

11. Gyakorlat

Nevezetes folytonos eloszlások

Elméleti összefoglaló

Exponenciális eloszlás

[> **with(Statistics)** :

Tekintsünk egy olyan konstrukciót, ahol egy (végtelen hosszúságú) *egyenes mentén pontok szóródnak valamilyen átlagos egyenletes sűrűséggel*. A gyakorlatban sok, ezzel modellezhető helyzet van; akár térben, akár időben (időtengelyen) szóródhatnak a megfigyelt, pontszerűnek tekinthető események (ill. azok valószínűségi változóval számszerűsített értékei).

Ilyen modell szerint rendeződnek el pl. egy adott pillanatban egy útszakaszon az autók - ha légifelvételt készítünk az útszakaszcól, akkor térben, de ha az amúgy mozgó járműveket egy megfigyelési ponton számláljuk, akkor időben is. Ezen analógia szerint érthetően ugyanilyen modell szerint jönnek velünk szemben a járókelők az utcán, megfigyelt meteorok a légkörbe, vagy műszerrel érzékelt részecskék egy radioaktív forrásból.

A modell tipikusan arra az esetre használható, ha egy (térbeli vagy időbeli) szakaszon hosszabb távon *az átlagos pontsűrűség ismert* (elméleti úton meghatározható, vagy kísérletileg megmérhető). A pontok száma persze (adott hosszúságú szakaszokon újra és újra megszámlálva) ezen átlag körül ingadozásokat mutat (a lehetséges darabszámokhoz tartozó megfelelő valószínűségekkel). Ezen eloszlás viszont nemhogy maga is pontosan meghatározott a konstrukció által, de ráadásul (érdekes és egyáltalán nem triviális módon) olyan szoros és egyértelmű összefüggésben van a saját átlagával, hogy a teljes szerkezete maradéktalanul jellemezhető vele, mint egyetlen paraméterrel (λ) – a megfigyelt szakaszon mért átlagos darabszámon kívül semmilyen más információra nincs szükség az előfordulási darabszámok valószínűségeinek leírásához.

A konstrukcióban a tipikusan feltehető kérdések:

1. *Egy adott szakaszon hány pontra milyen valószínűséggel lehet számítani? (Adott hosszúságú szakaszon mérhető darabszám valószínűségi eloszlása.)*
2. *Az egyes pontok között mekkora távolságra milyen valószínűséggel lehet számítani? (Pontok közti távolság valószínűségi eloszlása.)*

Az első kérdésre a *Poisson-eloszlás*, a másodikra a most sorra kerülő *exponenciális eloszlás* ad választ. A kettő jelentősen eltér már abban is, hogy előbbi diszkrét, utóbbi folytonos, mégis összefüggnek a közös modell révén.

Vizsgáljuk meg ezúttal a 2. kérdést! (A előző heti forgalomszámlálás feladatát tekintve ez az a kérdés lenne, hogy mennyi idő telik el a –közvetlenül egymás után haladó– járművek érkezése között.)

A szakaszra eső darabszámot leíró valószínűségi változó értékészlete egész számokból áll (diszkrét), viszont az idő folytonos, ezért a szomszédos pontok közti távolságot leíró valószínűségi változó is folytonos.

A Poisson-eloszlás felhasználásával könnyen fel lehet írni a szomszédos pontok távolságának eloszlásfüggvényét. Ennek definíció szerinti felírásához azt kell kiszámolnunk, hogy egy adott ponttól mérve milyen valószínűséggel van a következő (ténylegesen T távolságra levő) pont egy adott, a függvény változójaként szereplő x távolságon belül. Egyszerűbb viszont az ellentét-eseményt vizsgálni, vagyis hogy milyen valószínűséggel *nincs* újabb pont x -en belül. Erre pedig a választ a Poisson-eloszlás szolgáltatja, az x hosszúságú szakaszra számolt darabszám várható értéke, mint paraméter, és $k = 0$ előfordulási darabszám helyettesítésével.


Ha feltételezzük, hogy az előfordulási darabszám várható értéke egységnyi hosszon éppen λ , akkor x hosszon éppen $\lambda \cdot x$. Ezek szerint a λ paraméterű exponenciális eloszlású T valószínűségi változó eloszlásfüggvénye:

$$F_T(x) = P(T < x) = 1 - F_{\text{Poisson}(\lambda \cdot x)}(0) = 1 - e^{-\lambda \cdot x}$$

```
> F := (lambda, x) -> 1 - exp(-lambda*x);
      F := (\lambda, x) -> 1 - e^{-\lambda x} (1.1.1.1)
```

Az exponenciális eloszlás éppen erről az eloszlásfüggvényében (és sűrűségfüggvényében) megjelenő exponenciális függvényről kapta a nevét. A forgalomszámlálás példánkban szereplő adattal:

```
> lambdaperc := 6;
  plot(F(lambdaperc, x), x = 0..1, thickness = 3);
      lambdaperc := 6
```



A grafikon vízszintes tengelye percek szerint van skálázva. Látszik, hogy 1 percnél többet szinte soha nem kell várni a következő autóra.

Egész pontosan az 1 percnél hosszabb várakozás valószínűsége az 1 percnél rövidebb várakozás komplementereként számolva:

$$P(T > 1) = 1 - P(T < 1) = 1 - F_T(1)$$

```
> `P(T > 1)` := 1 - F(lambdaperc,1); evalf(%);
      P(T > 1) := e^{-6}
```

0.002478752177

(1.1.1.2)

Vagyis csak kb. 2.5 ezrelék valószínűséggel lesz 1 percnél hosszabb hézag két áthaladó autó között.

Az exponenciális eloszlás sűrűségfüggvénye:


$$f_T(x) = \frac{d}{dx} F_T(x) = \lambda \cdot e^{-\lambda \cdot x}$$

```
> f := (lambda, x) -> diff(F(lambda, x), x);
```

$$f := (\lambda, x) \rightarrow \frac{\partial}{\partial x} F(\lambda, x)$$

(1.1.1.3)

```
> plot(f(lambdaperc, x), x = 0..1, thickness = 3);
```



Ha ez valóban egy valószínűségi sűrűségfüggvény, akkor egységnyi terület van "szétkenve" a görbe alatt. Erről integrálással (improprius!) győződhetünk meg:

```
> assume(lambda > 0);  
int(f(lambda, x), x = 0..infinity);
```

1

(1.1.1.4)

Vegyük észre, hogy a sűrűségfüggvény 0-ban jobbról vett határértéke éppen λ , vagyis az időegység alatt várható események darabszáma. Jelen esetben ez 6, megfelelően annak, hogy az időegységként választott *perc* alatt átlagosan 6 jármű érkezik. Más időegység választása esetén nyilván más λ -val kell számolnunk.

Az exponenciális eloszlás várható értéke és szórása egyaránt a λ paraméter reciproka:

$$E(T) = \sigma(T) = \frac{1}{\lambda}$$

A pontok közti távolság várható értékére kapott $\frac{1}{\lambda}$ érték összhangban van az egységszakaszon mért darabszám λ várható értékével: ha pl. ha az egységnyi hosszúságú szakaszra átlagosan 3 pont esik, akkor nem meglepő, hogy a köztük lévő távolság átlagos értéke $\frac{1}{3}$.

▼ **Normál eloszlás**

A sok tényező összegzett hatása által kialakított valószínűségi változók eloszlása nagyon sok esetben harangszerű alakot vesz fel, mely mögött a valószínűségszámítás és statisztika méltán legnevezetesebb eloszlása, az ún. *normál eloszlás* áll. A természetben a statisztikai vizsgálatokkal mérhető paraméterek legtöbbje ilyen eloszlást közelít: legyen szó pl. a július hónap sokévi középhőmérsékletéről, az esőcseppek méretéről, a boltban vásárolható kilós kenyerek pontos tömegéről vagy pl. a felnőtt férfiak testmagasságáról.

A normál eloszlás sűrűségfüggvényének alakja (harang-görbe) jól meghatározott. Különböző esetekben figyelve ugyan a csúcsa (várható értéke) kerülhet máshova, és a lapultsága (szórása) is változhat, de lineáris transzformációkkal (nyújtásokkal, zsugorításokkal, eltolásokkal) bármelyik bármely másikba átvihető. A normál eloszlások bármelyike jellemezhető mindössze két paraméterrel: a várható értékkel és a szórással.


Szokás kijelölni a sok közül egy szabványosat: az ún. *standard normál eloszlást*, mely 0 várható értékkel és 1 szórással rendelkezik:

```
> N := RandomVariable(Normal(0, 1));  
N := _R (1.1.2.1)
```

Ennek sűrűségfüggvénye:

```
> f := x -> PDF(N, x) : 'f'(x) = f(x);  
plot(f(x), x = -4..4);
```

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




A görbe alatti teljes terület bizonyíthatóan 1.

Az eloszlásfüggvény:

```
> F := x -> CDF(N, x) : 'F'(x) = F(x);  
plot(F(x), x = -4 .. 4);
```

$$F(x) = \frac{1}{2} + \frac{1}{2} \operatorname{erf}\left(\frac{1}{2} x \sqrt{2}\right)$$



Az eloszlásfüggvény a sűrűségfüggvény integrálja. Különös viszont, hogy neki, mint a matematika egyik legnevezetesebb függvényének nincs zárt alakja. Márpedig a normál eloszlásokkal kapcsolatos számításokhoz folyamatosan ezt a függvényt kell használni, de az értékek csak közelítéssel számíthatók (amúgy tetszőleges pontossággal, tehát a gyakorlatban nem jelent különösebb problémát, de elméleti szempontból fontos, megjegyzendő tény, hogy egzaktsal számolható zárt formula nincs).


Bármilyen más normál eloszlás létrehozható a két paraméter, μ és σ megadásával:

```
> N1 := RandomVariable(Normal(2, 3));
f1 := x -> PDF(N1, x);
N1 := _R0
f1 := x -> Statistics:-PDF(N1, x) (1.1.2.2)
```

```
> N2 := RandomVariable(Normal(-1, .5));
f2 := x -> PDF(N2, x);
N2 := _R1
f2 := x -> Statistics:-PDF(N2, x) (1.1.2.3)
```

A különböző várható értékű és szórású normál eloszlásokat ábrázolhatjuk közös koordináta-rendszerben:

```
> plot([f(x), f1(x), f2(x)], x = -6..8, thickness = 3);
```



Mindegyik görbe eloszlásfüggvény, tehát mindegyik alatt a teljes 1 valószínűség oszlik el. Jól érthető módon kisebb szóráshoz keskenyebb görbe és magasabb csúcserték tartozik.

A sűrűségfüggvény pontos formulája: $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$, ahol μ várható értéket, σ a

szórást jelenti.

Ha egy normál eloszlással közelíthető eloszlásnak tudjuk a várható értékét és szórását (vagy akár csak tapasztalati úton egy statisztikai mintának), akkor e két paraméter behelyettesítésével azonnal illeszthetünk is rá egy megfelelő normál eloszlást.

Kidolgozott feladatok

1. Feladat (Út forgalma / 2.)*

Egy útszakasz egy pontján megfigyelések szerint óránként átlagosan 360 jármű halad át.

a) Adjuk meg a két jármű érkezése között eltelt T idő eloszlását, várható értékét, varianciáját és szórását! Ábrázoljuk T eloszlás és sűrűségfüggvényét!

b) Mennyi a valószínűsége, hogy két jármű érkezése között 10 másodpercnél kevesebb idő telik el?

c) Mennyi a valószínűsége, hogy két jármű érkezése között 5 másodpercnél kevesebb idő telik el?

- d) Mennyi a valószínűsége, hogy két jármű érkezése között 15 másodpercnél több idő telik el?
 e) Mennyi a valószínűsége, hogy egy jármű után a következő az 5. és 10. másodperc között érkezik?

Megoldás

[> restart;

a) Adjuk meg a két jármű érkezése között eltelt T idő eloszlását, várható értékét, varianciáját és szórását! Ábrázoljuk T eloszlás és sűrűségfüggvényét!

Miután példánk szerint percnként átlagosan $\frac{360}{60} = 6$ jármű érkezik, az átlagos várakozási idő 10 másodperc. Ha az idő mértékegységét *másodperc*nek választjuk, akkor eszerint a várakozási időket leíró, $E(T) = \frac{1}{\lambda} = 10$ várható értékű exponenciális eloszlás paramétere

$\lambda = \frac{1}{10}$ (másodpercnként átlagosan $\frac{1}{10}$ jármű érkezik):

[> with(Statistics):

> lambdamasodperc := 1/10;

$$\text{lambdamasodperc} := \frac{1}{10} \quad (1.2.1.1.1)$$

> T := RandomVariable(Exponential(1/lambdamasodperc));

$$T := _R \quad (1.2.1.1.2)$$

Vigyázzunk: a Maple-ben az exponenciális eloszlás paramétere –az általunk tanulttól eltérően– λ helyett $\frac{1}{\lambda}$!

Az eloszlásból visszkapjuk a várható értéket:

> ET := ExpectedValue(T); # = 1/lambda

$$ET := 10 \quad (1.2.1.1.3)$$

A variancia és a szórás:

> VarT := Variance(T); # = 1/lambda^2

$$\text{VarT} := 100 \quad (1.2.1.1.4)$$

> sigmaT := StandardDeviation(T); # = 1/lambda


$$\text{sigmaT} := 10 \quad (1.2.1.1.5)$$

Rajzoljuk most meg T eloszlásfüggvényét!

> F := x -> CDF(T, x): 'F'(x) = F(x); # x -> piecewise(x
 <= 0, 0, 1 - e^(-lambdamasodperc*x))

$$F(x) = \begin{cases} 0 & x < 0 \\ 1 - e^{-\frac{1}{10}x} & \text{otherwise} \end{cases} \quad (1.2.1.1.6)$$

> plot(F(x), x = 0..60, thickness = 3);




A sűrűségfüggvény ennek deriváltja, mely közvetlenül a Statistics csomag *PDF* eljárásával is számolható:

```
> f := x -> PDF(T, x): 'f'(x) = f(x); # x -> diff(F(x), x)
= piecewise(x <= 0, 0, lambdamasodperc*e^(-
lambdamasodperc*x))
```

$$f(x) = \begin{cases} 0 & x < 0 \\ \frac{1}{10} e^{-\frac{1}{10}x} & \textit{otherwise} \end{cases}$$


(1.2.1.1.7)

```
> surusegplot := plot(f(x), x = 0..60, thickness = 3):
surusegplot;
```



A sűrűségfüggvény közvetlen ábrázolására is van külön eljárás a Statistics csomagban:

```
> DensityPlot(T, range = 0..60, thickness = 3);
```



Láthatjuk, hogy a sűrűségfüggvény 0-ban jobbról vett határértéke éppen λ , vagyis az időegység alatt várható események darabszáma. Jelen esetben ez 0.1, megfelelően annak, hogy az időegységként választott *másodperc* alatt átlagosan 0.1 jármű érkezik (merthogy 10 másodpercenként érkezik átlagosan 1).

Megjegyzés: a grafikon adott időtartamra vonatkoztatott alakja független az idő mértékegységétől. (Eltekintve természetesen attól, hogy az x tengely skálázásának változása maga után vonja az y tengely skálázásának megváltozását, de egyszerű nyújtási transzformációkkal elérhető, hogy a grafikonok egybevágóak legyenek.)

Mivel példánkban az autók érkezése közötti jellemző időtartam néhány másodperc nagyságrendű, az idő mértékéül válasszunk másodpercet (ahogy a fenti grafikonok megrajzolásánál is), és a kérdésekre eszerint adjunk választ.

b) Mennyi a valószínűsége, hogy két jármű érkezése között 10 másodpercnél kevesebb idő telik el?

Annak valószínűségét, hogy két egymás után érkező jármű között adott időnél kevesebb telik el, az eloszlásfüggvény adja:

```
> `P(T < 10)` := F(10); evalf(%);
                                 $P(T < 10) := 1 - e^{-1}$ 
                                0.6321205588
```

(1.2.1.1.8)

Ezt meghatározhatjuk a *Probability* eljárással is:

```
> Probability(T < 10); evalf(%);
```


$$1 - e^{-1}$$
$$0.6321205588$$

(1.2.1.1.9)

Tehát kb. 63 % valószínűséggel telik el két jármű érkezése között (az amúgy átlagos) 10 másodpercnél kevesebb idő. Érdekes észrevenni, hogy bár az átlagos várakozási idő $\lambda = 10$ másodperc két jármű között, az esetek jóval több, mint felében a valódi várakozási idő kevesebb ennél. Az átlag úgy jöhet ki mégis 10 másodpercre, hogy bár összességében ritkábban fordulnak elő 10 másodperc feletti időhézagok, mint alattiak, mivel az értékre elvileg nincs felső korlát, olykor ezek elég nagyra válhatnak ahhoz, hogy kisebb előfordulási valószínűség mellett is felhúzzák az átlagot.

Grafikusan szemléltetve a valószínűség a sűrűségfüggvény alatti (egységnyi) területnek az a része, ami a 10-es abszcisszától negatív irányba (balra) esik (elvileg mínusz végtelentől integrálva, de mivel a negatív tartományon a függvény zérus, valójában $x = 0$ -tól elég figyelni):

```
> szinezesplot := plot(f(x), x = 0..10, filled = [color =  
yellow, transparency = 0.5]):  
plots[display](surusegplot, szinezesplot);
```



Vegyük észre, hogy a színezett terület befoglaló téglalapja $10 \times 0.1 = 1$ területű - ehhez mérten reálisnak tűnik a rá számítással kapott ~ 63 % érték.

c) Mennyi a valószínűsége, hogy két jármű érkezése között 5 másodpercnél kevesebb idő telik el?

```
> `P(T < 5)` := F(5); evalf(%); # = Probability(T < 5)
```


$$P(T < 5) := 1 - e^{-\frac{1}{2}}$$

0.3934693403

(1.2.1.1.10)

Természetesen az 5 másodpercnél kisebb hézag valószínűsége kisebb, mint a 10 másodpercnél kisebb hézag valószínűsége, hiszen előbbi esemény része utóbbinak. Ábrával szemléltetve:

```
> szinezesplot := plot(f(x), x = 0..5, filled = [color = yellow, transparency = 0.5]);  
plots[display](surusegplot, szinezesplot);
```



d) Mennyi a valószínűsége, hogy két jármű érkezése között 15 másodpercnél több idő telik el?

Az eloszlásfüggvény közvetlenül egy adott időnél *kevesebb* várakozási idő valószínűségét képes megmondani. Ha egy adott időnél *több* várakozási idő valószínűségére vagyunk kíváncsiak, azt komplementer eseményként kell számolni:

```
> `P(T < 15)` := F(15); evalf(%);
```

$$P(T < 15) := 1 - e^{-\frac{3}{2}}$$

0.7768698399

(1.2.1.1.11)


```
> `P(T > 15)` := 1 - `P(T < 15)`; evalf(%);
```

$$P(T > 15) := e^{-\frac{3}{2}}$$

0.2231301601

(1.2.1.1.12)

```
> szinezesplot := plot(f(x), x = 15..60, filled = [color =
yellow, transparency = 0.5]):
plots[display](surusegplot, szinezesplot);
```



e) Mennyi a valószínűsége, hogy egy jármű után a következő az 5. és 10. másodperc között érkezik?

Egy adott intervallumba esés azt jelenti, hogy kisebb az érték a felső végpontnál, de nem kisebb az alsónál. Vagyis az ide esés valószínűségét a felső végpont alá és az alsó végpont alá esés valószínűségeinek különbsége adja:

```
> `P(5 <= T < 10)` := F(10) - F(5); evalf(%);
```

$$P(5 \leq T < 10) := -e^{-1} + e^{-\frac{1}{2}}$$

0.2386512185

(1.2.1.1.13)

Vagy másként:


```
> Probability({5 <= T, T < 10}); evalf(%);
```

$$-e^{-1} + e^{-\frac{1}{2}}$$

0.2386512185

(1.2.1.1.14)

```
> szinezesplot := plot(f(x), x = 5..10, filled = [color =  
yellow, transparency = 0.5]):  
plots[display](surusegplot, szinezesplot);
```



Érdekes észrevenni, hogy az időhöz fentebb kiszámolt, első ötmásodperces tartományba esésének valószínűsége nagyobb, mint az iménti, második ötmásodperces tartományba esése - annak ellenére, hogy az átlagos várakozási időhöz (10 másodperc) az utóbbi tartomány van közelebb! Itt is ugyanaz a magyarázat, mint amit az a) pontnál említettünk.

▼ 2. Feladat (Dobások összege)*

Dobjunk egyszerre k dobókockával és jelölje X a dobott értékek összegét!

a) Készítsünk szimulációt $k = 1, 2, 3$ és 5 kocka esetén $n = 10000$ dobással és ábrázoljuk hisztogramon a tapasztalati eloszlást!

b) Illesszünk a $k = 5$ esetben kapott szimulált eloszlásra normál eloszlást és hasonlítsuk össze annak sűrűségfüggvényét a hisztogrammal!

▼ Megoldás

```
[> restart;
```

a) Készítsünk szimulációt $k = 1, 2, 3$ és 5 kocka esetén $n = 10000$ dobással és ábrázoljuk hisztogramon a tapasztalati eloszlást!

```
> restart;
with(Statistics):
randomize():
```

Felvesszük az adatokat: hány kockával dobunk, és hányszor tesszük ezt. A könnyű érthetőség kedvéért először mindössze két kockával és 10 dobással építsük fel a módszert:

```
> kockadb := 2; dobasdb := 10;
      kockadb := 2
      dobasdb := 10 (1.2.2.1.1)
```

Megfelelő valószínűségi változóval szimuláljuk a kockadobást. Mivel több kockával játszunk, mindegyiknek külön létrehozunk egy valószínűségi változót – egy valószínűségi változókból álló tömböt készítünk:

```
> Y := [seq(RandomVariable(DiscreteUniform(1, 6)), i = 1..
      kockadb)];
      Y := [_R, _R0] (1.2.2.1.2)
```

A listában összegyűjtött valószínűségi változók mindegyikével generálunk egy mintát, és a megfelelő értékpárokat össze is adjuk.

```
> osszegek := add(Sample(Y[i], dobasdb), i = 1..kockadb);
      # vektorokat elemenként össze lehet adni az add
      paranccsal
      osszegek := [ 11. 8. 8. 2. 3. 9. 6. 4. 2. 5. ] (1.2.2.1.3)
```


Adjuk meg az összegek lehetséges értékeit és a hozzájuk tartozó valószínűségeket is! (Ezek már nem kellene a hisztogram elkészítéséhez.)

```
> osszeg_ertekek := [seq(i, i = kockadb..6*kockadb)];
      osszeg_ertekek := [2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12] (1.2.2.1.4)
```

```
> osszeg_elofordulasok := [seq(0, i = kockadb..6*kockadb)]
      :
      for i to numelems(osszegek) do # numelems() kell, a nops
      () vektorokra nem az elemek számát adja
      ertekindex := round(osszegek[i] - kockadb + 1): #
      osszeghez tartozó index
      osszeg_elofordulasok[ertekindex] :=
      osszeg_elofordulasok[ertekindex] + 1:
      end do:
      osszeg_elofordulasok;
      osszeg_valoszinusegek := osszeg_elofordulasok/dobasdb;
      [2, 1, 1, 1, 1, 0, 2, 1, 0, 1, 0]
      osszeg_valoszinusegek := [ 1/5, 1/10, 1/10, 1/10, 1/10, 0, 1/5, 1/10, 0, 1/10, 0 ] (1.2.2.1.5)
```

Ábrázoljuk az eloszlást hisztogramon!

```
> Histogram(osszegek, discrete = true, thickness = 30);
```

Érdekes összevetni a dobott összegeket tartalmazó vektor adatait a diagrammal.

A mechanizmus megértése kedvéért a fenti példában kevés dobást végeztünk, de az egész folyamat könnyen megismételhető több dobással is. Legjobb, ha egy paramétereázhető procedúrában foglaljuk össze a fentebb lépésenként kifejtett műveletsort, miközben a köztes műveletek végén kettőspontra cseréljük a pontosvesszőket, csak a hisztogram rajzoló utasítás mögött hagyjuk meg.

```
> kockadobalas := proc(kocka_db, dobas_db)
  local Y, szamok, osszegek:
  Y := [seq(RandomVariable(DiscreteUniform(1, 6)), i =
1..kocka_db)]:
  osszegek := add(Sample(Y[i], dobas_db), i = 1..
kocka_db):
  return Histogram(osszegek, discrete = true, thickness
= round(330/(5*kocka_db + 1) - 3));
end proc:
```

Ezzel már könnyedén kísérletezhetünk különböző kocka- és dobás-számokkal.

```
> n := 10000;
```


$n := 10000$

(1.2.2.1.6)

$k = 1$ eset (egy kockával dobunk).

```
> k := 1;
kockadobalas(k, n);
```

$k := 1$




Látjuk, hogy nagyobb dobás-szám mellett a hisztogram kisimul, és közel egyenletes eloszlást mutat.

$k=2$:

```
> k := 2;  
kockadobalas(k, n);
```

$k:=2$



A kellően sok dobás miatt a hisztogram véletlenszerű ingadozásai csekélyek: szabályos alakot, de semmiképp sem egyenletes eloszlást mutat.


Látjuk, hogy a két kockával való dobáskor a középső összegek gyakrabban jelennek meg, mint a szélsők. Ez érthető, hiszen a 2-es értékhez csakis két 1-es, a 12-eshez csakis két 6-os dobással lehet eljutni, míg pl. a 7-es érték többféleképp is összejöhét a két kockából: 1 + 6, 2 + 5, 3 + 4, 4 + 3, 5 + 2, 6 + 1. A hisztogramon is épp ez látszik: a középső 7-es érték kb. 6-szor olyan gyakran fordul elő, mint a szélsők.

Könnyen kipróbálható a 3 vagy még több kockás eset is.

$k = 3$:


```
> k := 3;
   kockadobalas(k, n);
```

$k := 3$



$k=5$:

```
> k := 5;  
H := kockadobalas(k, n): H;  
k:=5
```



A fentebb kifejtett alapelv továbbra is igaz: a középső értékek nagyobb valószínűségűek, mert többféle kombinációval jöhetnek létre, mint a szélsők. A két kockás eset háromszög alakú grafikonjához képest viszont szépen kivehető, hogy az ábra alakja haranghoz válik hasonlatossá: a hisztogram közepe konvex, de a szélek egy bizonyos ponttól kezdve már konkávok.

b) Illesszünk a $k = 5$ esetben kapott szimulált eloszlásra normál eloszlást és hasonlítsuk össze annak sűrűségfüggvényét a hisztogrammal!

A fenti kísérletben a k növelésével kirajzolódó haranggörbe létrejötte mögött a *centrális határeloszlás tétel* áll, melynek következménye, hogy véges szórás esetén sok független, azonos eloszlású valószínűségi változó összege jól közelíthető az összeggel azonos várható értékű és szórású *normál eloszlású* változóval.

Jelölje Y_i , ($i = 1, 2, \dots, 5$) az i -edik kockával dobott számot és legyen Y ezek összege! Ekkor

Y eloszlása jól közelíthető egy $N(\mu, \sigma)$ normál eloszlással, ahol $\mu = E(Y)$ és $\sigma = \sigma(Y)$.

, így $E(Y_i) = \frac{6+1}{2} = 3.5$ és a várható érték additivitása miatt $E(Y) = 5 \cdot E(Y_1) = 17.5$.

Továbbá a kockák függetlenek, így a szórásnégyzet szintén additív:

$$\sigma^2(Y) = \sigma^2\left(\sum_{i=1}^5 Y_i\right) = 5 \cdot \sigma^2(Y_1).$$

```
> EY1 := 3.5; EY := k*EY1;
      EY1 := 3.5
      EY := 17.5
```

(1.2.2.1.7)

```
> VarY1 := add((i - EY1)^2*1/6, i = 1..6);
      VarY1 := 2.916666668
```

(1.2.2.1.8)

```
> VarY := k*VarY1;
      sigmaY := sqrt(VarY);
      VarY := 14.58333334
      sigmaY := 3.818813080
```

(1.2.2.1.9)

Ugyanez a számolás a Maple beépített eszközeivel:

```
> unassign('i');
      Y := add(RandomVariable(DiscreteUniform(1,6)), i = 1..k)
      ; # sum() nem jó csak az add()
      Y := _R12 + _R13 + _R14 + _R15 + _R16
```

(1.2.2.1.10)

```
> ExpectedValue(Y); evalf(%);
      35
      2
      17.50000000
```

(1.2.2.1.11)

```
> StandardDeviation(Y); evalf(%);
      5
      6 sqrt(21)
      3.818813079
```

(1.2.2.1.12)

Lássuk az illesztett normál eloszlás sűrűségfüggvényét:

```
> X := RandomVariable(Normal(EY, sigmaY));
      X := _R17
```


(1.2.2.1.13)

```
> 'f'(x) = PDF(X, x);
      f(x) = 
$$\frac{0.1309307341 \sqrt{2} e^{-0.03428571427 (x - 17.5)^2}}{\sqrt{\pi}}$$

```


(1.2.2.1.14)

```
> P1 := DensityPlot(X, range = k..6*k, color = red,
      thickness = 3): P1;
```



Ezt rárajzolva a fenti hisztogramra:

```
> plots[display](H, P1);
```



Jól látszik a szoros illeszkedés.

3. Feladat (Egyenletes eloszlások összege)

Sorsoljunk egyenletes eloszlással számokat a $[0, 1]$ intervallumból (egyszerre többet), és figyeljük ezek Y összegének eloszlását.

- Készítsünk szimulációt $k = 1, 2, 3$ ill. 5 szám összegére $n = 10000$ kísérlettel! Ábrázoljuk hisztogramon a szimulált eloszlást és rajzoljuk rá az elméleti sűrűségfüggvényt!
- Illesszünk a $k = 5$ esetben kapott szimulált eloszlásra normál eloszlást és hasonlítsuk össze annak sűrűségfüggvényét a hisztogrammal!

Megoldás

```
[> restart;
```

- Készítsünk szimulációt $k = 1, 2, 3$ ill. 5 szám összegére $n = 10000$ kísérlettel! Ábrázoljuk hisztogramon a szimulált eloszlást és rajzoljuk rá az elméleti sűrűségfüggvényt!

```
[> with(Statistics) :
  randomize( ) :
```


A fenti, több kockával való dobásról szóló (diszkrét) példa könnyen átvihető folytonos esetre is.

Lényegében az ott látottakat ismétljük, talán még egyszerűbben is.

```
> egyenletesosszegzes := proc(valtozodb, sorsolasdb)
  local Y, osszegek:
  Y := [seq(RandomVariable(Uniform(0, 1)), i = 1..
valtozodb)]:
  osszegek := add(Sample(Y[i], sorsolasdb), i = 1..
valtozodb):
  return Histogram(osszegek, bincount = 20);
end proc:
```

Tegyük egy próbát kevés kísérlettel, egy változóra:

```
> egyenletesosszegzes(1, 10);
```




10000 kísérlettel egy változóra megkapjuk a várt egyenletes eloszlást:

```
> n := 10000;
```


$n := 10000$

(1.2.3.1.1)

```
> Y1 := RandomVariable(Uniform(0, 1)):
P1 := DensityPlot(Y1, range = -0.25..1.25, color = red,
thickness = 3): P1;
```




```
> k := 1;  
H1 := egyenletesosszegzes(k, n):  
plots[display](P1, H1);  
k:=1
```




Nézzük hogy mutat ugyanez két változóval! A Maple képes közvetlenül megrajzolni a sűrűségfüggvényt, akár változók összegeként adódó újabb változókra is:

```
> Y2 := Y1 + RandomVariable(Uniform(0, 1)): # az előző  
változóhoz hozzáadunk még egyet  
P2 := DensityPlot(Y2, range = -0.25..2.25, color = red,  
thickness = 3): P2;
```




```
> k := 2;  
H2 := egyenletesosszegzes(k, n):  
plots[display](P2, H2);  
k := 2
```




(Az értékkészlet így természetesen 0-tól 2-ig terjed.)

Három változóval:

```
> Y3 := Y2 + RandomVariable(Uniform(0, 1)): # az előző  
    változóhoz hozzáadunk még egyet  
    P3 := DensityPlot(Y3, range = -0.25..3.25, color = red,  
    thickness = 3): P3;
```




```
> k := 3;  
H3 := egyenletesosszegzes(k, n):  
plots[display](P3, H3);  
k:=3
```




A $[0, 3]$ értékkészlet mellett az eloszlás már elkezd felvenni a jellegzetes harang-formát. Végül $k = 5$ esetén a hisztogram:

```
> Y4 := Y3 + RandomVariable(Uniform(0, 1)):
  Y5 := Y4 + RandomVariable(Uniform(0, 1)): # Vigyázzunk:
  ha egy sorban adjuk hozzá a két új egyenletes eloszlású
  valószínűségi változót, akkor azokat a Maple azonosnak
  fogja tekinteni, nem pedig függetlennek!
  P5 := DensityPlot(Y5, range = -0.25..5.25, color = red,
  thickness = 3): P5;
```



```
> k := 5;  
H5 := egyenletesosszegzes(k, n):  
plots[display](P5, H5);  
k:=5
```

Látjuk, hogy ezek a görbék jól illeszkednek a nekik megfelelő hisztogramokra.

b) Illesszünk a $k = 5$ esetben kapott szimulált eloszlásra normál eloszlást és hasonlítsuk össze annak sűrűségfüggvényét a hisztogrammal!

A 2. Feladat b) részéhez hasonlóan a k növelésével kirajzolódó haranggörbe mögött a *centrális határeloszlás tétel* húzódik meg, mely szerint Y nagy k esetén jól közelíthető egy azonos várható értékű és szórású *normál eloszlású* változóval. Tehát csupán 2 paramétert kell meghatározni.

Jelölje Y_i ($i = 1, 2, \dots, 5$) az i -edik véletlen számot. Ekkor $Y = Y_1 + Y_2 + \dots + Y_5$,

$E(Y_i) = \frac{0+1}{2} = 0.5$, és a várható érték additivitása miatt

$$E(Y) = 5 \cdot E(Y_1) = 2.5.$$

Továbbá a számokat függetlenül választottuk, így a szórásnégyzet szintén additív:

$$\sigma^2(Y) = \sigma^2\left(\sum_{i=1}^5 Y_i\right) = 5 \cdot \sigma^2(Y_1) = 5 \cdot \frac{(1-0)^2}{12} = \frac{5}{12}.$$

(Itt felhasználtuk az $[a, b]$ intervallumon egyenletes eloszlású valószínűségi változó szórásnégyzetére tanult $\sigma^2 = \frac{(b-a)^2}{12}$ képletet.)

```
> EY1 := 0.5; EY := k*EY1;
      EYI := 0.5
```

$$EY := 2.5 \quad (1.2.3.1.2)$$

```
> VarY1 := 1/12;
```

$$VarY1 := \frac{1}{12} \quad (1.2.3.1.3)$$

```
> VarY := k*VarY1;
sigmaY := sqrt(VarY); evalf(%);
```

$$VarY := \frac{5}{12}$$
$$sigmaY := \frac{1}{6} \sqrt{15}$$
$$0.6454972245 \quad (1.2.3.1.4)$$

Ugyanez a számolás a Maple beépített eszközeivel:

```
> unassign('i');
Y := add(RandomVariable(Uniform(0,1)), i = 1..k); # sum
() nem jó csak az add()
```

$$Y := _R16 + _R17 + _R18 + _R19 + _R20 \quad (1.2.3.1.5)$$

```
> ExpectedValue(Y); evalf(%);
```

$$\frac{5}{2}$$
$$2.500000000 \quad (1.2.3.1.6)$$

```
> StandardDeviation(Y); evalf(%);
```

$$\frac{1}{6} \sqrt{15}$$
$$0.6454972245 \quad (1.2.3.1.7)$$

Lássuk az illesztett normál eloszlás sűrűségfüggvényét:


```
> X := RandomVariable(Normal(EY, sigmaY));
```

$$X := _R21 \quad (1.2.3.1.8)$$

```
> 'f'(x) = PDF(X, x);
```


$$f(x) = \frac{1}{5} \frac{\sqrt{2} \sqrt{15} e^{-\frac{6}{5}(x-2.5)^2}}{\sqrt{\pi}} \quad (1.2.3.1.9)$$

```
> PN := DensityPlot(X, range = -0.25..5.25, color = red,
thickness = 3): PN;
```



Ezt rárajzolva a fenti hisztogramra:

```
> plots[display](H5, PN);
```



A normál sűrűségfüggvény görbéje jól láthatóan illeszkedik a hisztogramra, bár tudjuk, hogy nem teljesen egyezik az elméleti eloszlással, csak közelíti azt.

4. Feladat (Duzzasztógát)*

Egy duzzasztógát által felduzzasztott átlagos vízmélység 21 méter, és szórása 5 méter. A mindenkori X vízmélység méterben mérve normál eloszlású véletlen változó.

A gát tetején található egy biztonsági túlfolyó, amely megakadályozza, hogy a víz a 30 méteres szint fölé növekedjen. Másrészt van egy cső a túlfolyó teteje alatt 15 méterrel, amely bevezeti a vizet a hidroelektromos generátorhoz. (Hagyjuk figyelmen kívül a cső véges átmérőjét!)

a) Rajzoljuk fel az Y vízmélység sűrűségfüggvényét!

b) A teljes idő hányadrészében fordul elő, hogy a túlfolyón folyik el feleslegesen a felduzzasztott víz!

c) Szemléltessük a b) pontban számolt százalékot a sűrűség függvény görbéje alatti megfelelő terület befestésével!

d) Tudjuk, hogy a túlfolyón nem folyik a víz. Mekkora a feltételes valószínűsége ekkor annak, hogy a duzzasztó táplálja a generátort vízzel?

e) Az esetek hányadrészében nem táplálja a felduzzasztott víz a generátort?

f) Milyen h méter mélyre kellene betenni a generátort tápláló csövet a túlfolyó alatt ahhoz, hogy az esetek legfeljebb 5 %-ában ne kapjon vizet a generátor?

g) Szemléltessük az f) pontban számolt h mélységet, az Y vízmélység eloszlás függvényének és a 0.05 valószínűségi szintnek a felrajzolásával!

▼ *Megoldás*

```
> restart;  
> with(Statistics):  
  randomize():
```

Tegyük fel, hogy adott egy mérce a vízszint leolvasásához. Ennek 0 szintjéhez viszonyítunk minden adatot a példa megoldásakor.

a) Rajzoljuk fel az Y vízmélység sűrűség függvényét!

A felduzzasztott vízszintet az Y változó mutatja, mely a feltételezés szerint *normál* eloszlású, adott várható értékkel és szórással. Hosszuk létre a megfelelő eloszlású változót:

```
> mu := 21; sigma := 5;
```

$\mu := 21$

$\sigma := 5$

(1.2.4.1.1)

```
> Y := RandomVariable(Normal(mu, sigma));
```

$Y := _R$

(1.2.4.1.2)


Ebből már megrajzolható a sűrűségfüggvény:

```
> f := x -> PDF(Y, x);
```

$f := x \rightarrow \text{Statistics:-PDF}(Y, x)$

(1.2.4.1.3)

```
> surusegplot := plot(f(x), x = mu - 3*sigma..mu + 3*  
  sigma, thickness = 3): surusegplot; # 3-sigma szabály
```



b) A teljes idő hányadrésében fordul elő, hogy a túlfolyón folyik el feleslegesen a felduzzasztott víz!

Itt azt kérdezzük, mekkora valószínűséggel van a vízszint 30 méter fölött: $P(Y > 30) = ?$
 Az ilyen (adott intervallumba esés valószínűsége) típusú kérdésekre az eloszlásfüggvény és a sűrűségfüggvény használatával is lehet válaszolni. Vegyük most a valószínűségi változónk eloszlásfüggvényét:

```
> F := x -> CDF(Y, x);
      F := x -> Statistics:-CDF(Y, x) (1.2.4.1.4)
```

Ez a függvény - definíciója szerint - közvetlenül az adott érték *alá* esés valószínűségét képes mutatni, de közvetve adott érték fölé, vagy adott értékek közé esés valószínűsége is jól számolható vele. Például a kérdésünkben keresett valószínűséghez az is jó, ha a 30 alá esés valószínűségét tudjuk, mert annak komplementere lesz a megoldás:

```
> `P(Y > 30)` := evalf(1 - F(30));
      P(Y > 30) := 0.0359303192 (1.2.4.1.5)
```


Eszerint ~3.6 % valószínűséggel (a mérési időtartam átlagosan ennyi részében) lesz túlfolyás.

c) Szemléltessük a b) pontban számolt százalékot a sűrűség függvény görbéje alatti megfelelő terület befestésével!

Fenti eredmény szemléletesen azt jelenti, hogy a sűrűségfüggvény görbéje alatt "szétkent" egységnyi valószínűségből ennyi esik a 30-as abszcissa fölé. Ehhez készítünk egy szemléltető ábrát.

Elkészítjük a befestést. majd összemásoljuk a görbe rajzával:

```
> szinezesplot := plot(f(x), x = 30..mu + 3*sigma, filled  
= [color = yellow, transparency = 0.5]):  
plots[display](szinezesplot, surusegplot);
```



d) Tudjuk, hogy a túlfolyón nem folyik a víz. Mekkora a feltételes valószínűsége ekkor annak, hogy a duzzasztó táplálja a generátort vízzel?

A generátort tápláló kifolyó a túlfolyó alatt 15 méterrel van, ez a mércén 15 méternek felel meg.

A szóvegesen megfogalmazott kérdés a feltételes valószínűség tanult definícióját alkalmazva a következőképp formalizálható:

$$P(Y > 15 | Y < 30) = \frac{P(Y > 15 \wedge Y < 30)}{P(Y < 30)} = \frac{P(15 < Y < 30)}{P(Y < 30)}$$

A feltételes valószínűség két, külön kiszámítandó valószínűség hányadosa:

```
> `P(15 < Y < 30)` := evalf(F(30)-F(15));  
P(15 < Y < 30) := 0.8490000105 (1.2.4.1.6)
```

```
> `P(Y < 30)` := evalf(F(30));  
P(Y < 30) := 0.9640696808 (1.2.4.1.7)
```

```
> `P(15 < Y < 30)` / `P(Y < 30)`;  
0.8806417497 (1.2.4.1.8)
```

Tehát annak valószínűsége, hogy a duzzasztó táplálja a generátort vízzel, feltéve, hogy a

túlfolyón nem folyik a víz, kb. 88 %.

e) Az esetek hányadrészeben nem táplálja a felduzzasztott víz a generátort?

Mekkora valószínűséggel van a vízszint 15 méter alatt?

```
> evalf(F(15));
```

0.1150696703

(1.2.4.1.9)

11.5 % az esélye annak, hogy nem táplálja a felduzzasztott víz a generátort.

f) Milyen h méter mélyre kellene betenni a generátort tápláló csövet a túlfolyó alatt ahhoz, hogy az esetek legfeljebb 5 %-ában ne kapjon vizet a generátor?

Az előző pontban láttuk, hogy az átlagosan 21 méterestől egyre nagyobb eltéréseket egyre ritkábban produkáló vízszint 11.5 % valószínűséggel 15 méter alatt van. A generátor ilyenkor nem üzemel. Ha szeretnénk megnövelni az üzemelési időt úgy, hogy 11.5 % helyett csak 5% legyen a kiesés, a kifolyási szintet mélyebbre kell tenni (ahol nagyobb valószínűséggel van víz). Kérdés, hogy hol legyen ez, milyen h szint esetén lenne az az alá esés valószínűsége 5 %? A formalizált feladat: $P(Y < h) = 0.05$. Vagyis meg kell oldani az $F(h) = 0.05$ egyenletet:

```
> h := fsolve(F(h) = 0.05, h); # solve helyett fsolve  
kell, ha csak a valós megoldásokat keressük
```

$h := 12.77573187$


(1.2.4.1.10)

Ha tehát 12.77 méteres szint alá tesszük a kifolyót, akkor lehet garantálni átlagosan 5 %-nál kevesebb leállási időt.

g) Szemléltessük az f) pontban számolt h mélységet, az Y vízmélység eloszlás függvényének és a 0.05 valószínűségi szint felrajzolásával!

A fenti eredményt szemléltethetjük grafikonon is:

```
> plot([F(x), 0.05], x = 0..30);
```

▼ 5. Feladat (Ipari fúrógép)*

Egy ipari fúrógép fúrófejének élettartama jól közelíthető egy 10 óra várható értékű és 2 óra szórású valószínűségi változóval. Legalább hány fúrófej kell ahhoz, hogy a gépet legalább 95 %-os valószínűséggel 400 óráig működtetni tudjuk? (Feltehető, hogy az egyes fúrófejek élettartama egymástól független.)

▼ *Megoldás*

[> **restart**;

Jelölje X_1, X_2, X_3, \dots a fúrófejek élettartamát. A feladat szövege szerint X_i -k független, azonos eloszlású valószínűségi változók, $\mu_X = E(X_i) = 10$ h várható értékkel és

$\sigma_X = \sigma(X_i) = 2$ h szórással. Legyen $S_n = X_1 + X_2 + \dots + X_n$ az első n db fúrófej élettartamának összege. A feladat szövege szerint úgy kell n -et megválasztanunk, hogy

$$P(S_n \geq 400) \geq 0.95$$

teljesüljön.

```
> muX := 10;
  sigmaX := 2;
  t := 400;
  p := 0.95;
```

```
muX:= 10
sigmaX:= 2
t:= 400
p:= 0.95
```

(1.2.5.1.1)

Fontos, hogy bár az X_i változók pontos eloszlása *nem ismert*, az S_n összeg eloszlását mégis jól tudjuk közelíteni egy megfelelő normál eloszlással, ha n elég nagy ($n \geq 30$ általában jó). Ez a matematikai statisztikában rendkívül fontos állítás a *Centrális Határeloszlás Tétel* (CHT). A tétel minden eloszlásra (diszkrétre és folytonosra is) igaz, melynek létezik szórása; az összeadandók azonos eloszlása és függetlensége szükséges feltétel!

A CHT-t általában akkor alkalmazzuk, ha a kérdés az S_n összeg eloszlására vonatkozik, de az összeadandók eloszlása nem ismert, így S_n eloszlását sem tudjuk precízen meghatározni.

Ekkor az egyetlen lehetőségünk, ha elég nagy n -et feltételezve normál határeloszlással közelítjük az összeg eloszlását. Ennek paraméterei (a konkrét példában):

$$\mu = E(S_n) = n \cdot E(X_1) = n \cdot \mu_X$$

és

$$\sigma = \sqrt{\sigma^2(S_n)} = \sqrt{n \cdot \sigma^2(X_1)} = \sqrt{n} \sigma(X_1) = \sqrt{n} \cdot \sigma_X$$

Azaz $S_n \sim N(10n, 2 \cdot \sqrt{n})$.

A gyakorlatban elterjedt, hogy ehelyett S_n standardizáltjával számolunk, és azt közelítjük

standard normál eloszlással: $S_n^* = \frac{S_n - n \cdot \mu_X}{\sqrt{n} \cdot \sigma_X} \sim N(0, 1)$. Ez azért jó, mert így lényegében

csak egy konkrét eloszlás (standard normál) ismeretére van szükség bármely kísérlet leírásához. A szakkönyvekben is csak a standard normál eloszlásra vonatkozó négyjegyű függvénytáblázattal találkozhatunk, abból ugyanis bármely normál eloszlásfüggvény értékei számolhatók a standardizálási trükkel. A számítógépes statisztikai programcsomagok elterjedésével ez manapság már nem jelent megkötést, de a normál eloszlás jobb megértéséhez mégis érdemes így végigszámolni a feladatot.

$$\begin{aligned} 0.95 \leq P(S_n \geq 400) &= P\left(\frac{S_n - n \cdot \mu_X}{\sqrt{n} \cdot \sigma_X} \geq \frac{400 - n \cdot \mu_X}{\sqrt{n} \cdot \sigma_X}\right) \quad (\text{standardizálás}) \\ &= P\left(S_n^* \geq \frac{400 - 10n}{2 \cdot \sqrt{n}}\right) = P\left(S_n^* \geq \frac{200 - 5n}{\sqrt{n}}\right) \\ &= 1 - P\left(S_n^* < \frac{200 - 10n}{2 \cdot \sqrt{n}}\right) \quad / S_n^* \sim N(0, 1) \\ &= 1 - \Phi\left(\frac{200 - 10n}{2 \cdot \sqrt{n}}\right), \end{aligned}$$

ahol $\Phi(x)$ a standard normál eloszlás eloszlásfüggvényét jelöli. Ez ekvivalens azzal a

feltétellel, hogy $\Phi\left(\frac{200 - 10n}{2 \cdot \sqrt{n}}\right) \leq 0.05$, melyből Φ inverzét véve

$$\frac{200 - 10n}{2 \cdot \sqrt{n}} \leq \Phi^{-1}(0.05)$$

Ebből kell meghatározni az ismeretlen n -et! Eloszlásfüggvény inverzét a *Quantile* eljárással kaphatjuk meg:

```
> with(Statistics):
Phi_inverse := x -> Quantile(Normal(0, 1), x);
Phi_inverse := x -> Statistics:-Quantile(Normal(0, 1), x) (1.2.5.1.2)
```

```
> RealDomain[solve]((t - n*muX)/(sqrt(n)*sigmaX) <=
Phi_inverse(1 - p), n); evalf(%); # a RealDomain[solve]
eljárás csak a valós megoldásokat keresi
RealRange(42.13540794, infinity)
RealRange(42.13540794, infinity) (1.2.5.1.3)
```

Tehát $n \geq 42.135$, vagyis $n = 43$ fűrófej kell legalább ahhoz, hogy a gépet legalább 95 %-os valószínűséggel 400 óráig működtetni tudjuk!

Megjegyzés: mivel $n \geq 30$, ezért a megoldáshoz használt normál közelítésnek elhanyagolható a hibája.

Megoldás standardizálás nélkül:

```
> unassign('n');
Y := RandomVariable(Normal(n*muX, sqrt(n)*sigmaX)); #
S_n normál közelítése CHT-vel
Y := _R0 (1.2.5.1.4)
```

```
> egyenlet := Probability(Y >= 400) = p; # a feltételünk
(egyenlettel kell megadni), nincs standardizálás
egyenlet := 1/2 - 1/2 erf(1/4 * (-10*n + 400) * sqrt(2) / sqrt(n)) = 0.95 (1.2.5.1.5)
```

```
> n1, n2 := RealDomain[solve](egyenlet, n); # két
megoldást ad
n1, n2 := 37.97281379, 42.13540794 (1.2.5.1.6)
```

Így is megtaláltuk a megoldást, de sajnos bejött egy hamis gyök is, amit csak ellenőrzéssel tudunk kiszűrni:

```
> n := n1;
Probability(Y >= 400); evalf(%);
n := 37.97281379
1/2 - 1/2 erf(1/4 * (-10*n + 400) * sqrt(2) / sqrt(n))
0.0499999996 (1.2.5.1.7)
```

Ez rossz megoldás, mert 0.95-öt kell kapnunk!

```
> n := n2;
Probability(Y >= 400); evalf(%);
n := 42.13540794
1/2 - 1/2 erf(1/4 * (-10*n + 400) * sqrt(2) / sqrt(n))
0.9499999996 (1.2.5.1.8)
```

Ez a helyes megoldás! A felfelé kerekített egész darabszám lesz az, amivel már biztosan garantálni tudjuk a feltétel teljesülését, vagyis $n = 43$.

Abrázoljuk a p valószínűséget a normál sűrűségfüggvény alatti megfelelő terület besatírozásával!

```
> n := 43; (1.2.5.1.9)
```

$$n := 43$$

(1.2.5.1.9)

Határozzuk meg a várható értéket és a szórást, hogy tudjuk, melyik tartományon kell ábrázolni!

```
> mu := ExpectedValue(Y); # = n*muX
```

$$\mu := 430$$

(1.2.5.1.10)


```
> sigma := StandardDeviation(Y); # = sqrt(n)*sigmaX
```

$$\sigma := 2\sqrt{43}$$

(1.2.5.1.11)

A tartomány kiválasztásánál a 3σ -szabályt alkalmazzuk, azaz a $[\mu - 3\sigma, \mu + 3\sigma]$ intervallumon ábrázolunk.

```
> P1 := DensityPlot(Y, range = mu - 3*sigma..mu + 3*sigma,
  color = red, thickness = 3):
P2 := plot(PDF(Y, x), x = 400..mu + 3*sigma, color =
  red, thickness = 3, filled = [color = yellow,
  transparency = 0.5]): # DensityPlot-nál nem használható a
  'filled' opció
plots[display](P1, P2);
```



A sátozott terület n választása miatt legalább 95 %.

▼ 6. Feladat (Helymeghatározás)

$$F_E := x \rightarrow \text{piecewise}\left(x \leq 0, 0, F_Q\left(\frac{x^2}{\sigma^2}\right)\right) \quad (1.2.6.1.5)$$

A sűrűségfüggvény ennek deriváltja:


```
> f_E := x -> diff(F_E(x), x);
```

$$f_E := x \rightarrow \frac{d}{dx} F_E(x) \quad (1.2.6.1.6)$$

```
> P1 := plot(f_E(x), x = -1..2, color = red, thickness = 3):
```

```
  P2 := plot(f_E(x), x = 1..2, color = red, thickness = 3,
  filled = [color = yellow, transparency = 0.5]):
```

```
plots[display](P1, P2);
```



▼ Gyakorló feladatok

▼ Gy/1. Feladat

Egy gyümölcsárúsnál 5 almát vásárolunk. Egy alma tömege átlagosan 176 gramm, 50 gramm szórással és feltételezhető hogy normál eloszlást követ.

a) Mekkora az esélye, hogy a vásárolt almák össztömege kevesebb, mint 650 gramm?

- b) Mekkora az esélye, hogy az almák össztömege 800 és 900 gramm között van?
c) Egy almás süteményhez 1 kg alma kell. Hány almát kellene vennünk, hogy 95 % eséllyel el tudjuk készíteni a süteményt (ragaszkodunk a recept szerinti 1 kg-hoz)?

▼ *Megoldás*

[> restart;

▼ Gy/2. Feladat

Egy elektromos készülék élettartamát 10 év várható értékű exponenciális eloszlású valószínűségi változó írja le.

- a) Ábrázoljuk az élettartam eloszlás és sűrűségfüggvényét, és adjuk meg a szórását!
b) Melyiknek nagyobb az esélye: annak, hogy a készülék 5 éven belül elromlik, vagy annak, hogy 15 évig működésképes marad?
c) Hány év garanciát vállaljon a gyártó, ha azt szeretné, hogy termékeinek legfeljebb 10 %-át kelljen garanciaidőn belül javítani?

▼ *Megoldás*

[> restart;

▼ Gy/3. Feladat

Egy adott népességben a felnőttek várható testmagassága $\mu = 170$ cm, $\sigma = 8$ cm szórással. Jelölje X 50 véletlenszerűen kiválasztott felnőtt átlagos magasságát! Számítsuk ki az alábbi valószínűségeket és ábrázoljuk azokat a sűrűségfüggvény alatti megfelelő tartomány színezésével!

- a) $P(X > 169)$;
b) $P(X \leq 172)$;
c) $P(|X - \mu| > 1.5)$.

▼ *Megoldás*

[> restart;

▼ Gy/4. Feladat

Egy síközpontban párhuzamosan több sífelvonó is üzemel. Mindig akkor indítják a következő kabint, ha pont 10 síelő összegyűlt.

- a) Feltételezve, hogy a síelők Poisson-modell szerint érkeznek, percenként átlagosan 4-en, írjuk fel a két kabin indulása között eltelt T idő eloszlását valamint ábrázoljuk eloszlás- és sűrűségfüggvényét!
b) Határozzuk meg T várható értékét és szórását!
c) Mekkora a valószínűsége, hogy 3 percnél többet kell várni a következő kabin indulására?
d) Közelítsük T -t egy normál eloszlású valószínűségi változóval és hasonlítsuk össze a két sűrűségfüggvényt! Mi lenne a válasz a c) részre, ha a normál közelítéssel számolnánk?

▼ *Megoldás*

[> restart;

