elemszáma

n_j = a minta j-edik rétegének elemszáma

N = a teljes [sokaság](#) elemszáma

N_j = a teljes [sokaság](#) j-edik rétegének elemszáma

W_j = a teljes [sokaság](#) j-edik rétegének a teljes sokasághoz viszonyított aránya

s_j = a minta j-edik rétegének szórása

$$\hat{\bar{X}}_R = \sum_{j=1}^M W_j \bar{x}_j$$

$$s_{\hat{\bar{X}}_R}^2 = \sum_{j=1}^M W_j^2 \frac{s_j^2}{n_j} \left(1 - \frac{n_j}{N_j}\right)$$

[Megnézem a kapcsolódó epizódot](#)

A kétmintás becslésekre akkor van szükség, amikor két [sokaság](#) valamilyen paraméterét, leginkább az átlagát szeretnénk összehasonlítani.

A kétmintás [becslések](#) lehetnek független mintás [becslések](#) vagy páros mintás [becslések](#).

[Megnézem a kapcsolódó epizódot](#)

Ha mindkét [sokaság](#) közel normális eloszlású, akkor az [átlagok](#) különbségének becslésére ez a formula van forgalomban.

$$d \pm t_{1-\frac{\alpha}{2}} \cdot s_d \text{ ahol } d = \bar{x} - \bar{y}$$

$$s_d = s_c \cdot \sqrt{\frac{1}{n_Y} + \frac{1}{n_X}} \text{ itt } s_c^2 = \frac{(n_X-1)s_X^2 + (n_Y-1)s_Y^2}{n_X+n_Y-2}$$

$1 - \alpha$ = konfidencia szint

$\bar{x}$ = az egyik minta átlaga

$\bar{Y}$ = a másik minta átlaga

n_X = az egyik minta elemszáma

n_Y = a másik minta elemszáma

A szabadságfok $v = n_X + n_Y - 2$

[Megnézem a kapcsolódó epizódot](#)

Egy becslést torzítatlannak nevezünk, ha az egyes mintákból kapott [becslések](#) várható értéke megegyezik a becsléni kívánt mennyiséggel.

Ez a tulajdonság azt jelenti, hogy a becslés során kapott értékek a becsléni kívánt érték körül ingadoznak, és ez az ingadozás szimmetrikus. A torzítatlan becsléseket mindig előnyben részesítjük a torzítottakkal szemben.

[Megnézem a kapcsolódó epizódot](#)

A kérdés az, hogy ha egy sokasági jellemzőre több becslés jöhet szóba, hogyan válasszunk közülük, vagyis mikor tekintünk egy becslést jónak, kettő közül melyiket tekintjük jobbnak és kijelenthetjük-e valamelyikről, hogy a legjobb?

Két alapvető szempont alapján szoktuk a becsléseket versenyeztetni. Az egyik, a már jól ismert torzítatlanság, vagyis a becslésnek az a tulajdonsága, hogy az összes lehetséges mintán vett [becslések](#) átlaga megegyezik a becsléni kívánt sokasági jellemzővel. A másik az úgynevezett minimális variancia kritérium.

A minimális variancia kritérium azt jelenti, hogy ha van két torzítatlan becslésünk, akkor a kettő közül azt tekintjük jobbnak, aminek az összes mintán vett értékeinek varianciája kisebb.

[Megnézem a kapcsolódó epizódot](#)

$$MSE(\hat{\theta}) = \text{var}(\hat{\theta}) + (E(\hat{\theta}) - \theta)^2$$

Az első tag a varianciát, a második tag a várható értéktől való eltérést, vagyis a torzítottságot méri. Ha a becslés torzítatlan, $E(\hat{\theta}) = \theta$ így ez a második tag nulla. Két becslés közül azt részesítjük előnyben, amelyre MSE kisebb.

Az $E(\hat{\theta}) - \theta$ különbségre, vagyis a torzítás mértékére az angol bias szó alapján a $Bs\hat{\theta}$ jelölés van forgalomban. Használatos tehát az

$$MSE(\hat{\theta}) = \text{var}(\hat{\theta}) + Bs^2(\hat{\theta})$$

Képlet is.

[Megnézem a kapcsolódó epizódot](#)

Eddigi vizsgálódásaink egyik legfontosabb eredménye a mintaátlagot eloszlásának jellemzése. Ha a teljes [sokaság](#) átlaga μ és szórása pedig σ , akkor az ebből vett n elemű minták átlagai olyan eloszlással helyezkednek el, aminek átlaga szintén μ , a szórása pedig $\frac{\sigma}{\sqrt{n}}$.

Ezt az utóbbit a minta standard hibájának szokás nevezni. A standard hiba tehát azt mondja meg, hogy a minta [átlagok](#) mekkora szórással ingadoznak a tényleges sokasági átlag körül.

[Megnézem a kapcsolódó epizódot](#)

Mintavételi hibának azokat a hibákat nevezzük, amik kimondottan azért fordulnak elő, mert nem tudjuk, vagy nem akarjuk a teljes sokaságot vizsgálni. A mintavételi hiba tehát a [sokaság](#) eloszlásán és a mintavételi eljárásen kívül főleg a minta elemszáma határozza meg. Mivel pedig ezeket általában már a mintavételt megelőzően ismerjük, a mintavételi hibának megvan az a kellemes tulajdonsága, hogy legtöbbször előre megállapítható. Vagyis még el sem végeztük a mintavételt, de már tudjuk, hogy mekkora lesz a [mintavétel](#) során elkövetett hiba. Ez a kellemes tulajdonság lesz a kiindulópont a [becslések](#) és később a hipotézisvizsgálatok elméletének kiépítésében.

[Megnézem a kapcsolódó epizódot](#)

Hipotézisvizsgálat

Az [elfogadási tartomány](#) az a tartomány, ahová ha a próba értéke kerül, akkor a nullhipotézist elfogadjuk.

[Megnézem a kapcsolódó epizódot](#)

A [kritikus tartomány](#) az a tartomány, ahová ha a próba értéke kerül, akkor a nullhipotézist elvetjük.

[Megnézem a kapcsolódó epizódot](#)

A [szignifikanciaszint](#) a hibás döntés valószínűsége.

[Megnézem a kapcsolódó epizódot](#)

ELSŐ LÉPÉS: A HIPOTÉZIS MEGFOGALMAZÁSA

Minden [hipotézisvizsgálat](#) két egymásnak ellentmondó felvetés felírásával kezdődik. Az egyiket nullhipotézisnek nevezzük és H_0 -al jelöljük, a másikat pedig ellenhipotézisnek és jele H_1 .

MÁSODIK LÉPÉS: A PRÓBAFÜGGVÉNY KIVÁLASZTÁSA

A próbafüggvények kiválasztása magától a hipotézistől, illetve a [mintavétel](#) módjától is függ.

HARMADIK LÉPÉS: [SZIGNIFIKANCIASZINT](#) ÉS [KRITIKUS TARTOMÁNY](#)

Ha a próbafüggvény értéke az elfogadási tartományba fog esni, akkor ezt a tényt a nullhipotézist igazoló jelnek fogjuk tekinteni. Hogyha pedig a kritikus tartományba, akkor a nullhipotézist elvetjük.

NEGYEDIK LÉPÉS: [MINTAVÉTEL](#) ÉS DÖNTÉS

Ha a mintavétellel kapott eredményünk szerint a próbafüggvény az elfogadási tartományba esik, akkor a H_0 nullhipotézist tekintjük igaznak, a H_1 ellenhipotézist pedig elvetjük.

Ha viszont a próbafüggvény a minta alapján a kritikus tartományba esik, akkor a H_0 nullhipotézist vetjük el és a H_1 ellenhipotézist tekintjük igaznak.

[Megnézem a kapcsolódó epizódot](#)

A [sokaság](#) normális eloszlású, szórása σ , H_0 a [sokaság](#) átlagára vonatkozik, a minta elemszáma n .

$$Z = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}}$$

[Megnézem a kapcsolódó epizódot](#)

A [sokaság](#) normális eloszlású, szórása nem ismert, H_0 a [sokaság](#) átlagára vonatkozik, a minta elemszáma n .

$$t = \frac{\bar{x} - \mu_0}{\frac{s}{\sqrt{n}}}$$

[Megnézem a kapcsolódó epizódot](#)

A [sokaság](#) tetszőleges eloszlású, szórása nem ismert, H_0 a [sokaság](#) átlagára vonatkozik, a minta n elemű, elemszáma nagy.

$$Z = \frac{\bar{x} - \mu_0}{\frac{\sigma}{\sqrt{n}}}$$

[Megnézem a kapcsolódó epizódot](#)

A [sokaság](#) tetszőleges eloszlású, H_0 a sokasági arányra vonatkozik, a minta n elemű, elemszáma nagy.

$$Z = \frac{P - P_0}{\sqrt{\frac{P_0(1-P_0)}{n}}}$$

[Megnézem a kapcsolódó epizódot](#)

A [sokaság](#) normális eloszlású, H_0 a sokasági szórásra vonatkozik, a minta n elemű.

$$\chi^2 = \frac{(n-1) \cdot s^2}{\sigma_0^2}$$

[Megnézem a kapcsolódó epizódot](#)

A [sokaság](#) eloszlására irányuló vizsgálat.

H_0 : mindegyik osztályköz valószínűsége egy adott eloszlásnak megfelelő érték, vagyis minden i -re az i -edik osztályköz valószínűsége a P_i érték.

Az ellenhipotézis pedig, H_1 : van olyan osztályköz, ami nem az adott eloszlásnak megfelelő P_i érték. A próbát $\chi^2_{1-\alpha}(v)$ jobb oldali kritikus értékkel végezzük el, a nullhipotézist az ennél kisebb, az ellenhipotézist az ennél nagyobb értékek igazolják. A minta elemszáma n .

$$\chi^2(v) = \sum_{i=1}^k \frac{(f_i - nP_i)^2}{nP_i}$$

ahol a v szabadságfok: $v = k - b - 1$.

Itt k = az osztályközök száma és b = az adott [eloszlás](#) azon paramétereinek száma, amit a mintából becsléssel határozunk meg.

[Megnézem a kapcsolódó epizódot](#)

A sokaságon belül két [ismérv](#) függetlenségére irányuló vizsgálat. H_0 : a két [ismérv](#) független, az ellenhipotézis pedig, H_1 : a két [ismérv](#) közti kapcsolat sztochasztikus vagy függvényszerű.

A próbát $\chi^2_{1-\alpha}(v)$ jobb oldali kritikus értékkel végezzük el, a nullhipotézist az ennél kisebb, az ellenhipotézist az ennél nagyobb értékek igazolják. A minta elemszáma n , a minta alapján készített [kontingencia tábla](#) sorainak száma r , oszlopainak száma c .

$$\chi^2(v) = \sum \frac{(n_{ij} - n_{ij}^*)^2}{n_{ij}^*}$$

ahol a v szabadságfok $v = (r - 1)(c - 1)$.

[Megnézem a kapcsolódó epizódot](#)

Két sokaságban valamely változó eloszlásának egyezőségére irányuló vizsgálat. H_0 : a két sokaságban az [eloszlás](#) egyező, az ellenhipotézis pedig, H_1 : a két [eloszlás](#) nem egyező.

A próbát $\chi^2_{1-\alpha}(v)$ jobb oldali kritikus értékkel végezzük el, a nullhipotézist az ennél kisebb, az ellenhipotézist az ennél nagyobb értékek igazolják. Mintát ezúttal mindkét sokaságból veszünk, az X sokaságból vett minta elemszáma n_X az Y sokaságból vett mintáé n_Y mindkét mintában az osztályközök száma k .

$$\chi^2(v) = n_X \cdot n_Y \cdot \sum_{i=1}^k \left(\frac{1}{n_X + n_Y} \cdot \left(\frac{n_{Xi}}{n_X} - \frac{n_{Yi}}{n_Y} \right)^2 \right)$$

ahol a v szabadságfok $v = k - 1$.

[Megnézem a kapcsolódó epizódot](#)

Mindkét [sokaság](#) normális eloszlású, szórásaik σ_X és σ_Y .

$$Z = \frac{(\bar{y} - \bar{x}) - \delta_0}{\sqrt{\frac{\sigma_Y^2}{n_Y} + \frac{\sigma_X^2}{n_X}}}$$

A nullhipotézis: $H_0: \mu_X - \mu_Y = \delta_0$, ahol δ tetszőleges, de előre megadott érték. A minták elemszáma n_X és n_Y .

[Megnézem a kapcsolódó epizódot](#)

A két [sokaság](#) normális eloszlású és szórásaik egyformák.

$$t(v) = \frac{(\bar{y} - \bar{x}) - \delta_0}{s \cdot \sqrt{\frac{1}{n_Y} + \frac{1}{n_X}}}$$

$$\text{itt } s^2 = \frac{(n_X - 1)s_X^2 + (n_Y - 1)s_Y^2}{n_X + n_Y - 2}$$

A nullhipotézis $H_0: \mu_X - \mu_Y = \delta_0$, ahol δ tetszőleges, de előre megadott érték.

A minták elemszáma n_X és n_Y , szórása s_X és s_Y , a szabadságfok $v = n_Y + n_X - 2$

[Megnézem a kapcsolódó epizódot](#)

A két [sokaság](#) eloszlása és szórása nem ismert, mindkettő szórása véges, és mindkét minta elemszáma elég nagy.

$$Z = \frac{(\bar{y} - \bar{x}) - \delta_0}{\sqrt{\frac{s_Y^2}{n_Y} + \frac{s_X^2}{n_X}}}$$

A nullhipotézis $H_0: \mu_X - \mu_Y = \delta_0$, ahol δ tetszőleges, de előre megadott érték.

A minták elemszáma n_X és n_Y , szórása s_X és s_Y .

[Megnézem a kapcsolódó epizódot](#)

Két [sokaság](#) szórásának összehasonlítására irányuló próba, ha mindkét [sokaság](#) normális eloszlású. A nullhipotézis

$$H_0: \sigma_1^2 = \sigma_2^2$$

$$F = \frac{s_1^2}{s_2^2} \quad F_{1-p}(v_1; v_2) = \frac{1}{F_p(v_2; v_1)}$$

Az F-[eloszlás](#) két szabadságfoka

$$v_1 = n_1 - 1 \text{ és } v_2 = n_2 - 1$$

$$\text{Bal oldali kritikus érték: } \frac{1}{F_{1-\alpha}(v_2; v_1)}$$

$$\text{Jobb oldali kritikus érték: } F_{1-\alpha}(v_1; v_2)$$

Kétoldali kritikus érték:

$$\frac{1}{F_{1-\frac{\alpha}{2}}(v_2; v_1)} \text{ és } F_{1-\frac{\alpha}{2}}(v_1; v_2)$$

[Megnézem a kapcsolódó epizódot](#)

Több [sokaság](#) várható értékének összehasonlítására vonatkozó próba, ha mindegyik [sokaság](#) normális eloszlású és azonos szórású.

A H_0 nullhipotézis: $\mu_1 = \mu_2 = \mu_3 = \dots = \mu_M = \mu$, vagyis az, hogy a várható értékek az összes sokaságra (M db) megegyeznek, míg az ellenhipotézis az, hogy van olyan μ_j amire $\mu_j \neq \mu$.

[Megnézem a kapcsolódó epizódot](#)

A Bartlett-próba több [sokaság](#) szórásának összehasonlítására vonatkozó próba, ha mindegyik [sokaság](#) normális eloszlású.

A H_0 nullhipotézis: $\sigma_1 = \sigma_2 = \sigma_3 = \dots = \sigma_M = \sigma$, vagyis az, hogy az összes [sokaság](#) (M db.) szórása megegyezik, míg az ellenhipotézis az, hogy van olyan σ_j , amire $\sigma_j \neq \sigma$.

$$SSB = \sum_{j=1}^M (n_j - 1) s_j^2 \quad s_b = \frac{SSB}{n-M}$$

A próbafüggvény

$$B^2 = \frac{1}{c} \left(v \cdot \ln s_b^2 - \sum_{j=1}^M v_j \ln s_j^2 \right)$$

$$c = 1 + \frac{1}{3(M-1)} \left(\sum_{j=1}^M \frac{1}{v_j} - \frac{1}{v} \right)$$

Jobb oldali kritikus érték: $\chi_{1-\alpha}^2(M-1)$

[Megnézem a kapcsolódó epizódot](#)