



MATEKING.HU

Képletgyűjtemény

MŰSZAKI MATEMATIKA 2 tantárgy

Kiadás dátuma: 2026. 04. 13.

Tartalomjegyzék

Komplex számok.....	2
Határozatlan integrálás, primitív függvény.....	5
Határozott integrálás.....	9
Mátrixok, vektorok, vektorterek.....	10
Vektorok, egyenesek és síkok egyenletei.....	19
Lineáris egyenletrendszerek, mátrixok inverze.....	23
Determináns, sajátérték, sajátvektor, leképezések.....	26
Gram-Schmidt ortogonalizáció, LU és QR felbontás, pszeudoinvert.....	36
Kétváltozós függvények.....	41
Kétváltozós határérték és totális differenciálhatóság.....	45
Kettős és hármas integrál.....	46
Differenciálegyenletek.....	48
Izoklinák.....	52
Sorok & hatványsorok & Taylor-sorok.....	53
Fourier sorok.....	56
Laplace transzformáció.....	57
Paraméteres görbék.....	59
Vektormezők, görbementi és felületi integrálok.....	62
Divergencia és rotáció.....	63
Valszám alapok, Kombinatorika.....	66
Teljes valószínűség tétele, Bayes tétel.....	67
Geometriai valószínűség, Binomiális tétel.....	68
Eloszlás, eloszlásfüggvény, sűrűségfüggvény.....	69
Várható érték és szórás.....	72
Markov és Csebisev egyenlőtlenségek.....	73
Nevezetes diszkrét és folytonos eloszlások.....	74

Becslések.....	77
Hipotézisvizsgálat.....	83
Regressziószámítás.....	88

Komplex számok

Van itt két komplex szám: $z_1 = a + bi$, $z_2 = c + di$

A két komplex szám összege:

$$z_1 + z_2 = (a + c) + (b + d)i$$

A két komplex szám különbsége:

$$z_1 - z_2 = (a - c) + (b - d)i$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két komplex szám: $z_1 = a + bi$, $z_2 = c + di$

A két komplex szám szorzata:

$$z_1 \cdot z_2 = (a + bi) \cdot (c + di) = a \cdot c - b \cdot d + (a \cdot d + b \cdot c)i$$

[Megnézem a kapcsolódó epizódot](#)

A [komplex számok](#) egy valós és egy imaginárius (képzetes) számból épülnek föl. A valós számok a szokásos x tengelyen helyezkednek el, míg az imaginárius számok egy erre merőleges y tengelyen, amit imaginárius tengelynek, vagy képzetes tengelynek nevezünk. Az imaginárius tengely egysége az i , ami olyan, mint a valós tengelyen az 1 , csak éppen egy meglehetősen furcsa dolgot tud. Az imaginárius egység egy olyan komplex szám, aminek a négyzete -1 és i -vel jelöljük, azaz

$$i^2 = -1$$

[Megnézem a kapcsolódó epizódot](#)

A komplex számokat azért hívjuk "komplex"-nek, mert két részből tevődnek össze. Egy valós és egy imaginárius (képzetes) számból épülnek föl. A valós számok a szokásos x tengelyen helyezkednek el, míg az imaginárius számok egy erre merőleges y tengelyen, amit imaginárius tengelynek, vagy képzetes tengelynek nevezünk. A [komplex számok](#) egy valós számból és egy imaginárius számból tevődnek össze:

$$z = a + bi$$

Itt a és b valós számok, az i pedig az imaginárius egység, ami azt tudja, hogy $i^2 = -1$.

Magukat a valós számokat és az imaginárius számokat is komplex számnak tekinthetjük. A valós számok olyan [komplex számok](#), amelyeknek az imaginárius része nulla, míg az imaginárius számok olyan [komplex számok](#), amelyeknek a valós része nulla. A [komplex számok](#) egy síkon, az úgynevezett komplex számsíkon helyezkednek el. Kicsit olyanok, mint a koordinátageometriában a kétdimenziós sík vektorai, ahol az i és j bázisvektorkat szokás használni, az x tengelynél az i és az y tengelynél a j vektorral. Ennek az analógiának köszönhetően vannak, akik az imaginárius számokat nem is i -vel, hanem j -vel jelölik. Bár ez segíthet erősíteni az analógiát a sík vektoraival, de mégis zavaró, mivel aki komolyabban is foglalkozik a komplex számokkal, a hivatalos jelöléssel fog találkozni, ahol az imaginárius tengelyen i -k vannak.

[Megnézem a kapcsolódó epizódot](#)

A valós számokat úgy érdemes elképzelni, mint egy koordináta-rendszer x tengelyét. És minden helyet ki is töltenek a valós számok ezen a számevgyenesen. A [komplex számok](#) egy valós és egy imaginárius (képzetes) részből épülnek föl, és szemléltetésükhöz nem egy, hanem két koordinátatengelyre van szükség. Az x tengelyen vannak a valós számok, az y tengelyen pedig az imaginárius, vagyis a képzetes számok. A valós számok tengelyén az egység a szokásos 1, míg az imaginárius számok tengelyén az egység az i . A két tengely által kifeszített síkot nevezzük komplex számsíknak, vagy másként Gauss-féle számsíknak.

[Megnézem a kapcsolódó epizódot](#)

Van itt ez a komplex szám:

$$z = a + bi$$

Komplex számoknak van ilyenje, hogy imaginárius egység:

$$i^2 = -1$$

[Komplex számok](#) konjugáltja:

$$\bar{z} = a - bi$$

[Megnézem a kapcsolódó epizódot](#)

Van itt ez a komplex szám: $z = a + bi$

Ennek a komplex számnak az abszolútértéke:

$$|z| = \sqrt{a^2 + b^2}$$

[Megnézem a kapcsolódó epizódot](#)

A $z = a + bi$ komplex szám trigonometrikus alakja:

$$z = r(\cos \theta + i \sin \theta), \text{ ahol}$$

$$r = \sqrt{a^2 + b^2} \quad \cos \theta = \frac{a}{r}$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két komplex szám trigonometrikus alakban: $z_1 = r_1(\cos \theta_1 + i \sin \theta_1)$, $z_2 = r_2(\cos \theta_2 + i \sin \theta_2)$

[Komplex számok szorzása](#) trigonometrikus alakban:

$$z_1 z_2 = r_1 r_2 (\cos(\theta_1 + \theta_2) + i \sin(\theta_1 + \theta_2))$$

[Komplex számok osztása](#) trigonometrikus alakban:

$$\frac{z_1}{z_2} = \frac{r_1}{r_2} (\cos(\theta_1 - \theta_2) + i \sin(\theta_1 - \theta_2))$$

[Megnézem a kapcsolódó epizódot](#)

Van itt ez a komplex szám trigonometrikus alakban: $r(\cos \theta + i \sin \theta)$

Ekkor ennek a komplex számnak az n -edik hatványa:

$$z^n = r^n (\cos n\theta + i \sin n\theta)$$

[Megnézem a kapcsolódó epizódot](#)

Van itt ez a komplex szám trigonometrikus alakban: $z = r(\cos \theta + i \sin \theta)$

Ekkor ennek a komplex számnak az n -edik gyöke:

$$\sqrt[n]{z} = \sqrt[n]{r} \left(\cos \frac{\theta + 2k\pi}{n} + i \sin \frac{\theta + 2k\pi}{n} \right)$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két komplex szám exponenciális alakban: $z_1 = r_1 e^{i\theta_1}$, $z_2 = r_2 e^{i\theta_2}$

[Komplex számok szorzása](#) exponenciális alakban:

$$z_1 z_2 = r_1 r_2 e^{i(\theta_1 + \theta_2)}$$

[Komplex számok osztása](#) exponenciális alakban:

$$\frac{z_1}{z_2} = \frac{r_1}{r_2} e^{i(\theta_1 - \theta_2)}$$

[Megnézem a kapcsolódó epizódot](#)

Van itt ez a komplex szám exponenciális alakban: $z = r e^{i\theta}$

Ekkor ennek a komplex számnak az n -edik hatványa:

$$z^n = r^n e^{ni\theta}$$

[Megnézem a kapcsolódó epizódot](#)

Van itt ez a komplex szám exponenciális alakban: $z = r e^{i\theta}$

Ekkor ennek a komplex számnak az n -edik gyöke:

$$\sqrt[n]{z} = \sqrt[n]{r} e^{i \frac{\theta + 2k\pi}{n}}$$

[Megnézem a kapcsolódó epizódot](#)

Határozatlan integrálás, primitív függvény

Az $f(x)$ függvény primitív függvényének jele $F(x)$ és azt tudja, hogy ha deriváljuk, akkor visszakapjuk $f(x)$ -et, azaz

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

Egy függvény primitív függvényeinek halmazát nevezzük a függvény határozatlan integráljának.

[Megnézem a kapcsolódó epizódot](#)

$$\int x^n dx = \frac{x^{n+1}}{n+1} + c \quad n \neq -1$$

$$\int \frac{1}{x} dx = \ln|x| + c$$

$$\int e^x dx = e^x + c$$

$$\int a^x dx = \frac{a^x}{\ln a} + c$$

$$\int \cos x dx = \sin x + c$$

$$\int \sin x dx = -\cos x + c$$

$$\int \frac{1}{\cos^2 x} dx = \tan x + c$$

$$\int \frac{1}{\sin^2 x} dx = -\cot x + c$$

$$\int \frac{1}{1+x^2} dx = \arctan x + c$$

[Megnézem a kapcsolódó epizódot](#)

$$\int (ax + b)^n dx = \frac{(ax+b)^{n+1}}{n+1} \frac{1}{a} + c$$

$$\int \frac{1}{ax+b} dx = \ln |ax + b| \frac{1}{a} + c$$

$$\int e^{ax+b} dx = e^{ax+b} \frac{1}{a} + c$$

$$\int A^{ax+b} dx = \frac{A^{ax+b}}{\ln A} \frac{1}{a} + c$$

$$\int \cos(ax + b) dx = \sin(ax + b) \frac{1}{a} + c$$

$$\int \sin(ax + b) dx = -\cos(ax + b) \frac{1}{a} + c$$

$$\int \frac{1}{\cos^2(ax+b)} dx = \tan(ax + b) \frac{1}{a} + c$$

$$\int \frac{1}{\sin^2(ax+b)} dx = -\cot(ax + b) \frac{1}{a} + c$$

$$\int \frac{1}{1+(ax+b)^2} dx = \arctan(ax + b) \frac{1}{a} + c$$

[Megnézem a kapcsolódó epizódot](#)

Integráláskor a konstans szorzó kivihető:

$$\int c \cdot f = c \cdot \int f$$

[Megnézem a kapcsolódó epizódot](#)

Összeget külön-külön is integrálhatunk:

$$\int f + g = \int f + \int g$$

[Megnézem a kapcsolódó epizódot](#)

Ha a szorzás elvégezhető, akkor végezzük el, és utána integráljunk.

[Megnézem a kapcsolódó epizódot](#)

$$\int f^\alpha \cdot f' = \frac{f^{\alpha+1}}{\alpha+1} + c$$

[Megnézem a kapcsolódó epizódot](#)

A parciális integrálást szorzatok integrálására fejlesztették ki. Az elnevezés onnan ered, hogy a szorzatot részenként fogjuk integrálni:

$$\int f \cdot g' = f \cdot g - \int f' \cdot g$$

[Megnézem a kapcsolódó epizódot](#)

$$\int f(g(x)) \cdot g'(x) = F(g(x)) + c$$

Ez a tétel az összetett függvények integrálásáról szól. Csak sajnós az a gond az összetett függvényekkel, hogy az integrálásuk általában elég reménytelen vállalkozás.

Érdemes még néhány speciális esetet megjegyeznünk:

$$\int e^g \cdot g' = e^g + c \quad \int a^g \cdot g' = \frac{a^g}{\ln a} + c$$

$$\int \frac{g'}{1+g^2} = \arctan g + c \quad \int \frac{g'}{\sqrt{1-g^2}} = \arcsin g + c$$

[Megnézem a kapcsolódó epizódot](#)

Próbálkozzunk a tört földarabolásával és utána integráljunk.

$$\int \frac{ax+b}{cx+d} dx = \int \frac{\frac{a}{c}(cx+d)+b-\frac{ad}{c}}{cx+d} dx = \int \frac{\frac{a}{c}(cx+d)}{cx+d} + \frac{E}{cx+d} dx =$$

$$= \int \frac{a}{c} + \frac{E}{cx+d} dx = \frac{a}{c}x + E \ln |cx + d| \frac{1}{c}$$

[Megnézem a kapcsolódó epizódot](#)

$$\int \frac{f'}{f} = \ln |f| + c$$

[Megnézem a kapcsolódó epizódot](#)

A helyettesítéses integrálás lényege, hogy egy kifejezést u -val helyettesítünk annak reményében, hogy hátha így képesek leszünk majd megoldani a feladatot.

Hasznos helyettesítések:

$$\int \frac{ax+b}{\sqrt{cx+d}} dx \quad \sqrt{cx+d} = u$$

$$\int f(g(x)) dx \quad g(x) = u$$

$$\sqrt{1-f} \quad f = \sin^2 u$$

$$\sqrt{1+f} \quad f = \sinh^2 u$$

$$\sqrt{f-1} \quad f = \cosh^2 u$$

[Megnézem a kapcsolódó epizódot](#)

Bármilyen racionális törtfüggvényt nagyon egyszerűen tudunk integrálni. Mindössze annyit kell tennünk, hogy fölbontjuk elemi törtekre és az elemi törteket az előbbi módszereinkkel integráljuk.

$$\int \frac{A}{ax+b} dx = A \int \frac{1}{ax+b} dx = A \ln |ax+b| \cdot \frac{1}{a}$$

$$\begin{aligned} \int \frac{Ax+B}{ax^2+bx+c} dx &= A \int \frac{x+\frac{B}{A}}{ax^2+bx+c} dx = \frac{A}{2a} \int \frac{2ax+\frac{2aB}{A}}{ax^2+bx+c} dx = \\ &= \frac{A}{2a} \int \frac{2ax+b+\frac{2aB}{A}-b}{ax^2+bx+c} dx = \frac{A}{2a} \left(\int \frac{2ax+b}{ax^2+bx+c} + \frac{E}{ax^2+bx+c} dx \right) = \\ &= \frac{A}{2a} \left(\ln |ax^2+bx+c| + \frac{E}{aD} \arctan \left(\frac{1}{\sqrt{D}}x + \frac{b}{2a\sqrt{D}} \right) \cdot \sqrt{D} \right) \end{aligned}$$

[Megnézem a kapcsolódó epizódot](#)

A helyettesítéses integrálás úgy működik, hogy egy kifejezést u -val helyettesítünk annak reményében, hogy hátha így képesek leszünk megoldani a feladatot.

A helyettesítéses integrálás egyik legfurcsább esete az $u = \tan \frac{x}{2}$. Olyankor használjuk, ha a törtben $\sin x$ és $\cos x$ is csak első fokon szerepel.

$$\sin x = \frac{2u}{1+u^2} \quad \cos x = \frac{1-u^2}{1+u^2} \quad dx = \frac{2}{1+u^2} du$$

[Megnézem a kapcsolódó epizódot](#)

Határozott integrálás

Ha $f(x)$ integrálható az $[a, b]$ intervallumon és létezik primitív függvénye ezen az intervallumon, akkor a [Newton Leibniz formula](#) szerint a határozott integrálját a következőképp számolhatjuk ki:

$$\int_a^b f(x) dx = [F(x)]_a^b = F(b) - F(a)$$

[Megnézem a kapcsolódó epizódot](#)

Az f $[a, b]$ intervallumon korlátos függvény Riemann integrálható az $[a, b]$ intervallumon, ha egyetlen olyan I szám létezik, hogy bármely felosztásra:

$$s \leq I \leq S$$

ahol s az alsó közelítő összeg: $s = \sum_{i=1}^n m_i(x_i - x_{i-1})$ $m_i = \inf \{f(x), x \in [x_{i-1}, x_i]\}$

ahol S a felső közelítő összeg: $S = \sum_{i=1}^n M_i(x_i - x_{i-1})$ $M_i = \sup \{f(x), x \in [x_{i-1}, x_i]\}$

[Megnézem a kapcsolódó epizódot](#)

Ha integráljuk a pozitív számegegyenesen az

$$f(x) = \frac{1}{x^\alpha}$$

függvényt, akkor 0-tól 1-ig is improprius integrált kapunk és 1-től végtelenig is.

Ha 0-tól 1-ig integrálunk:

$$\int_0^1 \frac{1}{x^\alpha} dx = \begin{cases} \frac{1}{-\alpha+1} & \text{ha } \alpha < 1 \\ \infty & \text{ha } \alpha \geq 1 \end{cases}$$

Ha 1 és végtelen között integrálunk:

$$\int_1^\infty \frac{1}{x^\alpha} dx = \begin{cases} \frac{1}{\alpha-1} & \text{ha } \alpha > 1 \\ \infty & \text{ha } \alpha \leq 1 \end{cases}$$

[Megnézem a kapcsolódó epizódot](#)

Forgástest térfogata:

$$V = \pi \int_a^b f^2(x) dx$$

Forgástest felszíne:

$$A = 2\pi \int_a^b f(x) \sqrt{1 + (f'(x))^2} dx$$

[Megnézem a kapcsolódó epizódot](#)

Mátrixok, vektorok, vektorterek

Egy $n \times k$ -as [mátrix](#) tulajdonképpen nem más, mint egy táblázat, aminek n darab sora és k darab oszlopa van.

$$\text{pl.: } A = \begin{pmatrix} 2 & 3 & 1 \\ 5 & 1 & 1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Ha egy mátrixot egy számmal szorzunk, akkor a [mátrix](#) összes elemét meg kell szorozni a számmal.

$$\text{pl.: } 3 \cdot \begin{pmatrix} 5 & 7 & -2 \\ 2 & 2 & 1 \end{pmatrix} = \begin{pmatrix} 15 & 21 & -6 \\ 6 & 6 & 3 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Ha egy mátrixot osztunk egy számmal, akkor a [mátrix](#) minden elemét osztani kell a számmal.

$$\text{pl.: } \frac{\begin{pmatrix} 6 & 9 & -12 \\ 3 & 3 & 15 \end{pmatrix}}{3} = \begin{pmatrix} 2 & 3 & -4 \\ 1 & 1 & 5 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Két [mátrix](#) összeadásakor összeadjuk az ugyanazon pozícióban lévő elemeket. Két mátrixot csak akkor lehet összeadni, ha ugyanannyi soruk és oszlopuk van.

$$\text{pl.: } \begin{pmatrix} 2 & 4 & 7 \\ 1 & 5 & 3 \end{pmatrix} + \begin{pmatrix} 1 & 7 & -2 \\ 4 & 2 & 1 \end{pmatrix} = \begin{pmatrix} 3 & 11 & 5 \\ 5 & 7 & 4 \end{pmatrix}$$

A [mátrixok](#) összeadása kommutatív, azaz

$$A + B = B + A$$

És asszociatív, azaz

$$(A + B) + C = A + (B + C)$$

[Megnézem a kapcsolódó epizódot](#)

Két [mátrix](#) kivonásakor kivonjuk az ugyanazon pozícióban lévő elemeket. Két mátrixot csak akkor lehet kivonni egymásból, ha ugyanannyi soruk és oszlopuk van.

$$\text{pl.: } \begin{pmatrix} 2 & 4 & 7 \\ 1 & 5 & 3 \end{pmatrix} - \begin{pmatrix} 1 & 7 & -2 \\ 4 & 2 & 1 \end{pmatrix} = \begin{pmatrix} 1 & -3 & 9 \\ -3 & 3 & 2 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Két [mátrix](#) szorzata akkor létezik, ha a bal oldali [mátrix](#) oszlopainak száma megegyezik a jobb oldali [mátrix](#) sorainak számával.

Ha az A [mátrix](#) $m \times n$ -es a B [mátrix](#) pedig $n \times k$ -s, akkor az eredmény [mátrix](#) $m \times k$ -s lesz.

Az eredmény [mátrix](#) i -edik sorának j -edik elemét úgy kapjuk, hogy a bal oldali [mátrix](#) i -edik sorát skalárisan szorozzuk a jobb oldali [mátrix](#) j -edik oszlopával. (Tehát az első elemet az elsővel, a másodikat a másodikkal stb. szorozzuk, majd összeadjuk)

$$\text{pl.: } \begin{pmatrix} 3 & 4 \\ 1 & 5 \end{pmatrix} \cdot \begin{pmatrix} 2 & 4 & 7 \\ 1 & 5 & 3 \end{pmatrix} = \begin{pmatrix} 10 & 32 & 33 \\ 7 & 29 & 22 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Két mátrixot csak akkor adhatunk össze, ha ugyanannyi soruk és oszlopuk van.

A [mátrix](#) összeadás kommutatív:

$$A + B = B + A$$

És asszociatív:

$$(A + B) + C = A + (B + C)$$

[Megnézem a kapcsolódó epizódot](#)

A mátrixszorzás nem kommutatív, azaz:

$$A \cdot B \neq B \cdot A$$

De asszociatív, azaz:

$$(A \cdot B) \cdot C = A \cdot (B \cdot C)$$

[Megnézem a kapcsolódó epizódot](#)

A kvadratikus [mátrix](#) négyzetes [mátrix](#) vagyis ugyanannyi sora van, mint oszlopa.

$$\text{pl.: } \begin{pmatrix} 2 & 3 & 5 \\ 1 & 4 & 1 \\ 2 & 1 & 1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

A diagonális [mátrix](#) olyan kvadratikus [mátrix](#), aminek a főátlóján kívüli elemek nullák.

$$\text{pl.: } \begin{pmatrix} 2 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az egységmátrix olyan mátrix, ami azt tudja, hogy bármely A mátrixra $A \cdot I = A$.

Az egységmátrixok olyan diagonális mátrixok, aminek minden főátló-eleme egy.

$$\text{pl.: } I_{2 \times 2} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az inverz mátrix jele A^{-1} és ez egy olyan mátrix, ami azt tudja, hogy

$$A \cdot A^{-1} = I \text{ (jobb inverz)}$$

$$A^{-1} \cdot A = I \text{ (bal inverz)}$$

[Megnézem a kapcsolódó epizódot](#)

A transzponált a mátrix sorainak és oszlopainak felcserélése. Jele A^T vagy A^*

pl.:

$$A = \begin{pmatrix} 2 & 3 & 5 \\ 1 & 4 & 1 \\ 2 & 5 & 7 \end{pmatrix} \Rightarrow A^T = \begin{pmatrix} 2 & 1 & 2 \\ 3 & 4 & 5 \\ 5 & 1 & 7 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Azokat a mátrixokat, melyek transzponáltjuk önmaga, szimmetrikus mátrixnak nevezzük.

$$\text{pl.: } A = \begin{pmatrix} 5 & 1 & 7 \\ 1 & 4 & 2 \\ 7 & 2 & 6 \end{pmatrix} \Rightarrow A^T = \begin{pmatrix} 5 & 1 & 7 \\ 1 & 4 & 2 \\ 7 & 2 & 6 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Vektort egy számmal úgy szorzunk, hogy a vektor minden koordinátáját megszorozzuk a számmal.

$$\text{Pl.: } 3 \cdot \begin{pmatrix} 1 \\ 3 \\ 5 \end{pmatrix} = \begin{pmatrix} 3 \\ 9 \\ 15 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Vektort egy számmal úgy osztunk, hogy a vektor minden koordinátáját leosztjuk a számmal.

$$\text{Pl.: } \frac{\begin{pmatrix} 3 \\ 6 \\ 15 \end{pmatrix}}{3} = \begin{pmatrix} 1 \\ 2 \\ 5 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Két vektort úgy adunk össze, hogy minden egyes koordinátájukat külön-külön össze adjuk.

$$\text{Pl.: } \begin{pmatrix} 2 \\ 4 \\ -1 \end{pmatrix} + \begin{pmatrix} 4 \\ 2 \\ 7 \end{pmatrix} = \begin{pmatrix} 6 \\ 6 \\ 6 \end{pmatrix}$$

Tulajdonságok:

$$\text{kommutatív: } \underline{a} + \underline{b} = \underline{b} + \underline{a}$$

$$\text{asszociatív: } (\underline{a} + \underline{b}) + \underline{c} = \underline{a} + (\underline{b} + \underline{c})$$

[Megnézem a kapcsolódó epizódot](#)

Két vektort úgy vonunk ki egymásból, hogy minden egyes koordinátájukat külön-külön kivonjuk egymásból.

$$\text{Pl.: } \begin{pmatrix} 2 \\ 4 \\ -1 \end{pmatrix} - \begin{pmatrix} 4 \\ 2 \\ 7 \end{pmatrix} = \begin{pmatrix} -2 \\ 2 \\ -8 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

A [skaláris szorzat](#) két vektor közti művelet, ami csinál belőlük egy számot.

$$\text{Pl.: } \underline{a} = \begin{pmatrix} 3 \\ 2 \\ 5 \end{pmatrix} \quad \underline{b} = \begin{pmatrix} 4 \\ 1 \\ 2 \end{pmatrix}$$

$$\underline{a}^T \cdot \underline{b} = 3 \cdot 4 + 2 \cdot 1 + 5 \cdot 2 = 24$$

Tulajdonságok:

$$\text{kommutatív: } \underline{a}^T \cdot \underline{b} = \underline{b}^T \cdot \underline{a}$$

$$\text{nem asszociatív: } (\underline{a}^T \cdot \underline{b})^T \cdot \underline{c} \neq \underline{a}^T \cdot (\underline{b}^T \cdot \underline{c})$$

[Megnézem a kapcsolódó epizódot](#)

Két vektor diadikus szorzata egy [mátrix](#). Lássuk milyen.

$$\text{Pl.: } \underline{a} = \begin{pmatrix} 3 \\ 2 \\ 5 \end{pmatrix} \quad \underline{b} = \begin{pmatrix} 4 \\ 1 \\ 2 \end{pmatrix}$$

$$\underline{a} \cdot \underline{b}^T = \begin{pmatrix} 12 & 3 & 6 \\ 8 & 2 & 4 \\ 20 & 5 & 10 \end{pmatrix}$$

Tulajdonságok:

nem kommutatív

nem asszociatív

[Megnézem a kapcsolódó epizódot](#)

Ha egy mátrixot beszorunk az $\underline{I} = \begin{pmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$ vektorral, akkor az szépen összeadja a mátrixunk soraiban lévő elemeket.

[Megnézem a kapcsolódó epizódot](#)

Ha egy mátrixot beszorunk az $\underline{I}^T = (1 \ 1 \ \dots \ 1)$ vektorral, akkor az szépen összeadja a mátrixunk oszlopaiban lévő elemeket.

[Megnézem a kapcsolódó epizódot](#)

Ha egy mátrixot megszorunk jobbról egy \underline{e}_i egységvektorral, akkor megkapjuk a [mátrix](#) i-edik oszlopát.

[Megnézem a kapcsolódó epizódot](#)

Ha egy mátrixot megszorunk balról egy \underline{e}_i egységvektorral, akkor megkapjuk a [mátrix](#) i-edik sorát.

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0)$ ponton átmenő és $\underline{n} = \begin{bmatrix} A \\ B \end{bmatrix}$ normálvektorú egyenes egyenlete:

$$A(x - x_0) + B(y - y_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0, z_0)$ ponton átmenő és $\underline{n} = \begin{bmatrix} A \\ B \\ C \end{bmatrix}$ normálvektorú sík egyenlete:

$$A(x - x_0) + B(y - y_0) + C(z - z_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

Van a síkban két pont: $P(x_1, y_1)$ és $Q(x_2, y_2)$.

Ekkor a két pont közti vektor:

$$\vec{PQ} = \begin{bmatrix} x_2 - x_1 \\ y_2 - y_1 \end{bmatrix}$$

Ha a térben veszünk két pontot: $P(x_1, y_1, z_1)$ és $Q(x_2, y_2, z_2)$.

Akkor a két pont közti vektor:

$$\vec{PQ} = \begin{bmatrix} x_2 - x_1 \\ y_2 - y_1 \\ z_2 - z_1 \end{bmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két pont a síkban: $P(x_1, y_1)$ és $Q(x_2, y_2)$.

Ekkor a két pont közti távolság:

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

Ha a térben veszünk két pontot: $P(x_1, y_1, z_1)$ és $Q(x_2, y_2, z_2)$.

Akkor a két pont közti távolság a térben:

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (z_1 - z_2)^2}$$

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0)$ ponton átmenő és $\underline{n} = \begin{pmatrix} A \\ B \end{pmatrix}$ normálvektorú egyenes egyenlete:

$$A \cdot (x - x_0) + B \cdot (y - y_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0, z_0)$ ponton átmenő és $\underline{n} = \begin{pmatrix} A \\ B \\ C \end{pmatrix}$ normálvektorú sík egyenlete:

$$A \cdot (x - x_0) + B \cdot (y - y_0) + C \cdot (z - z_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két vektor: $\underline{a} = \begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix}$ és $\underline{b} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}$

A két vektor vektoriális szorzata:

$$\underline{a} \times \underline{b} = \det \begin{bmatrix} \underline{e}_1 & \underline{e}_2 & \underline{e}_3 \\ a_1 & a_2 & a_3 \\ b_1 & b_2 & b_3 \end{bmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az \underline{a} és \underline{b} vektorok vektoriális szorzata az $\underline{a} \times \underline{b}$ vektor, ami merőleges az \underline{a} és \underline{b} vektorok által kifeszített síkra, és

$$\underline{a} = \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} \quad \underline{b} = \begin{pmatrix} b_1 \\ b_2 \\ b_3 \end{pmatrix} \quad \underline{a} \times \underline{b} = \det \begin{pmatrix} \underline{e}_1 & \underline{e}_2 & \underline{e}_3 \\ a_1 & a_2 & a_3 \\ b_1 & b_2 & b_3 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

A V nem üres halmazt vektortérnek nevezzük a valós számok felett, ha a V halmazon értelmezve van egy összeadás nevű művelet, úgy, hogy minden V -beli \underline{v}_1 és \underline{v}_2 vektorhoz hozzárendelünk egy $\underline{v}_1 + \underline{v}_2$ vektort, ami szintén eleme V -nek.

1. Az összeadás kommutatív: bármely $\underline{v}_1, \underline{v}_2$ V -beli vektorra

$$\underline{v}_1 + \underline{v}_2 = \underline{v}_2 + \underline{v}_1$$

2. Az összeadás asszociatív: bármely $\underline{v}_1, \underline{v}_2, \underline{v}_3$ V -beli vektorra

$$(\underline{v}_1 + \underline{v}_2) + \underline{v}_3 = \underline{v}_1 + (\underline{v}_2 + \underline{v}_3)$$

3. Létezik nullelem: van olyan $\underline{0}$ V -beli vektor, hogy bármely \underline{v}_1 V -beli vektorra

$$\underline{v}_1 + \underline{0} = \underline{0} + \underline{v}_1 = \underline{v}_1$$

4. Létezik ellentett: bármely \underline{v}_1 V bel vektorra létezik olyan $-\underline{v}_1$ V -beli vektor, hogy

$$\underline{v}_1 + (-\underline{v}_1) = -\underline{v}_1 + \underline{v}_1 = \underline{0}$$

Értelmezve van egy skalárral való szorzás nevű művelet is úgy, hogy minden V -beli \underline{v}_1 vektorhoz és bármely valós számhoz hozzárendelünk egy $\lambda \cdot \underline{v}_1$ vektort, ami szintén V -beli.

5. A skalárszoros asszociatív: bármely \underline{v}_1 V -beli vektorra és λ, μ skalárra

$$(\lambda \cdot \mu) \cdot \underline{v}_1 = \lambda \cdot (\mu \cdot \underline{v}_1)$$

6. A skalárszoros disztributív a vektorokra: bármely $\underline{v}_1, \underline{v}_2$ V -beli vektorra és λ skalárra

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

7. A skalárszoros disztributív a skalárookra: bármely \underline{v}_1 V -beli vektorra és λ, μ skalárra

$$(\lambda + \mu) \cdot \underline{v}_1 = \lambda \cdot \underline{v}_1 + \mu \cdot \underline{v}_1$$

8. Egységyszeres: bármely \underline{v}_1 V -beli vektorra és az 1 valós számra

$$1 \cdot \underline{v}_1 = \underline{v}_1$$

[Megnézem a kapcsolódó epizódot](#)

A $\underline{v}_1, \underline{v}_2, \underline{v}_3, \dots, \underline{v}_n$ [vektorok](#) lineárisan függetlenek, ha

$$\lambda_1 \cdot \underline{v}_1 + \lambda_2 \cdot \underline{v}_2 + \lambda_3 \cdot \underline{v}_3 + \dots + \lambda_n \cdot \underline{v}_n = \underline{0}$$

csak úgy teljesül, ha minden $\lambda_i = 0$

[Megnézem a kapcsolódó epizódot](#)

A $\underline{v}_1, \underline{v}_2, \underline{v}_3, \dots, \underline{v}_n$ [vektorok](#) lineárisan összefüggők, ha

$$\lambda_1 \cdot \underline{v}_1 + \lambda_2 \cdot \underline{v}_2 + \lambda_3 \cdot \underline{v}_3 + \dots + \lambda_n \cdot \underline{v}_n = \underline{0}$$

úgy is teljesül, hogy van olyan $\lambda_i \neq 0$

[Megnézem a kapcsolódó epizódot](#)

Egy V vektortérben a $\underline{v}_1, \underline{v}_2, \underline{v}_3, \dots, \underline{v}_n$ [vektorok](#) generátor-rendszert alkotnak, ha minden \underline{w} vektor a V vektortérben előáll $\underline{w} = \lambda_1 \cdot \underline{v}_1 + \lambda_2 \cdot \underline{v}_2 + \lambda_3 \cdot \underline{v}_3 + \dots + \lambda_n \cdot \underline{v}_n$ alakban.

[Megnézem a kapcsolódó epizódot](#)

A $\underline{v}_1, \underline{v}_2, \underline{v}_3, \dots, \underline{v}_n$ [vektorok](#) független rendszert alkotnak, ha

$$\lambda_1 \cdot \underline{v}_1 + \lambda_2 \cdot \underline{v}_2 + \lambda_3 \cdot \underline{v}_3 + \dots + \lambda_n \cdot \underline{v}_n = \underline{0}$$

csak úgy teljesül, ha minden $\lambda_i = 0$

[Megnézem a kapcsolódó epizódot](#)

A bázis független generátorrendszer.

A bázis minden vektort egyértelműen előállít, míg \mathbb{R}^* -ben azok a generátor-rendszerek pedig, amelyek n -nél több vektorból állnak, minden vektort végtelensokféleképpen.

[Megnézem a kapcsolódó epizódot](#)

Egy vektorrendszer rangja a benne lévő független [vektorok](#) maximális száma. \mathbb{R}^3 -ban a rang például maximum három lehet.

[Megnézem a kapcsolódó epizódot](#)

A V vektortérnek W altere, ha $W \subset V$ és W maga is vektortér a V -beli műveletekre.

[Megnézem a kapcsolódó epizódot](#)

Egy vektor akkor állítható egy vektorrendszerrel, ha előáll azon [vektorok](#) lineáris kombinációjaként.

[Megnézem a kapcsolódó epizódot](#)

Vektorok, egyenesek és síkok egyenletei

Van itt két vektor: $\underline{a} = (a_1, a_2)$, $\underline{b} = (b_1, b_2)$

A két vektor összege:

$$\underline{a} + \underline{b} = (a_1 + b_1, a_2 + b_2)$$

A két vektor különbsége:

$$\underline{a} - \underline{b} = (a_1 - b_1, a_2 - b_2)$$

$$\overrightarrow{AB} = \underline{b} - \underline{a}$$

[Megnézem a kapcsolódó epizódot](#)

Van itt az $\underline{a} = (a_1, a_2)$ és $\underline{b} = (b_1, b_2)$ vektor.

Az \underline{a} vektor hossza:

$$|\underline{a}| = \sqrt{a_1^2 + a_2^2}$$

Az \overrightarrow{AB} vektor hossza:

$$|\overrightarrow{AB}| = |\underline{b} - \underline{a}| = \sqrt{(b_1 - a_1)^2 + (b_2 - a_2)^2}$$

És pont ugyanígy kapjuk meg az A és B pontok távolságát is.

[Megnézem a kapcsolódó epizódot](#)

Két pont közti vektor a végpontba mutató helyvektor minusz a kezdőpontba mutató helyvektor.

$$\text{Tehát } \overrightarrow{AB} = \underline{b} - \underline{a}$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két vektor: $\underline{a} = (a_1, a_2)$, $\underline{b} = (b_1, b_2)$.

Az \underline{a} és \underline{b} vektorok skaláris szorzata:

$$\underline{a} \cdot \underline{b} = |\underline{a}| \cdot |\underline{b}| \cdot \cos \gamma = a_1 \cdot b_1 + a_2 \cdot b_2$$

ahol γ a két vektor által bezárt szög

$$|\underline{a}| = \sqrt{a_1^2 + a_2^2}, \text{ vagyis az } \underline{a} \text{ vektor hossza}$$

$$|\underline{b}| = \sqrt{b_1^2 + b_2^2}, \text{ vagyis a } \underline{b} \text{ vektor hossza}$$

Két vektor merőleges egymásra, ha $\underline{a} \cdot \underline{b} = 0$.

[Megnézem a kapcsolódó epizódot](#)

Van itt az $\underline{a} = (a_1, a_2)$ vektor.

Az \underline{a} +90°-os elforgatottja:

$$\underline{a}^{+90^\circ} = (-a_2, a_1)$$

Az \underline{a} -90°-os elforgatottja:

$$\underline{a}^{-90^\circ} = (a_2, -a_1)$$

[Megnézem a kapcsolódó epizódot](#)

Két vektor skaláris szorzatát kiszámolhatjuk így:

$$\underline{a} \cdot \underline{b} = |\underline{a}| \cdot |\underline{b}| \cdot \cos \gamma$$

ahol γ a két vektor által bezárt szög,

$$|\underline{a}| = \sqrt{a_1^2 + a_2^2}, \text{ vagyis az } \underline{a} \text{ vektor hossza}$$

$$|\underline{b}| = \sqrt{b_1^2 + b_2^2}, \text{ vagyis az } \underline{b} \text{ vektor hossza}$$

Illetve kiszámolhatjuk így is:

$$\underline{a} \cdot \underline{b} = a_1 \cdot b_1 + a_2 \cdot b_2$$

[Megnézem a kapcsolódó epizódot](#)

Két vektor merőleges egymásra, ha skaláris szorzatuk 0, azaz ha $\underline{a} \cdot \underline{b} = 0$.

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0)$ ponton átmenő és $\underline{n} = \begin{bmatrix} A \\ B \end{bmatrix}$ normálvektorú egyenes egyenlete:

$$A(x - x_0) + B(y - y_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0, z_0)$ ponton átmenő és $\underline{n} = \begin{bmatrix} A \\ B \\ C \end{bmatrix}$ normálvektorú sík egyenlete:

$$A(x - x_0) + B(y - y_0) + C(z - z_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

Van a síkban két pont: $P(x_1, y_1)$ és $Q(x_2, y_2)$.

Ekkor a két pont közti vektor:

$$\vec{PQ} = \begin{bmatrix} x_2 - x_1 \\ y_2 - y_1 \end{bmatrix}$$

Ha a térben veszünk két pontot: $P(x_1, y_1, z_1)$ és $Q(x_2, y_2, z_2)$.

Akkor a két pont közti vektor:

$$\vec{PQ} = \begin{bmatrix} x_2 - x_1 \\ y_2 - y_1 \\ z_2 - z_1 \end{bmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két pont a síkban: $P(x_1, y_1)$ és $Q(x_2, y_2)$.

Ekkor a két pont közti távolság:

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

Ha a térben veszünk két pontot: $P(x_1, y_1, z_1)$ és $Q(x_2, y_2, z_2)$.

Akkor a két pont közti távolság a térben:

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + (z_1 - z_2)^2}$$

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0)$ ponton átmenő és $\underline{n} = \begin{pmatrix} A \\ B \end{pmatrix}$ normálvektorú egyenes egyenlete:

$$A \cdot (x - x_0) + B \cdot (y - y_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

A $P(x_0, y_0, z_0)$ ponton átmenő és $\underline{n} = \begin{pmatrix} A \\ B \\ C \end{pmatrix}$ normálvektorú sík egyenlete:

$$A \cdot (x - x_0) + B \cdot (y - y_0) + C \cdot (z - z_0) = 0$$

[Megnézem a kapcsolódó epizódot](#)

Van itt két vektor: $\underline{a} = \begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix}$ és $\underline{b} = \begin{bmatrix} b_1 \\ b_2 \\ b_3 \end{bmatrix}$

A két vektor vektoriális szorzata:

$$\underline{a} \times \underline{b} = \det \begin{bmatrix} \underline{e}_1 & \underline{e}_2 & \underline{e}_3 \\ a_1 & a_2 & a_3 \\ b_1 & b_2 & b_3 \end{bmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Az \underline{a} és \underline{b} vektorok vektoriális szorzata az $\underline{a} \times \underline{b}$ vektor, ami merőleges az \underline{a} és \underline{b} vektorok által kifeszített síkra, és

$$\underline{a} = \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} \quad \underline{b} = \begin{pmatrix} b_1 \\ b_2 \\ b_3 \end{pmatrix} \quad \underline{a} \times \underline{b} = \det \begin{pmatrix} \underline{e}_1 & \underline{e}_2 & \underline{e}_3 \\ a_1 & a_2 & a_3 \\ b_1 & b_2 & b_3 \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Lineáris egyenletrendszerek, mátrixok inverze

Egy egyenletrendszer együtthatómátrixa az x -ek együtthatóiból álló [mátrix](#).

[Megnézem a kapcsolódó epizódot](#)

A Gauss-elimináció egy lineáris egyenletrendszerek megoldására használt algoritmus.

Az elimináció lényege, hogy egyenletrendszerünket visszavezetjük vagy valamely háromszög- vagy átlós [mátrix](#) alakra.

A Gauss-elimináció megengedett lépései:

- Két sort (egyenletet) felcserélhetünk
- Egy sort (egyenletet) nem nulla számmal szorozhatunk
- Egyik sorhoz (egyenlethez) hozzáadhatjuk egy másik sor (egyenlet) nem nulla számsorosát

[Megnézem a kapcsolódó epizódot](#)

Az elemi bázistranszformáció (Szuper-Gauss) a lineáris egyenletrendszerek megoldásának egy algoritmikus módja.

1. lépés: a generáló elem választása

Csak x -es oszlopból és e -s sorból választhatunk generáló elemet, nullát nem választhatunk és lehetőleg 1-et vagy mínusz 1-et érdemes.

2. lépés: a bázistranszformáció

A generáló elem sorát osztjuk a generáló elemmel, oszlopát elhagyjuk.

A többi elemből kivonjuk a generáló elem neki megfelelő sorában és oszlopában lévő számok szorzatát, osztva a generálóelemmel.

3. lépés: megint generáló elem választás

Újra és újra végrehatjuk a bázistranszformációt, amíg az összes oszlop el nem tűnik

4. lépés: az utolsó transzformáció és a megoldás

[Megnézem a kapcsolódó epizódot](#)

Az elemi bázistranszformáció (Szuper-Gauss) a lineáris egyenletrendszerek megoldásának egy algoritmikus módja.

1. lépés: a generáló elem választása

Csak x -es oszlopból és e -s sorból választhatunk generáló elemet, nullát nem választhatunk és lehetőleg 1-et vagy mínusz 1-et érdemes.

2. lépés: a bázistranszformáció

A generáló elem sorát osztjuk a generáló elemmel, oszlopát elhagyjuk.

A többi elemből kivonjuk a generáló elem neki megfelelő sorában és oszlopában lévő számok szorzatát, osztva a generálóelemmel.

3. lépés: megint generáló elem választás

Újra és újra végrehatjuk a bázistranszformációt, amíg az összes oszlop el nem tűnik

4. lépés: az utolsó transzformáció és a megoldás

[Megnézem a kapcsolódó epizódot](#)

Ha egy egyenletrendszernek több az ismeretlene, mint ahány egyenlete van, akkor az egyenletrendszernek nincs egyértelmű megoldása.

Bázistranszformációval, ha maradnak e -s sorok ahol már nem tudunk generáló elemet választani, olyankor mindig végtelen sok megoldás van, vagy nincs megoldás.

[Megnézem a kapcsolódó epizódot](#)

Ha egy egyenletrendszerben két olyan egyenlet szerepel, ahol az ismeretlenek együtthatói megegyeznek, de más az eredményük, akkor az ellentmondó egyenletrendszer, aminek nincs megoldása.

[Megnézem a kapcsolódó epizódot](#)

A bázistranszformáció során fent maradt x -ek úgynevezett szabadváltozók. A szabadságfok a szabadváltozók száma, tehát ahány x_i főt maradt.

[Megnézem a kapcsolódó epizódot](#)

Négyzetes [mátrixok](#) inverzét a Gauss-elimináció segítségével úgy állíthatjuk elő, hogy megoldjuk az $Ax = b$ egyenletrendszert úgy, hogy a b helyére beírjuk az egységmátrixot. Az eliminációs lépéseket addig kell végezni, amíg az egységmátrixot nem kapjuk az A helyén, a b helyén keletkezett [mátrix](#) pedig az A [mátrix](#) inverze lesz.

[Megnézem a kapcsolódó epizódot](#)

Négyzetes [mátrixok](#) inverzét a bázistranszformáció segítségével úgy állíthatjuk elő, hogy megoldjuk az $Ax = b$ egyenletrendszert úgy, hogy a b helyére beírjuk az egységmátrixot.

[Megnézem a kapcsolódó epizódot](#)

Négyzetes [mátrixok](#) inverzét a Gauss-Jordan elimináció segítségével úgy állíthatjuk elő, hogy megoldjuk az $Ax = b$ egyenletrendszert úgy, hogy a b helyére beírjuk az egységmátrixot.

[Megnézem a kapcsolódó epizódot](#)

Az inverz kiszámolása rettentő egyszerű dolog. Mindössze annyit kell tennünk, hogy felírjuk a mátrixot a szokásos táblázatba, és mellé írjuk az egységmátrixot. Ezek után jön a bázistranszformáció. Ha nem tudjuk mindegyik x -et levinni, akkor nincs inverz. Ha mindet le tudjuk vinni, akkor van.

[Megnézem a kapcsolódó epizódot](#)

Determináns, sajátérték, sajátvektor, leképezések

Ha az A egy $n \times n$ -es [mátrix](#), akkor determinánsa

$$\det(A) = \sum_{\forall p} (-1)^{I(p)} \cdot \prod_{i=1}^n a_{ip(i)}$$

ahol p az oszlopindexek permutációi, $I(p)$ pedig ezen permutációk inverziószáma.

[Megnézem a kapcsolódó epizódot](#)

Egy 2×2 -es [mátrix](#) determinánsa:

$$A = \begin{pmatrix} a & b \\ c & d \end{pmatrix} \quad \det(A) = \det \begin{pmatrix} a & b \\ c & d \end{pmatrix} = a \cdot d - b \cdot c$$

[Megnézem a kapcsolódó epizódot](#)

A 3×3 -as [mátrixok](#) determinánásának kiszámolására van egy szabály, ami szarrusz szabály néven ismert. A szabály lényege, hogy fogjuk a mátrixot és leírjuk saját maga mögé még egyszer, majd vesszük a főátlókat és a mellékátlókat, így

$$\det(A) = -a_{13}a_{22}a_{31} - a_{11}a_{23}a_{32} - a_{12}a_{21}a_{33} + a_{11}a_{22}a_{33} + a_{12}a_{23}a_{31} + a_{13}a_{21}a_{32}$$

[Megnézem a kapcsolódó epizódot](#)

Ha az A egy $n \times n$ -es [mátrix](#), akkor determinánsa

$$A = \begin{pmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{pmatrix}$$

$$\det(A) = \sum_{j=1}^n (-1)^{i+j} a_{ij} \cdot \det(A_{ij})$$

Itt $\det(A_{ij})$ az a_{ij} elemhez tartozó aldetermináns.

[Megnézem a kapcsolódó epizódot](#)

Az A mátrix determinánása nulla, ha

- van csupa nulla sora
- van két azonos sora
- egyik sora a másik sor számszorosa
- egyik sora más sorok lineáris kombinációja
- mindez sor helyett oszlopra is elmondható

Determinánsok szorzási tétele:

$$\det(A \cdot B) = \det(A) \cdot \det(B)$$

$$\det(A^k) = \det(A)^k$$

[Megnézem a kapcsolódó epizódot](#)

Azokat a mátrixokat nevezzük szingulárisnak, amelyek determinánása nulla.

Az A mátrix szinguláris:

- $\det(A) = 0$
- Nem létezik A^{-1} inverz mátrix
- $\text{RANG} < n$
- Az A mátrix oszlopvektoraiból álló vektorrendszer lineárisan összefüggő
- Az $A \cdot \underline{x} = \underline{b}$ egyenletrendszernek vagy végtelen sok megoldása van vagy nincs megoldása
- Az $A \cdot \underline{x} = \underline{0}$ homogén lineáris egyenletrendszernek végtelen sok megoldása van

[Megnézem a kapcsolódó epizódot](#)

Azokat a mátrixokat nevezzük regulárisnak, amelyek determinánása nem nulla.

Az A mátrix reguláris:

- $\det(A) \neq 0$
- Létezik A^{-1} inverz mátrix
- $\text{RANG} = n$
- Az A mátrix oszlopvektoraiból álló vektorrendszer lineárisan független
- Az $A \cdot \underline{x} = \underline{b}$ egyenletrendszernek csak egy megoldása van
- Az $A \cdot \underline{x} = \underline{0}$ homogén lineáris egyenletrendszernek csak egy megoldása van (a triviális megoldás)

[Megnézem a kapcsolódó epizódot](#)

A Cramer szabály szerint az $A \cdot \underline{x} = \underline{b}$ egyenletrendszer megoldásai a következőképp állnak elő:

$$x_k = \frac{\det(A_k)}{\det(A)}$$

ahol $\det(A_k)$ annak a mátrixnak a determinánsát jelenti, hogy az A mátrix k -edik oszlopát kicseréljük a \underline{b} vektorral.

[Megnézem a kapcsolódó epizódot](#)

Az A $n \times n$ -es [mátrix](#) sajátértéke egy olyan λ valós szám, amelyhez van valami \underline{v} nem nullvektor, hogy $A \cdot \underline{v} = \lambda \cdot \underline{v}$

A sajátérték lényege, hogy vannak olyan [mátrixok](#), és olyan [vektorok](#), hogyha a mátrixot megszorozzuk a vektorral, akkor az eredeti vektornak egy számszorosát kapjuk. Az egységmátrixpéldául ilyen: ha az egységmátrixszal megszorozunk egy tetszőleges vektort, akkor ugyanazt a vektort kapjuk. Ilyenkor minden vektor sajátvektor és a sajátérték 1, mert minden vektorból az 1-szerese lesz.

A saját[vektorok](#) és sajátértékek egyik legfontosabb alkalmazása a geometriai transzformációk, amelyek szintén mátrixokkal írhatók le. A síkbeli tükrözés az x tengelyre például egy geometriai transzformáció, aminek a mátrixa két sajátértékkel rendelkezik. Az x tengelyen lévő vektorokkal a tükrözés hatására nem történik semmi. Ezek tehát saját maguk 1-szeresei lesznek. Az y tengelyen lévő [vektorok](#) viszont az x tengelyre történő tükrözéskor "megfordulnak" vagyis beszorzódnak -1-gyel. A tükrözés mátrixának tehát ezek lesznek a sajátértékei. Az 1 és a -1. Mindez sokkal érthetőbb lesz, ha megnézed a kapcsolódó epizódot.

[Megnézem a kapcsolódó epizódot](#)

Az A $n \times n$ -es [mátrix](#) sajátvektora egy olyan \underline{v} nem nullvektor, amelyhez van valami λ valós szám, hogy $A \cdot \underline{v} = \lambda \cdot \underline{v}$

A sajátvektor lényege, hogy vannak olyan [mátrixok](#), és olyan [vektorok](#), hogyha a mátrixot megszorozzuk a vektorral, akkor az eredeti vektornak egy számszorosát kapjuk. A saját[vektorok](#) és sajátértékek egyik legfontosabb alkalmazása a geometriai transzformációk, amelyek szintén mátrixokkal írhatók le.

Vegyük például a síkbeli tükrözést az x tengelyre. Ez egy geometriai transzformáció. Az x tengelyen lévő vektorokkal a tükrözés hatására nem történik semmi. Ezek tehát saját maguk 1-szeresei lesznek. Vagyis ezek a [vektorok](#) egytől egyig saját[vektorok](#), mert teljesítik azt amit egy sajátvektornak tudnia kell: ha megszorozzuk a mátrixot a vektorral, akkor az eredeti vektor számszorosát kapjuk. Itt most éppen az eredeti vektor 1-szeresét kapjuk. Az y tengelyen lévő [vektorok](#) szintén saját[vektorok](#), mert az x tengelyre történő tükrözéskor "megfordulnak" vagyis beszorzódnak -1-gyel. Vagyis ezek a [vektorok](#) saját maguk -1-szeresei lesznek. A tükrözés mátrixának tehát ezek lesznek a sajátvektorai: az x tengely és az y tengely vektorai. Az x tengelyen lévő sajátvektorokhoz tartozó sajátérték az 1, míg az y tengelyen lévő sajátvektorokhoz tartozó sajátérték a -1. Mindez sokkal érthetőbb lesz, ha megnézed a kapcsolódó epizódot.

[Megnézem a kapcsolódó epizódot](#)

A karakterisztikus egyenlet a sajátértékek kiszámolásához szükséges egyenlet:

$$\det(A - \lambda \cdot I) = 0$$

A karakterisztikus egyenlet segít nekünk kiszámolni egy [mátrix](#) sajátértékeit. A sajátértékeket úgy kapjuk, hogy a karakterisztikus polinomot egyenlővé tesszük nullával. Így egy egyenletet kapunk, és ennek az egyenletnek a megoldásai a sajátértékek. Az egyenletet karakterisztikus egyenletnek is szokás nevezni, és egyetlen bökkenő vele, hogy egy $n \times n$ -es [mátrix](#) karakterisztikus egyenlete n -edfokú. Vagyis 2-nél és 3-nál még valahogyan meg tudjuk oldani az egyenletet, de mondjuk egy 5×5 -ös mátrixnál már ötödfokú egyenletet kapunk, amivel adódhatnak gondok.

[Megnézem a kapcsolódó epizódot](#)

A karakterisztikus polinom:

$$\det(A - \lambda \cdot I)$$

A karakterisztikus polinom segít nekünk kiszámolni egy [mátrix](#) sajátértékeit. A sajátértékeket úgy kapjuk, hogy a karakterisztikus polinomot egyenlővé tesszük nullával. Így egy egyenletet kapunk, és ennek az egyenletnek a megoldásai a sajátértékek. Vagyis a sajátértékek mindig a karakterisztikus polinom gyökei. Előfordul, hogy egy sajátérték többszörös gyök, és az is megeshet, hogy komplex gyökei vannak a karakterisztikus polinomnak.

Azt az egyenletet, amikor a karakterisztikus polinomot egyenlővé tesszük nullával karakterisztikus egyenletnek is szokás nevezni, és egyetlen bökkenő vele, hogy egy $n \times n$ -es [mátrix](#) karakterisztikus egyenlete n -edfokú. Vagyis 2-nél és 3-nál még valahogyan meg tudjuk oldani az egyenletet, de mondjuk egy 5×5 -ös mátrixnál már ötödfokú egyenletet kapunk, amivel adódhatnak gondok.

[Megnézem a kapcsolódó epizódot](#)

Ha egy $n \times n$ -es mátrixnak van n darab független sajátvektora, akkor létezik a mátrixnak egy úgynevezett diagonális alakja.

A diagonális alak így néz ki:

$$\text{diag}(A) = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_n \end{pmatrix}$$

a főatlóban vannak a sajátértékek és az összes többi elem nulla.

A diagonális alakot a következő módon állítjuk elő:

$$\text{diag}(A) = X^{-1} \cdot A \cdot X$$

$$\text{itt } X = (\underline{v}_1 \quad \underline{v}_2 \quad \dots \underline{v}_n)$$

[Megnézem a kapcsolódó epizódot](#)

Ha egy $n \times n$ -es mátrixnak van n darab független sajátvektora, akkor létezik a mátrixnak egy úgynevezett diagonális alakja.

A diagonális alak így néz ki:

$$\text{diag}(A) = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_n \end{pmatrix}$$

a főatlóban vannak a sajátértékek és az összes többi elem nulla.

A diagonális alakot a következő módon állítjuk elő:

$$\text{diag}(A) = X^{-1} \cdot A \cdot X$$

$$\text{itt } X = (\underline{v}_1 \quad \underline{v}_2 \quad \dots \underline{v}_n)$$

[Megnézem a kapcsolódó epizódot](#)

Ha egy $n \times n$ -es mátrixnak van n darab független sajátvektora, akkor létezik a mátrixnak egy úgynevezett diagonális alakja.

A diagonális alak így néz ki:

$$\text{diag}(A) = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_n \end{pmatrix}$$

a főatlóban vannak a sajátértékek és az összes többi elem nulla.

A diagonális alakot a következő módon állítjuk elő:

$$\text{diag}(A) = X^{-1} \cdot A \cdot X$$

$$\text{itt } X = (\underline{v}_1 \quad \underline{v}_2 \quad \dots \underline{v}_n)$$

[Megnézem a kapcsolódó epizódot](#)

Ha az A mátrix egy $n \times n$ -es diagonalizálható mátrix, akkor a sajátfelbontása:

$$A = X \cdot \text{diag}(A) \cdot X^{-1}$$

Itt $X = (\underline{v}_1 \quad \underline{v}_2 \quad \dots \quad \underline{v}_n)$ vagyis egyszerűen úgy keletkezi, hogy a sajátvektorokat fogjuk, és leírjuk egymás mellé és

$$\text{diag}(A) = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_n \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

A spektrálfelbontás segítségével könnyebben hatványozhatunk:

$$A^n = X \cdot (\text{diag}(A))^n \cdot X^{-1}$$

[Megnézem a kapcsolódó epizódot](#)

Egy mátrix sarak főminor mátrixai a mátrix bal felső sarkától kezdődő sarak mátrixok determinánsai.

$$\text{Pl.: } A = \begin{pmatrix} 2 & 3 & 5 & 1 \\ 4 & 7 & 2 & 1 \\ 2 & 1 & 14 & \\ 3 & 5 & 1 & 7 \end{pmatrix}$$

első sarokfőminora a 2-es

második sarokfőminora a bal felső 2x2-es determináns

$$\det \begin{pmatrix} 2 & 3 \\ 4 & 7 \end{pmatrix} = 2 \cdot 7 - 3 \cdot 4 = 2$$

és így tovább

[Megnézem a kapcsolódó epizódot](#)

Egy [mátrix](#) főminor mátrixai a [mátrix](#) bal felső sarkától kezdődő sarok [mátrixok](#) determinánsai.

$$\text{Pl.: } A = \begin{pmatrix} 2 & 3 & 5 & 1 \\ 4 & 7 & 2 & 1 \\ 2 & 1 & 14 & \\ 3 & 5 & 1 & 7 \end{pmatrix}$$

első főminora a 2-es

második főminora a bal felső 2x2-es determináns

$$\det \begin{pmatrix} 2 & 3 \\ 4 & 7 \end{pmatrix} = 2 \cdot 7 - 3 \cdot 4 = 2$$

és így tovább

[Megnézem a kapcsolódó epizódot](#)

Az A $n \times n$ -es [mátrix](#) pozitív definit, ha minden λ sajátérték: $\lambda > 0$.

Vagy ha minden sarokfőminor pozitív.

[Megnézem a kapcsolódó epizódot](#)

Az A $n \times n$ -es [mátrix](#) negatív definit, ha minden λ sajátérték: $\lambda < 0$.

Vagy ha a sarokfőminorok váltakozva $- + - +$ de mínusszal indul.

[Megnézem a kapcsolódó epizódot](#)

Az A $n \times n$ -es [mátrix](#) pozitív szemidefinit, ha minden λ sajátérték: $\lambda \geq 0$.

2x2-es mátrixoknál, ha az első sarokfőminor pozitív, a második nulla.

[Megnézem a kapcsolódó epizódot](#)

Az A $n \times n$ -es [mátrix](#) negatív szemidefinit, ha minden λ sajátérték: $\lambda \leq 0$.

2x2-es mátrixoknál, ha az első sarokfőminor negatív, a második nulla.

[Megnézem a kapcsolódó epizódot](#)

Az A $n \times n$ -es [mátrix](#) indefinit, ha van λ_1 és λ_2 sajátérték, hogy $\lambda_1 > 0$ és $\lambda_2 < 0$.

Ha $\det(A) \neq 0$ és nem pozitív vagy negatív definit, akkor indefinit.

[Megnézem a kapcsolódó epizódot](#)

Ha A $n \times n$ -es szimmetrikus [mátrix](#) és \underline{x} egy vektor \mathbb{R}^n -ben, akkor a

$$Q(\underline{x}) = \underline{x}^* \cdot A \cdot \underline{x}$$

kifejezést kvadratikus alaknak nevezzük.

Azért hívjuk kvadratikusnak vagyis négyzetesnek, mert ez mindig egy homogén másodfokú kifejezés.

[Megnézem a kapcsolódó epizódot](#)

A $Q(\underline{x}) = \underline{x}^* \cdot A \cdot \underline{x}$ kvadratikus alak

pozitív definit, ha minden $\underline{x} \neq \underline{0}$ vektorra $Q(\underline{x}) > 0$

negatív definit, ha minden $\underline{x} \neq \underline{0}$ vektorra $Q(\underline{x}) < 0$

pozitív szemidefinit, ha minden $\underline{x} \neq \underline{0}$ vektorra $Q(\underline{x}) \geq 0$

negatív szemidefinit, ha minden $\underline{x} \neq \underline{0}$ vektorra $Q(\underline{x}) \leq 0$

indefinit, ha van olyan $\underline{x} \neq \underline{0}$ és $\underline{y} \neq \underline{0}$, hogy $Q(\underline{x}) < 0$ és $Q(\underline{y}) > 0$

[Megnézem a kapcsolódó epizódot](#)

A φ leképezést lineáris leképezésnek nevezzük, ha bármely $\underline{v}_1, \underline{v}_2 \in V_1$ vektorokra és $\lambda \in \mathbb{R}$ 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 bázisvektorok 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](#)

Ha egy $n \times n$ -es mátrixnak van n darab független sajátvektora, akkor létezik a mátrixnak egy úgynevezett diagonális alakja.

A diagonális alak így néz ki:

$$\text{diag}(A) = \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \dots & \dots & \dots & \dots \\ 0 & 0 & \dots & \lambda_n \end{pmatrix}$$

a főatlóban vannak a sajátértékek és az összes többi elem nulla.

A diagonális alakot a következő módon állítjuk elő:

$$\text{diag}(A) = X^{-1} \cdot A \cdot X$$

$$\text{itt } X = (\underline{v}_1 \quad \underline{v}_2 \quad \dots \quad \underline{v}_n)$$

[Megnézem a kapcsolódó epizódot](#)

A φ lineáris leképezésnek a $\underline{b}_1 \underline{b}_2 \dots \underline{b}_n$ bázisban felírt mátrixát úgy kapjuk meg, hogy a bázisvektorok képeit egymás mellé írjuk:

$$(\varphi)_b = (\varphi(\underline{b}_1) \varphi(\underline{b}_2) \varphi(\underline{b}_3) \dots \varphi(\underline{b}_n))$$

Bármilyen bázist is választunk is V_1 -ben, a leképezés mátrixa mindig egy $n \times n$ -es mátrix lesz. Ha ennek a mátrixnak van n darab független sajátvektora, akkor ezek a sajátvektorok szintén egy bázist alkotnak V_1 -ben, amit sajátbázisnak nevezünk.

[Megnézem a kapcsolódó epizódot](#)

A $V_1 \rightarrow V_2$ lineáris leképezést másnéven homomorfizmusnak is nevezzük. Ezek a homomorfizmusok és azok mátrixai maguk is egy vektorteret alkotnak, ezt a vektorteret $Hom(V_1, V_2)$ -nek nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Ha A és B olyan mátrixok, hogy létezik egy C mátrix úgy, hogy

$$A = C^{-1} \cdot B \cdot C$$

akkor a két mátrix egymáshoz hasonló.

[Megnézem a kapcsolódó epizódot](#)

Gram-Schmidt ortogonalizáció, LU és QR felbontás, pszeudoinverz

Azokat a vektorokat, ahol a [vektorok](#) egymásra merőlegesek ortogonális rendszernek nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Az olyan mátrixot, ahol minden elem egy-egy [vektorok](#) szorzata, szorzótáblaszerűen elrendezve, Gram mátrixnak nevezzük.

Pl. a $\underline{b}_1, \underline{b}_2, \underline{b}_3$ [vektorok](#) Gram mátrixa:

$$\begin{pmatrix} \langle \underline{b}_1, \underline{b}_1 \rangle & \langle \underline{b}_1, \underline{b}_2 \rangle & \langle \underline{b}_1, \underline{b}_3 \rangle \\ \langle \underline{b}_2, \underline{b}_1 \rangle & \langle \underline{b}_2, \underline{b}_2 \rangle & \langle \underline{b}_2, \underline{b}_3 \rangle \\ \langle \underline{b}_3, \underline{b}_1 \rangle & \langle \underline{b}_3, \underline{b}_2 \rangle & \langle \underline{b}_3, \underline{b}_3 \rangle \end{pmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

Hogyha egy ortogonális vektorrendszer éppen annyi vektorból áll, amennyi koordinátája van a vektoroknak, akkor az a vektorrendszer egy ortogonális bázis.

[Megnézem a kapcsolódó epizódot](#)

Ha egy vektorrendszerben bármely két vektor skaláris szorzata 0, akkor az egy ortonormált vektorrendszer.

[Megnézem a kapcsolódó epizódot](#)

Ha egy vektorrendszerben bármely két vektor skaláris szorzata 0 és minden vektora egységnyi hosszú, akkor az egy ortonormált vektorrendszer.

[Megnézem a kapcsolódó epizódot](#)

Az olyan bázist, ahol bármely két vektor skaláris szorzata 0 és minden vektor egység hosszú, ortonormált bázisnak nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Hogyha a $\underline{b}_1, \underline{b}_2, \dots, \underline{b}_n$ [vektorok](#) a V vektortérnek egy bázisa, akkor bármely $\underline{x} \in V$ vektor előállítható a bázisvektorok lineáris kombinációjaként.

$$\lambda_1 \cdot \underline{b}_1 + \lambda_2 \cdot \underline{b}_2 + \dots + \lambda_n \cdot \underline{b}_n = \underline{x}$$

És most végre azt is megtudjuk a [skaláris szorzat](#) segítségével, hogy pontosan mik lesznek ezek a λ_i együtthatók.

A trükk az lesz, hogy beszorozzuk az egyenletet a \underline{b}_1 bázisvektorral...

$$\lambda_1 \cdot \underline{b}_1 \cdot \underline{b}_1 + \lambda_2 \cdot \underline{b}_2 \cdot \underline{b}_1 + \dots + \lambda_n \cdot \underline{b}_n \cdot \underline{b}_1 = \underline{x} \cdot \underline{b}_1$$

Aztán beszorozzuk a \underline{b}_2 bázisvektorral is.

$$\lambda_1 \cdot \underline{b}_1 \cdot \underline{b}_2 + \lambda_2 \cdot \underline{b}_2 \cdot \underline{b}_2 + \dots + \lambda_n \cdot \underline{b}_n \cdot \underline{b}_2 = \underline{x} \cdot \underline{b}_2$$

És így tovább az összesel.

$$\lambda_1 \cdot \underline{b}_1 \cdot \underline{b}_n + \lambda_2 \cdot \underline{b}_2 \cdot \underline{b}_n + \dots + \lambda_n \cdot \underline{b}_n \cdot \underline{b}_n = \underline{x} \cdot \underline{b}_n$$

Az így keletkező n darab egyenletet Gauss-féle normálegyenletnek nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Hogyha a $\underline{b}_1, \underline{b}_2, \dots, \underline{b}_n$ [vektorok](#) a V vektortérben egy ortogonális bázis, és $\underline{x} \in V$ tetszőleges vektor, akkor az

$$\underline{x} = \lambda_1 \cdot \underline{b}_1 + \lambda_2 \cdot \underline{b}_2 + \dots + \lambda_n \cdot \underline{b}_n$$

lineáris kombináció együtthatói felírhatók skaláris szorzatok segítségével:

$$\lambda_1 = \frac{\langle \underline{x}, \underline{b}_1 \rangle}{\langle \underline{b}_1, \underline{b}_1 \rangle}$$

$$\lambda_2 = \frac{\langle \underline{x}, \underline{b}_2 \rangle}{\langle \underline{b}_2, \underline{b}_2 \rangle}$$

⋮

$$\lambda_n = \frac{\langle \underline{x}, \underline{b}_n \rangle}{\langle \underline{b}_n, \underline{b}_n \rangle}$$

Ezeket az együtthatókat Fourier-együtthatóknak nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Az ortogonális [mátrix](#) olyan, ahol az oszlopvektorok egységnyi hosszúak.

[Megnézem a kapcsolódó epizódot](#)

Hogyha Q egy ortogonális [mátrix](#), akkor

$$Q^{-1} = Q^T$$

Q oszlopvektorai ortonormált rendszert alkotnak

Q sorvektorai ortonormált rendszert alkotnak

$$Q \cdot Q^T = Q^T \cdot Q = I$$

[Megnézem a kapcsolódó epizódot](#)

A régi bázis úgy alakítható át ortogonális bázissá, hogy szépen egymás után lecseréljük a régi bázisvektorokat új bázisvektorokra. Az átalakítást Gram-Schmidt ortogonalizációnak nevezzük.

Az új ortogonális bázis legyen \underline{q}_1 , \underline{q}_2 és \underline{q}_3

Az új bázis első vektorát akárhogy választhatjuk, legyen ez mondjuk a régi bázisból \underline{q}_1

$$\underline{q}_1 = \underline{b}_1$$

Aztán lássuk mi lesz az új bázis második vektora:

$$\underline{q}_2 = \underline{b}_2 - \lambda_{21} \cdot \underline{q}_1 \quad \lambda_{21} = \frac{\langle \underline{q}_1, \underline{b}_2 \rangle}{\langle \underline{q}_1, \underline{q}_1 \rangle}$$

Itt jön aztán az új bázis harmadik vektora:

$$\underline{q}_3 = \underline{b}_3 - \lambda_{31} \cdot \underline{q}_1 - \lambda_{32} \cdot \underline{q}_2 \quad \lambda_{31} = \frac{\langle \underline{q}_1, \underline{b}_3 \rangle}{\langle \underline{q}_1, \underline{q}_1 \rangle} \quad \lambda_{32} = \frac{\langle \underline{q}_2, \underline{b}_3 \rangle}{\langle \underline{q}_2, \underline{q}_2 \rangle}$$

[Megnézem a kapcsolódó epizódot](#)

Egy [mátrix](#) LU felbontása azt jelenti, hogy a mátrixot felbontjuk egy alsó és egy felső háromszög [mátrix](#) szorzatára. Módszere a Gauss eliminációra épül.

[Megnézem a kapcsolódó epizódot](#)

Egy $n \times n$ -es mátrixnak akkor létezik LU-felbontása, ha az első $n-1$ főminorá nem nulla.

[Megnézem a kapcsolódó epizódot](#)

Hogyha egy olyan [mátrix](#) LU felbontására van szükségünk, amelynek valamelyik (nem utolsó) főminorá 0, akkor megtehetjük azt, hogy egy premutációs [mátrix](#) segítségével felcseréljük a sorait. Hiszen a sorcsere hatására a [mátrix](#) determinánsa, az egyenletrendszer megoldása stb. nem változnak.

[Megnézem a kapcsolódó epizódot](#)

Az LU-felbontás módszere nem négyzetes mátrixokra ugyanolyan, mint eddig, a Gauss elimináció segítségével történik. Legfeljebb az U [mátrix](#) nem lesz négyzetes, így nem lesz valódi felső háromszög [mátrix](#).

[Megnézem a kapcsolódó epizódot](#)

Ha az A mátrix szimmetrikus és pozitív definit mátrix, akkor egyértelműen létezik olyan pozitív diagonális L alsó háromszögmátrix, amelyre:

$$A = L \cdot L^T$$

Ezt a felbontást Cholesky-felbontásnak nevezzük. Ez tulajdonképpen egy olyan LU-felbontás, ahol az U mátrix az L -nek a transzponáltja.

[Megnézem a kapcsolódó epizódot](#)

Hogyha az A egy olyan $n \times k$ -es mátrix, $n \geq k$, és a mátrix teljes oszloprangú, vagyis az oszlopvektorok rangja k , akkor létezik olyan $n \times n$ -es Q ortogonális mátrix, és olyan R felső háromszögmátrix, hogy

$$A = Q \cdot R$$

Ezt a felbontást nevezzük QR-felbontásnak.

[Megnézem a kapcsolódó epizódot](#)

QR-felbontást kaphatunk akkor is, ha az A mátrixot addig-addig szorozgatjuk Givens forgatások mátrixaival, amíg felső háromszögmátrixot nem kapunk.

[Megnézem a kapcsolódó epizódot](#)

Az A mátrixból először készítünk egy felső háromszögmátrixot a Householder-tükrözések segítségével.

Hogyha \underline{a} és \underline{b} különböző vektorok, és teljesül rájuk, hogy $|\underline{a}| = |\underline{b}|$ akkor létezik olyan Householder-tükrözés, ami az \underline{a} vektort a \underline{b} vektorba transzformálja.

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

ahol $\underline{v} = \underline{a} - \underline{b}$.

[Megnézem a kapcsolódó epizódot](#)

Ha egy egyenletrendszernek nincs megoldása, akkor az optimális megoldás megadja a legjobb közelítést.

Az $A\underline{x} = \underline{b}$ egyenletrendszer optimális megoldásai megegyeznek az

$$A^T \cdot A\underline{x} = A^T \cdot \underline{b}$$

egyenletrendszer megoldásaival.

[Megnézem a kapcsolódó epizódot](#)

Az $A\underline{x} = \underline{b}$ egyenletrendszer Gauss-féle normálegyenlete:

$$A^T \cdot A\underline{x} = A^T \cdot \underline{b}$$

[Megnézem a kapcsolódó epizódot](#)

Egy \underline{b} vektort nem csak merőlegesen vetíthetjük, hanem ferdén is. Viszont egyedül a merőleges vetítés rendelkezik a legjobb közelítés tulajdonságával.

A \underline{b} vektor legjobb közelítése a W altérben egy olyan \underline{b}' vektor, amire $|\underline{b} - \underline{b}'|$ minimális.

[Megnézem a kapcsolódó epizódot](#)

Az x és y változó közötti kapcsolat meghatározásához méréseket végzünk.

Az x_1, x_2, \dots , és x_n értékekhez...

Az y_1, y_2, \dots , és y_n értékek tartoznak.

Keressük az a lineáris függvényt, amely a lehető legjobban illeszkedik a mérési pontokra.

Éppen itt is van.

$$y = b_1 \cdot x + b_0$$

A függvény grafikonja akkor illeszkedik a legjobban a mérési pontokra, ha ezek az egyenletek egyszerre teljesülnek:

$$b_1 \cdot \sum_{i=1}^n x_i^2 + b_0 \cdot \sum_{i=1}^n x_i = \sum_{i=1}^n x_i \cdot y_i$$

$$b_1 \cdot \sum_{i=1}^n x_i + b_0 \cdot n = \sum_{i=1}^n y_i$$

Ezeket az egyenleteket normálegyenleteknek nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Az A mátrix Moore-Penrose-féle pseudoinverze egy olyan A^* mátrix, amely ezt a négy dolgot tudja:

$$1) AA^+A = A$$

$$2) A^+AA^+ = A^+$$

$$3) (AA^+)^T = AA^+$$

$$4) (A^+A)^T = A^+A$$

[Megnézem a kapcsolódó epizódot](#)

Kétváltozós függvények

A kétváltozós függvények úgy működnek, hogy két valós számhoz rendelnek hozzá egy harmadik valós számot. Másként fogalmazva számpárokhoz rendelnek hozzá egy harmadik számot.

Ezeket a számpárokat tekinthetjük úgy, mint a sík pontjainak koordinátáit.

A kétváltozós függvények ennek a síknak a pontjaihoz rendelnek hozzá egy harmadik koordinátát, egy magasságot.

Az értelmezési tartomány minden pontjához hozzárendelve ezt a harmadik, magasság koordinátát, kirajzolódik az x , y sík felett a függvény, ami egy felület.

[Megnézem a kapcsolódó epizódot](#)

A Young-tétel szerint vegyes másodrendű deriváltak egyenlők (egészen pontosan akkor egyenlők, ha a függvény kétszer totálisan deriválható):

$$f''_{xy}(x, y) = f''_{yx}(x, y)$$

[Megnézem a kapcsolódó epizódot](#)

Az $f(x, y)$ függvény x szerinti parciális deriváltja:

$$f'_x(x, y)$$

Ez azt jelenti, hogy x szerint deriválunk, y most csak konstansnak számít, ha önállóan áll, akkor deriváltja nulla, ha szorozva van valami x -essel, akkor marad

Az $f(x, y)$ függvény y szerinti parciális deriváltja:

$$f'_y(x, y)$$

Ez azt jelenti, hogy y szerint deriválunk, x most csak konstansnak számít, ha önállóan áll, akkor deriváltja nulla, ha szorozva van valami y -ossal, akkor marad

[Megnézem a kapcsolódó epizódot](#)

Első lépés:

$$\frac{\delta f}{\delta x} = f'_x(x, y) \quad \frac{\delta f}{\delta y} = f'_y(x, y)$$

Második lépés:

$$f'_x(x, y) = 0$$

$$f'_y(x, y) = 0$$

Az egyenletrendszer megoldásai a stacionárius pontok

Harmadik lépés:

$$f'' = \begin{bmatrix} f''_{xx}(x, y) & f''_{xy}(x, y) \\ f''_{yx}(x, y) & f''_{yy}(x, y) \end{bmatrix}$$

Ha $\det \begin{bmatrix} f''_{xx} & f''_{xy} \\ f''_{yx} & f''_{yy} \end{bmatrix}$ pozitív, és $f''_{xx} > 0$, akkor lokális minimum van.

Ha $\det \begin{bmatrix} f''_{xx} & f''_{xy} \\ f''_{yx} & f''_{yy} \end{bmatrix}$ pozitív, és $f''_{xx} < 0$, akkor lokális maximum van.

Ha $\det \begin{bmatrix} f''_{xx} & f''_{xy} \\ f''_{yx} & f''_{yy} \end{bmatrix}$ negatív, akkor nyeregpont van.

Ha $\det \begin{bmatrix} f''_{xx} & f''_{xy} \\ f''_{yx} & f''_{yy} \end{bmatrix}$ nulla, akkor további vizsgálat szükséges, de ilyen nem nagyon szokott lenni.

[Megnézem a kapcsolódó epizódot](#)

Az $f(x, y)$ függvény értelmezési tartományának azon pontjait, ahol mindkét [parciális derivált](#) nulla, az $f(x, y)$ függvény stacionárius pontjainak nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Ha az f többváltozós függvénynek az $x_0 \in D_f$ pontban léteznek f első parciális deriváltjai és

$$\delta_1 f(x_0) = \delta_2 f(x_0) = \dots = \delta_k f(x_0) = 0$$

akkor x_0 az f többváltozós függvény stacionárius pontja.

[Megnézem a kapcsolódó epizódot](#)

A másodrendű deriváltakból képzett [mátrix](#), amely segít eldönteni, hogy a függvénynek a stacionárius pontokban minimuma, maximuma, vagy éppen nyeregpontja van-e.

$$\underline{f}'' = \begin{bmatrix} f''_{xx}(x, y) & f''_{xy}(x, y) \\ f''_{yx}(x, y) & f''_{yy}(x, y) \end{bmatrix}$$

[Megnézem a kapcsolódó epizódot](#)

A sík azon pontjainak összességét, amelyekben az f függvény ugyanazt a konstans értéket veszi fel, azaz $f(x, y) = c$, az f függvény szintvonalának nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Az $f(x, y)$ függvényhez a $P(x_0, y_0, z_0)$ pontban húzott érintősík egyenlete:

$$z = f'_x(x_0, y_0)(x - x_0) + f'_y(x_0, y_0)(y - y_0) + f(x_0, y_0)$$

[Megnézem a kapcsolódó epizódot](#)

Az $f(x, y)$ függvény x és y szerinti deriváltjaiból álló vektort derivált-vektornak vagy másként gradiensnek hívjuk.

Íme a derivált-vektor:

$$\underline{f}'(x_0, y_0) = \begin{bmatrix} f'_x(x_0, y_0) \\ f'_y(x_0, y_0) \end{bmatrix} \quad \text{röviden} \quad \underline{f}' = \begin{bmatrix} f'_x \\ f'_y \end{bmatrix}$$

A derivált-vektor segítségével tudjuk kiszámítani az iránymenti deriváltat.

[Megnézem a kapcsolódó epizódot](#)

Az [iránymenti derivált](#) azt jelenti, hogy egy általunk megadott tetszőleges \underline{v} irány mentén milyen meredeken emelkedik a függvény felülete.

Az $f(x, y)$ függvény \underline{v} iránymenti deriváltja az (x_0, y_0) pontban:

$$\frac{\delta f(x_0, y_0)}{\delta \underline{v}} = \underline{f}'(x_0, y_0) \cdot \underline{v}$$

(Itt \underline{v} egységvektor)

[Megnézem a kapcsolódó epizódot](#)

Egy függvény akkor implicit, ha y nincs kifejezve, vagyis nem $y = \dots$ alakú.

[Megnézem a kapcsolódó epizódot](#)

Ha $F(x, y) = 0$ egy egyváltozós implicit függvény, akkor deriváltja:

$$\frac{\delta y}{\delta x} = -\frac{F'_x(x, y)}{F'_y(x, y)} \quad \frac{\delta x}{\delta y} = -\frac{F'_y(x, y)}{F'_x(x, y)}$$

Ha $F(x_1, x_2, \dots, x_{n-1}) = 0$ egy n változós implicit függvény, akkor az x_i , mint implicit függvény deriváltja az x_j változó szerint:

$$\frac{\delta x_i}{\delta x_j} = -\frac{F'_j(x_1, x_2, \dots, x_{n+1})}{F'_i(x_1, x_2, \dots, x_{n+1})}$$

[Megnézem a kapcsolódó epizódot](#)

Kétváltozós határérték és totális differenciálhatóság

Az $f(x, y)$ [függvény határértéke](#) az $R(x_0, y_0)$ pontban B , ha minden $\epsilon > 0$ -ra van $\delta > 0$ úgy, hogy ha (x, y) eleme az $R(x_0, y_0)$ pont δ sugarú környezetének, vagyis ha

$$0 < \sqrt{(x - x_0)^2 + (y - y_0)^2} < \delta$$

akkor

$$|f(x, y) - B| < \epsilon$$

[Megnézem a kapcsolódó epizódot](#)

Az $f(x, y)$ kétváltozós függvény totálisan differenciálható az (x_0, y_0) helyen, ha léteznek olyan A és B valós számok, hogy

$$\lim_{(x,y) \rightarrow (x_0,y_0)} \frac{f(x,y) - (A(x-x_0) + B(y-y_0) + f(x_0,y_0))}{\sqrt{(x-x_0)^2 + (y-y_0)^2}} = 0$$

[Megnézem a kapcsolódó epizódot](#)

Az $f(x, y)$ kétváltozós függvény x szerinti parciális deriváltja:

$$\lim_{(x,y_0) \rightarrow (x_0,y_0)} \frac{f(x,y_0) - f(x_0,y_0)}{x - x_0} = f'_x(x_0, y_0) = \frac{\delta f(x_0, y_0)}{\delta x}$$

Az $f(x, y)$ kétváltozós függvény y szerinti parciális deriváltja:

$$f'_y(x_0, y_0) = \frac{\delta f(x_0, y_0)}{\delta y}$$

[Megnézem a kapcsolódó epizódot](#)

Kettős és hármas 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](#)

Differenciálegyenletek

A [differenciálegyenletek](#) olyan egyenletek, amiben az ismeretlenek függvények. Az egyenletben ezeknek a függvényeknek a különböző deriváltjai és hatványai szerepelnek.

Ha ez a bizonyos függvény egyváltozós, akkor a differenciálegyenletet közönséges differenciálegyenletnek nevezzük, ha a függvény többváltozós, akkor parciális differenciálegyenletnek.

[Megnézem a kapcsolódó epizódot](#)

A rend azt mondja meg, hogy a függvény maximum hányadik deriváltja szerepel az egyenletben.

[Megnézem a kapcsolódó epizódot](#)

Ha az ismeretlen függvény és deriváltjai csak első fokon szerepelnek a differenciálegyenletben, akkor az egyenlet lineáris.

[Megnézem a kapcsolódó epizódot](#)

A [szeparábilis differenciálegyenlet](#) így néz ki:

$$f(x) dx = g(y) dy$$

Megoldásának menete pedig a következő:

Az y' -t lecseréljük arra, hogy $\frac{dy}{dx}$.

Aztán jön a szétválasztás: minden y -os dolgot a dy -os oldalra viszünk és minden x -eset a dx -es oldalra.

Ezt követően mindkét oldalt integráljuk és megkapjuk a megoldást.

[Megnézem a kapcsolódó epizódot](#)

Egy [differenciálegyenlet](#) homogén fokszámú, ha $y = ux$ helyettesítés után minden x -es tag kitevője megegyezik.

A homogén fokszámú [differenciálegyenletek](#) megoldásának menete a következő:

Először elvégezzük az $y(x) = xu(x)$ (röviden $y = xu$) helyettesítést, ekkor $dy = u \cdot dx + x \cdot du$.

Így ez az egyenlet már szeparábilis, úgyhogy jöhet a szétválasztás.

Megoldjuk a szeparábilis egyenletet, ahol y helyett most u -ra hajtunk. És amikor u már megvan, visszacsináljuk y -ra.

[Megnézem a kapcsolódó epizódot](#)

A $p(x, y)dx + q(x, y)dy = 0$ [differenciálegyenlet](#) akkor egzakt, ha $p'_y(x, y) = q'_x(x, y)$, röviden $\frac{\delta p}{\delta y} = \frac{\delta q}{\delta x}$.

Az egzakt egyenletek megoldása $F(x, y) = C$, ahol $F'_x(x, y) = p(x, y)$ és $F'_y(x, y) = q(x, y)$

A megoldást intgerálással kapjuk:

$$F(x, y) = \int p(x, y) dx$$

[Megnézem a kapcsolódó epizódot](#)

Ha a [differenciálegyenlet](#) nem egzakt, akkor megpróbálhatjuk egzakttá tenni egy integráló tényező segítségével.

Az integráló tényező megtalálásához elsőként kiszámoljuk ezeket:

$$\frac{\frac{\delta p}{\delta y} - \frac{\delta q}{\delta x}}{p} \text{ és } \frac{\frac{\delta p}{\delta y} - \frac{\delta q}{\delta x}}{q}$$

Ha ezek közül az első csak y -t tartalmaz, vagy a második csak x -et tartalmaz, nos olyankor van remény az integráló tényező megtalálására.

Az integráló tényező:

$$u = e^{-\int f(y) dy} \text{ vagy } u = e^{\int g(x) dx}$$

[Megnézem a kapcsolódó epizódot](#)

Az elsőrendű lineáris [differenciálegyenlet](#) általános alakja úgy néz ki, hogy van benne egy y' , és van benne egy elsőfokú y .

$$y' + yP(x) = Q(x)$$

Megoldásának menete pedig a következő:

Kiszámolunk egy $v(x)$ függvényt:

$$v = e^{\int P(x) dx}$$

Beszorozzuk az egyenletet $v(x)$ -el, hogy a bal oldal egy szorzat deriváltja legyen.

$$y'v + yvP(x) = vQ(x)$$

Végül mindkét oldalt integráljuk.

$$\int (yv)' dx = \int vQ(x) dx$$

[Megnézem a kapcsolódó epizódot](#)

A konstans variálás módszere egy megoldási módszer az elsőrendű lineáris differenciálegyenletekhez.

Első lépésként megoldjuk az úgynevezett homogén egyenletet, ami ez:

$$y' + yP(x) = 0$$

A homogén egyenlet megoldása:

$$y_0 = Ce^{-\int P(x) dx}$$

Ezt követően jön a konstansok variálása, azt mondjuk, hogy a megoldásban szereplő konstans legyen egy $C(x)$ függvény. És ezt a $C(x)$ függvényt úgy variáljuk, hogy ha behelyettesítjük az egyenletbe, akkor épp az inhomogén egyenlet jobb oldalát kapjuk.

$$y = C(x)e^{-\int P(x) dx}$$

Az egyenlet megoldását úgy kapjuk meg, hogy a homogén megoldásban $C(x)$ helyére beírjuk, ami kijött.

[Megnézem a kapcsolódó epizódot](#)

Az elsőrendű [lineáris állandó együtthatós differenciálegyenlet](#) egy speciális esete a lineáris elsőrendű egyenleteknek. Azért hívják állandó együtthatósoknak, mert a $P(x)$ függvény ilyenkor valamilyen konstans, mondjuk a .

$$y' + ay = Q(x)$$

Az általános megoldása úgy jön ki, hogy a homogén megoldáshoz hozzáadjuk a partikuláris megoldást.

$$\text{A homogén egyenlet: } y' + ay = 0$$

$$\text{A homogén megoldás: } y_0 = Ce^{-ax}$$

Az általános megoldás: homogén megoldás + partikuláris megoldás

A partikuláris megoldást próbafüggvény módszerrel keressük meg. Az, hogy mi is lesz a partikuláris megoldás, ez mindig a jobb oldali függvényről függ:

$$Q(x) = \text{másodfokú polinom: } y_p = Ax^2 + Bx + C$$

$$Q(x) = \text{harmadfokú polinom: } y_p = Ax^3 + Bx^2 + Cx + D$$

$$Q(x) = \text{exponenciális kifejezés: } y_p = Ae^{\alpha x}$$

$$Q(x) = \text{szinusz vagy koszinusz: } y_p = A\cos \alpha x + B\sin \alpha x$$

[Megnézem a kapcsolódó epizódot](#)

Rezonanciáról beszélünk, ha az elsőrendű [lineáris állandó együtthatós differenciálegyenlet](#) partikuláris megoldásában szerepel $e^{\alpha x}$ és a kitevője éppen megegyezik a homogén megoldás kitevőjével.

[Megnézem a kapcsolódó epizódot](#)

A másodrendű lineáris állandó együtthatós homogén [differenciálegyenlet](#) általános alakja:

$$ay'' + by' + cy = 0$$

A megoldás lépései:

Először megoldjuk a karakterisztikus egyenletet.

Ha a karakterisztikus egyenletnek két különböző valós megoldása van r_1 és r_2 akkor $y = C_1 e^{r_1 x} + C_2 e^{r_2 x}$

Ha a karakterisztikus egyenletnek egy valós megoldása van akkor $y = C_1 e^{rx} + C_2 x e^{rx}$

Ha a karakterisztikus egyenletnek két különböző komplex megoldása van $r_1 = A + Bi$ és $r_2 = A - Bi$ akkor $y = e^{Ax} (C_1 \cos Bx + C_2 \sin Bx)$

[Megnézem a kapcsolódó epizódot](#)

A másodrendű lineáris állandó együtthatós inhomogén [differenciálegyenlet](#) általános alakja:

$$ay'' + by' + cy = Q(x)$$

A megoldás lépései:

Először megoldjuk a karakterisztikus egyenletet: $ar^2 + br + c = 0$.

Ha a karakterisztikus egyenletnek két különböző valós megoldása van r_1 és r_2 akkor $y = C_1 e^{r_1 x} + C_2 e^{r_2 x}$

Ha a karakterisztikus egyenletnek egy valós megoldása van akkor $y = C_1 e^{rx} + C_2 x e^{rx}$

Ha a karakterisztikus egyenletnek két különböző komplex megoldása van $r_1 = A + Bi$ és $r_2 = A - Bi$ akkor $y = e^{Ax} (C_1 \cos Bx + C_2 \sin Bx)$

Ezzel megkapjuk a homogén megoldást.

A partikuláris megoldást próbafüggvény módszerrel végezzük:

$$Q(x) = \text{polinom: } y_p = A_n x^n + A_{n-1} x^{n-1} + \dots + A_1 x + A_0$$

$$Q(x) = \text{exponenciális kifejezés: } y_p = A e^{\alpha x}$$

$$Q(x) = \text{szinusz vagy koszinusz: } y_p = A \cos \alpha x + B \sin \alpha x$$

Az általános megoldás a homogén megoldás és partikuláris megoldás összege.

[Megnézem a kapcsolódó epizódot](#)

Izoklinák

Azon pontok halmazát, melyekben a megoldásfüggvények meredeksége egy adott számmal egyenlő, a [differenciálegyenlet](#) izoklinájának nevezzük.

Az $y' = f(x, y(x))$ izoklináinak egyenlete:

$$f(x, y(x)) = K$$

[Megnézem a kapcsolódó epizódot](#)

Sorok & hatványsorok & Taylor-sorok

Azokat a sorokat nevezzük mértani sornak, amelyek így néznek ki, mint ez:

$$\sum_{n=0}^{\infty} a_1 q^n$$

Ha $|q| < 1$ akkor a mértani sor konvergens és összege

$$\sum_{n=0}^{\infty} a_1 q^n = \frac{a_1}{1-q}$$

Ha $|q| \geq 1$ akkor a sor divergens.

[Megnézem a kapcsolódó epizódot](#)

Egy végtelen sor akkor konvergens, ha részletösszege sorozata konvergens és ekkor a sor összege:

$$\sum_{n=1}^{\infty} a_n = \lim S_n$$

[Megnézem a kapcsolódó epizódot](#)

Ha $\lim a_n \neq 0$ akkor $\sum a_n$ divergens.

[Megnézem a kapcsolódó epizódot](#)

A $\sum (-1)^n \cdot a_n$ sor konvergens, ha $a_n \rightarrow 0$ monoton csökkenő sorozat.

[Megnézem a kapcsolódó epizódot](#)

A $\sum a_n$ sor konvergenciája a gyök kritérium alapján így dönthető el:

Ha $\lim \sqrt[n]{|a_n|} < 1$ akkor $\sum a_n$ abszolút konvergens.

Ha $\lim \sqrt[n]{|a_n|} > 1$ akkor $\sum a_n$ divergens.

Ha $\lim \sqrt[n]{|a_n|} = 1$ akkor nem tudunk semmit.

[Megnézem a kapcsolódó epizódot](#)

A $\sum a_n$ sor konvergenciája a hányados kritérium alapján így dönthető el:

Ha $\lim \left| \frac{a_{n+1}}{a_n} \right| < 1$ akkor $\sum a_n$ abszolút konvergens.

Ha $\lim \left| \frac{a_{n+1}}{a_n} \right| > 1$ akkor $\sum a_n$ divergens.

Ha $\lim \left| \frac{a_{n+1}}{a_n} \right| = 1$ akkor nem tudunk semmit.

[Megnézem a kapcsolódó epizódot](#)

Ha $a_n \rightarrow 0$ pozitív tagú monoton csökkenő sorozat, akkor a

$$\sum (-1)^n a_n = -a_1 + a_2 - a_3 + a_4 - \dots$$

végtelen sort Leibniz sornak nevezzük.

[Megnézem a kapcsolódó epizódot](#)

Ha $\sum a_n$ és $\sum b_n$ nem negatív tagú sorok, és egy bizonyos tagtól $a_n \leq b_n$ akkor

$$\sum b_n \text{ konvergens} \Rightarrow \sum a_n \text{ is konvergens}$$

$$\sum a_n \text{ divergens} \Rightarrow \sum b_n \text{ is divergens}$$

[Megnézem a kapcsolódó epizódot](#)

$$\sum_{n=1}^{\infty} \frac{1}{n^\alpha} = \begin{cases} \text{konvergens, ha } \alpha > 1 \\ \text{divergens, ha } \alpha \leq 1 \end{cases}$$

[Megnézem a kapcsolódó epizódot](#)

A teleszkopikus sorok olyan végtelennek tűnő összegek, amik megfelelő átalakítások után már csak véges sok tagból állnak.

Például:

$$\sum_{n=1}^{\infty} \frac{1}{n(n+1)} = \frac{1}{1 \cdot 2} + \frac{1}{2 \cdot 3} + \frac{1}{3 \cdot 4} + \dots + \frac{1}{n(n+1)} = \frac{1}{1} - \frac{1}{2} + \frac{1}{2} - \frac{1}{3} + \frac{1}{3} - \frac{1}{4} + \dots + \frac{1}{n} - \frac{1}{n+1} = 1 - \frac{1}{n+1}$$

[Megnézem a kapcsolódó epizódot](#)

Ha x_0 a [hatványsor](#) középpontja, akkor az x_0 pont r sugarú környezetét konvergencia tartománynak nevezzük, ahol r a konvergenciasugár.

A [konvergencia tartomány](#) belső pontjaiban a [hatványsor](#) abszolút konvergens, a végpontokat pedig külön kell vizsgálni.

[Megnézem a kapcsolódó epizódot](#)

Ha x_0 a [hatványsor](#) középpontja, akkor az x_0 pont r sugarú környezetét konvergencia tartománynak nevezzük.

A [konvergencia tartomány](#) belső pontjaiban a [hatványsor](#) abszolút konvergens, a végpontokat pedig külön kell vizsgálni.

[Megnézem a kapcsolódó epizódot](#)

Legyen $f(x)$ k -szor differenciálható egy I intervallumon, ami tartalmazza az a számot. Ekkor az $f(x)$ függvény a pontban felírt k -adfokú Taylor polinomja:

$$T(x) = \sum_{n=0}^k \frac{f^{(n)}(a)}{n!} (x - a)^n$$

[Megnézem a kapcsolódó epizódot](#)

Legyen $f(x)$ akárhányszor differenciálható egy I intervallumon, ami tartalmazza az a számot. Ekkor az $f(x)$ függvény a pontban felírt Taylor sora:

$$T(x) = \sum_{n=0}^{\infty} \frac{f^{(n)}(a)}{n!} (x - a)^n$$

[Megnézem a kapcsolódó epizódot](#)

Az e^x , $\ln x$, $\sin x$ és $\cos x$ függvények Taylor sorai:

$$e^x = \sum_{n=0}^{\infty} \frac{1}{n!} x^n \quad \ln x = \sum_{n=1}^{\infty} \frac{(-1)^{n-1}}{n} (x - 1)^n$$

$$\cos x = \sum_{n=0}^{\infty} \frac{(-1)^n}{(2n)!} x^{2n} \quad \sin x = \sum_{n=0}^{\infty} \frac{(-1)^n}{(2n+1)!} x^{2n+1}$$

[Megnézem a kapcsolódó epizódot](#)

Ha $f(x)$ egymás után k -szor folytonosan differenciálható az $[a, b]$ zárt intervallumon, és $k + 1$ -edszer differenciálható az (a, b) nyílt intervallumon, akkor létezik olyan $c \in (a, b)$ amire

$$f(b) = T(b) + R(b) = \sum_{n=0}^k \frac{f^{(n)}(a)}{n!} (b - a)^n + \frac{f^{(k+1)}(c)}{(k+1)!} (b - a)^{k+1}$$

[Megnézem a kapcsolódó epizódot](#)

Azokat a végtelen sorokat, amelyek így néznek ki, hatványsornak nevezzük:

$$\sum a_n (x - x_0)^n$$

[Megnézem a kapcsolódó epizódot](#)

Fourier sorok

A [Fourier sor](#) a 2π szerint periodikus függvények egy speciális függvénysora:

$$a_0 + \sum_{n=1}^{\infty} a_n \cos nx + b_n \sin nx$$

ahol az úgynevezett Fourier-együtthetők:

$$a_0 = \frac{1}{2\pi} \int_C^{C+2\pi} f(x) dx \quad a_n = \frac{1}{\pi} \int_C^{C+2\pi} f(x) \cos nx dx \quad b_n = \frac{1}{\pi} \int_C^{C+2\pi} f(x) \sin nx dx$$

[Megnézem a kapcsolódó epizódot](#)

Laplace transzformáció

Az $f(x)$ függvény Laplace transzformáltja a következő integrálás:

$$f(x) \rightarrow F(s) = \int_0^{\infty} f(x)e^{-sx} dx$$

[Megnézem a kapcsolódó epizódot](#)

Néhány függvény Laplace transzformáltja:

$$f(x) = C \rightarrow F(s) = \frac{C}{s}$$

$$f(x) = x^n \rightarrow F(s) = \frac{n!}{s^{n+1}}$$

$$f(x) = e^{ax} \rightarrow F(s) = \frac{1}{s-a}$$

$$f(x) = \sin(ax) \rightarrow F(s) = \frac{a}{s^2+a^2}$$

$$f(x) = \cos(ax) \rightarrow F(s) = \frac{s}{s^2+a^2}$$

$$f(x) = x^n e^{ax} \rightarrow F(s) = \frac{n!}{(s-a)^{n+1}}$$

$$f(x) = e^{ax} \sin(bx) \rightarrow F(s) = \frac{b}{(s-a)^2+b^2}$$

$$f(x) = e^{ax} \cos(bx) \rightarrow F(s) = \frac{s-a}{(s-a)^2+b^2}$$

$$f(x) = x \sin(ax) \rightarrow F(s) = \frac{2as}{(s^2+a^2)^2}$$

$$f(x) = x \cos(ax) \rightarrow F(s) = \frac{s^2-a^2}{(s^2+a^2)^2}$$

[Megnézem a kapcsolódó epizódot](#)

Néhány függvény inverz Laplace transzformáltja:

$$F(s) = \frac{C}{s} \rightarrow f(x) = C$$

$$F(s) = \frac{n!}{s^{n+1}} \rightarrow f(x) = x^n$$

$$F(s) = \frac{1}{s-a} \rightarrow f(x) = e^{ax}$$

$$F(s) = \frac{a}{s^2+a^2} \rightarrow f(x) = \sin(ax)$$

$$F(s) = \frac{s}{s^2+a^2} \rightarrow f(x) = \cos(ax)$$

$$F(s) = \frac{n!}{(s-a)^{n+1}} \rightarrow f(x) = x^n e^{ax}$$

$$F(s) = \frac{b}{(s-a)^2+b^2} \rightarrow f(x) = e^{ax} \sin(bx)$$

$$F(s) = \frac{s-a}{(s-a)^2+b^2} \rightarrow f(x) = e^{ax} \cos(bx)$$

$$F(s) = \frac{2as}{(s^2+a^2)^2} \rightarrow f(x) = x \sin(ax)$$

$$F(s) = \frac{s^2-a^2}{(s^2+a^2)^2} \rightarrow f(x) = x \cos(ax)$$

[Megnézem a kapcsolódó epizódot](#)

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 kíséző triéder.

[Megnézem a kapcsolódó epizódot](#)

Az $r(t)$ 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 $r'(t) \times r''(t)$.

[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:

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

[Megnézem a kapcsolódó epizódot](#)

Az $r(t) = (x(t), y(t))$ paraméteres görbe görbülete:

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

[Megnézem a kapcsolódó epizódot](#)

Hogyha a görbének egy P pontjában létezik nem nulla görbülete, akkor azt a kört, amely a 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 simulókörök 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](#)

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:

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

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](#)

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:

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

#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.

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

Ezt a tételt divergencia-tételnek vagy másként Gauss-Ostrogradskij-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](#)

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](#)

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.

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

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](#)

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 tetszőleges 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](#)

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 becslni kívánt mennyiséggel.

Ez a tulajdonság azt jelenti, hogy a becslés során kapott értékek a becslni 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 becslni 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 eljárásán 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 határozzunk 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 .

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

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](#)

Regressziószámítás

A **regresszió** egyenes egyenlete:

$$y = b_0 + b_1 \cdot x$$

$$\text{Ahol } b_1 = \frac{\sum dx \cdot dy}{\sum d^2x} \text{ és } b_0 = \bar{y} - b_1 \cdot \bar{x}$$

A regressziós egyenes egyenletében szereplő regressziós paraméterek közül b_1 az egyenes meredeksége. A b_0 érték kevésbé jelentős, ez azt adja meg, hogy a magyarázó változó nulla értékéhez milyen y érték tartozik.

[Megnézem a kapcsolódó epizódot](#)

$$\text{A regressziós egyenes egyenlete } \hat{y} = \hat{b}_0 + \hat{b}_1 \cdot x$$

Ez egy **lineáris függvény**, ami mindegyik x -hez hozzárendel valamilyen y -t. Ezek általában eltérnek a valódi y -októl. Ezeket az eltéréseket reziduumoknak nevezzük.

[Megnézem a kapcsolódó epizódot](#)

A reziduumokból képzett mutató az úgynevezett SSE, jelentése sum of squares of the errors vagyis eltérés-négyzetösszeg.

$$SSE = \sum e_i^2 = \sum (y_i - \hat{y}_i)^2$$

Ha a **regresszió** tökéletesen illeszkedik, akkor az $e_i = y_i - \hat{y}_i$ különbségek mindegyike 0, így $SSE=0$. Ha az illeszkedés nem tökéletes, akkor SSE egy pozitív érték, ami az illeszkedés pontatlanságát méri.

[Megnézem a kapcsolódó epizódot](#)

Ha az SSE értékeit elosztjuk a megfigyelt pontok számával és a kapott eredménynek vesszük a gyökét, akkor kapjuk a reziduális szórást:

$$s_e^* = \sqrt{\frac{SSE}{n}} = \sqrt{\frac{\sum e_i^2}{n}} = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}}$$

[Megnézem a kapcsolódó epizódot](#)

Az illeszkedés egy mérőszáma a lineáris **korrelációs együttható**:

$$r = \frac{\sum dx \cdot dy}{\sqrt{\sum d^2x \cdot \sum d^2y}}$$

A lineáris **korrelációs együttható** azt méri, hogy x és y között milyen szoros lineáris kapcsolat van. Értéke mindig $-1 \leq r \leq 1$.

[Megnézem a kapcsolódó epizódot](#)

A magyarázóerőt méri az úgynevezett determinációs együttható, melynek jele R^2 . Ez a kétváltozós lineáris modell esetében megegyezik r^2 -tel.

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST}$$

Itt SSE az eltérés-négyzetösszeg, míg SSR az úgynevezett regressziós, vagy magyarázó négyzetösszeg, SST pedig a teljes négyzetösszeg, a köztük lévő kapcsolat pedig...

$$SST = \sum d^2 y \quad SSR = \sum (\hat{y}_i - \bar{\hat{y}})^2 = b_1^2 \sum d^2 x \quad SSE = \sum (y_i - \hat{y}_i)^2 = \sum e_i^2$$

[Megnézem a kapcsolódó epizódot](#)

A [regresszió](#) egyenes egyenlete:

$$\hat{y} = \hat{b}_0 + \hat{b}_1 x$$

Amból

$$\lg \hat{y} = \lg \hat{b}_0 + \hat{b}_1 \cdot \lg x$$

$$\text{Ahol } \hat{b}_1 = \frac{\sum d \lg x \cdot d \lg y}{\sum d^2 \lg x} \text{ és } \lg \hat{b}_0 = \overline{\lg y} - \overline{\lg x} \cdot \hat{b}_1$$

[Megnézem a kapcsolódó epizódot](#)

A [regresszió](#) egyenes egyenlete:

$$\hat{y} = \hat{b}_0 \cdot \hat{b}_1^x$$

Amból

$$\lg \hat{y} = \lg \hat{b}_0 + x \cdot \hat{b}_1$$

$$\text{Ahol } \lg \hat{b}_1 = \frac{\sum dx \cdot d \lg y}{\sum d^2 x} \text{ és } \lg \hat{b}_0 = \overline{\lg y} - \bar{x} \cdot \lg \hat{b}_1$$

[Megnézem a kapcsolódó epizódot](#)

Az elaszticitás két összefüggő jelenség közti kapcsolat.

$$\text{Lineáris modellben: } El(\hat{y}, x) = \frac{\hat{b}_1 x}{\hat{y}} = \frac{\hat{b}_1 x}{\hat{b}_0 + \hat{b}_1 x}$$

$$\text{Hatványkitevős modellben: } El(\hat{y}, x) = \hat{b}_1$$

$$\text{Exponenciális modellben: } El(\hat{y}, x) = x \cdot \ln \hat{b}_1$$

[Megnézem a kapcsolódó epizódot](#)

- I. A magyarázó változók nem valószínűségi változók.
- II. A magyarázó változók lineárisan független rendszert alkotnak.
- III. Az eredményváltozó közel lineáris függvénye a magyarázó változónak.
- IV. Az ϵ hibatag feltételes eloszlása normális, várható értéke nulla.
- V. Az ϵ hibatag különböző x -ekhez tartozó értékei korrelálatlanok.

[Megnézem a kapcsolódó epizódot](#)

A paraméterek becslése:

$$\hat{b}_i \pm t_{1-\frac{\alpha}{2}} \cdot (n - k - 1) \cdot s_{\hat{b}_i}$$

A [regresszió](#) becslése:

$$\hat{y}_* \pm t_{1-\frac{\alpha}{2}} \cdot (n - k - 1) \cdot s_{\hat{y}_*}$$

[Megnézem a kapcsolódó epizódot](#)

A többváltozós regressziós modelleket olyankor alkalmazzuk, amikor az eredményváltozó alakulását több magyarázó változó tükrében vizsgáljuk.

A többváltozós [lineáris regresszió](#) egyenlete:

$$y = \hat{b}_0 + \hat{b}_1 x_1 + \hat{b}_2 x_2 + \dots + \hat{b}_k x_k + \epsilon$$

Az y eredményváltozó itt k darab magyarázó változótól és a hibatagtól függ.

A képletben a \hat{b}_0 paraméter a tengelymetszet, a többi \hat{b}_i paraméter pedig azt jelenti, hogy az i -edik magyarázó változó egy egységgel történő változása, mennyivel változtatja az \hat{y} értéket, ha a többi magyarázó változót rögzítjük.

[Megnézem a kapcsolódó epizódot](#)

A kétváltozós esethez hasonlóan a [korreláció](#) itt is a változók közti kapcsolat szorosságát írja le, csak hogy itt egy fokkal rosszabb a helyzet, ugyanis most bármely két változó korrelációját vizsgálhatjuk. Ezt tartalmazza a korrelációmátrix.

$$R = \begin{pmatrix} 1 & r_{y1} & r_{y2} & \dots & r_{yk} \\ r_{1y} & 1 & r_{12} & \dots & r_{1k} \\ r_{2y} & r_{21} & 1 & \dots & r_{2k} \\ \dots & \dots & \dots & \dots & \dots \\ r_{ky} & r_{k1} & r_{k2} & \dots & 1 \end{pmatrix}$$

Itt r_{ij} az x_i és az x_j magyarázó változók közti korrelációt írja le, tehát például r_{12} az x_1 és az x_2 közti korrelációt jelenti.

r_{iy} pedig az x_i magyarázó változó és az y eredményváltozó közti kapcsolatot jelenti.

Mivel $r_{ij} = r_{ji}$ a [korreláció-mátrix](#) szimmetrikus. Az áttekinthetőbb felírás kedvéért a felső háromszöget el is szokták hagyni.

[Megnézem a kapcsolódó epizódot](#)

A [lineáris regresszió](#) egyenlete: $\hat{y} = \hat{b}_0 + \hat{b}_1x_1 + \hat{b}_2x_2 + \dots + \hat{b}_kx_k$

A tesztelés úgy zajlik, hogy nullhipotézisnek tekintjük a $H_0 : b_i = 0$ feltevést, ellenhipotézisnek pedig azt, hogy $H_1 : b_i \neq 0$.

A nullhipotézis azt állítja, hogy a modellben a b_i paraméter szignifikánsan nulla, vagyis az i -edik magyarázó változó felesleges, annak hatása az eredményváltozóra nulla. Az ellenhipotézis ezzel szemben az, hogy $b_i \neq 0$ vagyis az i -edik magyarázó változónak a regresszióban nem nulla hatása van.

[Megnézem a kapcsolódó epizódot](#)

Szóródás oka	Négyzetösszeg	Szabadságfok	Átlagos négyzetösszeg	F
Regresszió	SSR	k	$MSR = \frac{SSR}{k}$	$F = \frac{MSR}{MSE}$
Hiba	SSE	$n - k - 1$	$MSE = \frac{SSE}{n - k - 1}$	
Teljes	SST	$n - 1$		

[Megnézem a kapcsolódó epizódot](#)

A multikollinearitás röviden összefoglalva azt jelenti, hogy két vagy több magyarázó változó között túl szoros [korrelációs kapcsolat](#) van, és ez zavarja a becslést.

A multikollinearitás mérésére az úgynevezett VIF (variance inflator factor) variancia növelő faktor van forgalomban.

$$VIF_j = \frac{1}{1 - R_j^2}$$

A képletben szereplő R_j^2 a j -edik magyarázó változó és az összes többi magyarázó változó közti determinációs együttható.

[Megnézem a kapcsolódó epizódot](#)

Az auto**korreláció** a **regresszió** maradéktagjának a saját későbbi értékeivel való korrelációját jelenti, vagyis egyfajta szabályszerűséget a maradékváltozóban. Ideális esetben a maradéktagnak véletlenszerűnek kell lennie, bármiféle szabályszerűségért a magyarázó változók felelnek a regresszióban.

Az autó**korreláció** tesztelésére a Durbin-Watson-tesztet használjuk.

[Megnézem a kapcsolódó epizódot](#)

A Durbin-Watson-teszt lényegében egy hipotézisvizsgálat, aminek részletezésére nem térünk ki, mindössze a használatát nézzük meg.

Maga a próbafüggvény

$$d = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=2}^n e_t^2}$$

A **szignifikanciaszint** α , a próba elvégzése pedig az alábbi módon történik:

d_L és d_U értékeket kikeressük a táblázatból,

n = a megfigyelések száma,

k = a magyarázó változók száma,

végül megnézzük, hogy a próbafüggvény melyik tartományba esik.

[Megnézem a kapcsolódó epizódot](#)
