

Náhoda při hře



Martingale:

- Vsadíš řekněme 1 dolar na barvu, kterou si vybereš (červená či černá) a budeš stále sázet jen na ni.
- Roztočíš ruletu a čekáš ...
- Pokud prohraješ, zdvojnásobíš sázku, takže vsadíš příště 2 dolary. Pak řekněme, že znovu prohraješ, tak příště vsadíš 4 dolary. A když zas prohraješ, tak příště vsadíš 8 dolarů. Řekněme, že už konečně padla barva, kterou jsi vsadil. Casino ti dá ke tvým vsazeným 8 dolarům svých 8, takže máš teď 16 dolarů. Spočítej si, kolik jsi vsadil: $1 + 2 + 4 + 8 = 15$ dolarů, takže - vydělal jsi 1 dolar!
- Pak začneš sázet znovu 1 dolar...

Náhoda při hře



Pravděpodobnost výhry při sázce na barvu:

$$p = 18/37 = 0,486$$

Průměrný "zisk" při n sázkách částky č:

$$- n \cdot \check{c} + 2 \cdot \check{c} \cdot n \cdot p = n \cdot \check{c} \cdot (-0,027)$$

Dlouhodobý zisk kasina je 2,7% ze vsazených částek.

Co to je pravděpodobnost?

- je matematická disciplína, popisující zákonitosti týkající se jevů, které (přinejmenším z hlediska pozorovatele) mohou a nemusí nastat, resp. jejichž výsledná hodnota není předem jistá.
- Příkladem může být výsledek hodu kostkou ještě předtím, než hodíme, anebo venkovní teplota zítra v poledne.



- **Laplaceova def. pravděpodobnosti**
Může-li náhodný pokus vykazat konečný počet n různých, vzájemně se vylučujících, stejně možných výsledků a jestli m z těchto výsledků má za následek událost A , pak pravděpodobnost události A položíme rovnou číslu m/n

$$P(A) = \frac{m}{n}$$

Model pro hod kostkou

Úkol: Odhadněte pst, že padne šestka

100 x opakujeme pokus

```
hody=ceil(6*rand(100,1))
```

transformace $U(0,1)$

nebo

```
hody2=randi(6,100,1)
```

diskrétní $U(1, 2, \dots, 6)$

Bodovým odhadem pravděpodobnosti je relativní četnost.

```
pst6=sum(hody==6)/1000
```

Základní pojmy

Náhodný pokus -výsledky závisí nejen na předepsaných podmínkách, ale také na **náhodě**.

Náhodný jev - každý výsledek (elementární jev) nebo skupina výsledků náhodného pokusu.

Jakékoliv tvrzení o výsledku náhodného pokusu, o kterém lze (po provedení pokusu) rozhodnout, zda je pravdivé.

Prostor elementárních jevů S - množina všech možných výsledků pokusů

- jsme schopni je všechny předem vyjmenovat (*ve sš matematice konečná*),
- jsou vzájemně neslučitelné (*žádné dva nemohou nastat současně*),
- jeden z nich nastane vždy (*nemůže nastat žádný jiný než jeden z jmenovaných*),

Chevalier de Mere



- **Hod jednou kostkou**

Chevalier de Mere přijímal sázky na to, že hodí minimálně jednu šestku ve čtyřech po sobě následujících hodech.

Pravděpodobnost padnutí šestky je v každém hodu 1/6. Domníval se, že jeho šance na padnutí šestky ve čtyřech hodech je tedy $(1/6) \times 4 = 2/3$.

- **Správně:** Vypočítáme pravděpodobnost doplňkového jevu k počtu nepříznivých možností: $P(A) = 1 - (5/6)^4 = 0,517746914$

- **Hod dvěma kostkami.**

Vyhraje, pokud se nám alespoň jedenkrát podaří hodit 2 šestky ve 24 hodech.

Pravděpodobnost vrhnutí dvou šestek v jednom hodu je 1/36.

De Mere předpokládal, že jeho šance je tedy $(1/36) \times 24$ a tedy opět 2/3 .

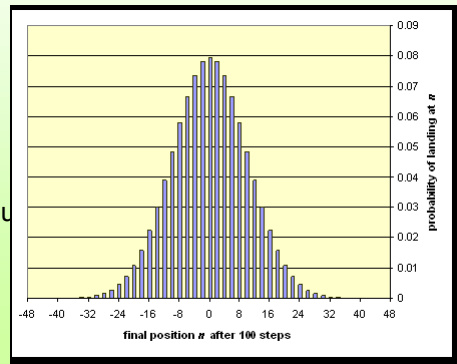
- **Správně:** Pravděpodobnost výhry bude:
 $P(A) = 1 - (35/36)^{24} = 0,491403876$.

Metoda Monte Carlo

- Metoda, která používá stochastických metod k řešení deterministických problémů.

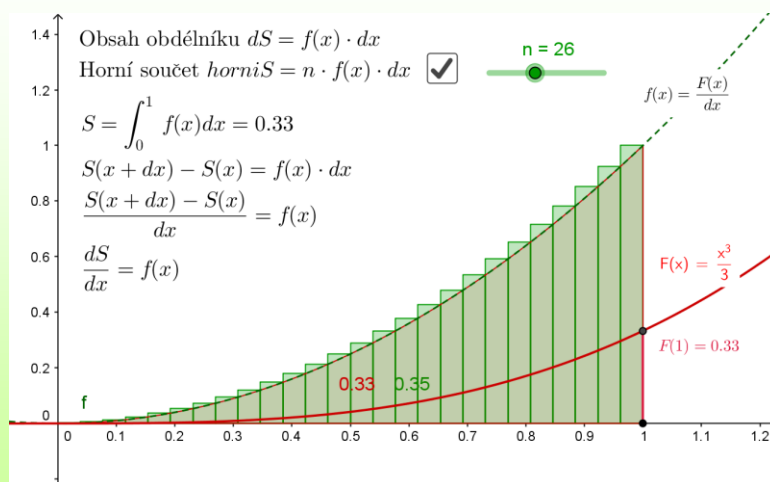
Postup:

1. Systém nahradíme simulačním modelem se stejnými pravděpodobnostními charakteristikami a chování mnohonásobně simulujeme na modelu.
2. Jednotlivé charakteristiky výstupu nahradíme bodovým odhadem - střední hodnotu průměrem - pst stavu relativní četností




Obr: Náhodná procházka 2D (1D)

Výpočet integrálu metodou Monte Carlo



Výpočet derivace funkce a "hledání obsahu plochy pod grafem" jsou "obrácené" operace.

Výpočet integrálu metodou Monte Carlo



$$I = \int_a^b f(x)$$

$$\Omega = \langle a, b \rangle \times \langle 0, d \rangle$$

$$I = S_B$$


X ... náhodně vybraný bod z Ω

$$X \in B \Leftrightarrow f(x) > y$$

$$P(X \in B) = \frac{S_B}{S_\Omega}$$

Pravděpodobnost odhadneme relativní četností

$$P(X \in B) = \frac{N_B}{N_\Omega}$$



Simulace Monte Carlo

%Určete obsah plochy $y=x^2$ pod grafem na intervalu (0,1)

```
clc;clear;
```

```
datax=rand(100,1);
```

```
datay=rand(100,1);
```

```
NoS=sum(datay < datax.^2)
```

```
area=NoS/100
```

```
n=100;pokusy=500
```

```
area = zeros(1,n);
```

```
for i=1:n
```

```
datax=rand(pokusy,1);
```

```
datay=rand(pokusy,1);
```

```
NoS=sum(datay < datax.^2);
```

```
area(i)=NoS/pokusy;
```

```
end
```

```
mean(area)
```

<https://scratch.mit.edu/projects/148016090/>

Metoda Monte Carlo

- Při každém běhu dostaneme jiný výsledek
 - Odpovídá reálné situaci
- Každý výsledek jednoho běhu stochastického simulačního modelu musí být považován za jedno pozorování statistického experimentu !
- Kolikrát musíme opakovat simulaci abychom mohli „důvěřovat“ výsledku?

Intervalový odhad zkoumaných veličin

- Provádíme n nezávislých pokusů – získáme realizace X_i zkoumané náhodné veličiny . Interval spolehlivosti pro odhad střední hodnoty náhodné veličiny

$$\left(\bar{X} - t_{\frac{(1-\alpha)}{2},(n-1)} \frac{\sigma}{\sqrt{n}}; \bar{X} + t_{\frac{(1-\alpha)}{2},(n-1)} \frac{\sigma}{\sqrt{n}} \right)$$

- σ - standardní odchylka získaná ze vzorku
- α – hladina významnosti

$t_{\frac{(1-\alpha)}{2},(n-1)}$ kvantil Studentova rozdělení s $(n-1)$ stupni volnosti

Statistika



aneb známe tři druhy lži:

- úmyslná
- neúmyslná
- statistika

Statistika je metoda, jak vyjádřit nejistá data s přesností na setinu procenta.

Statistika

- Shromažďování a třídění dat
- Analýza za účelem formulování obecných závěrů a rozhodování

Popisná statistika - Metody zjišťování a sumarizace informací

Inferenční statistika - Měření spolehlivosti závěrů o populaci založených na informacích získaných z výběru



den	teplota
1.4.2008	11
2.4.2008	10
3.4.2008	10
4.4.2008	9
5.4.2008	8
6.4.2008	7
7.4.2008	8
8.4.2008	9
9.4.2008	4
10.4.2008	9
11.4.2008	8
12.4.2008	7
13.4.2008	8
14.4.2008	9
15.4.2008	12
16.4.2008	13
17.4.2008	15
18.4.2008	11
19.4.2008	12
20.4.2008	10
21.4.2008	9
22.4.2008	8
23.4.2008	9
24.4.2008	11
25.4.2008	10
26.4.2008	9
27.4.2008	6

Elementární zpracování dat

- cílem je zjednodušit nějaká data tak, abychom se v nich lépe vyznali
- důsledkem je ztráta informací!

průměrná teplota: 9.2°C
 minimum: 4°C
 maximum: 15°C
 rozsah: 11°C
 modus: 9°C
 medián: 9°C
 rozptyl: 5.1°C
 směrodatná odchylka: 2.3°C

Hodnota statistického znaku

1. Kvalitativní

- Nominální – kvalitativní znaky
Jednotlivé hodnoty jsou neporovnatelné, data nelze seřadit, neexistuje nic jako „velikost“
- Ordinární – lze je seřadit a přiřadit jim číslo, tj. určit pořadí
Neumožňují posoudit vzdálenost

2. Kvantitativní

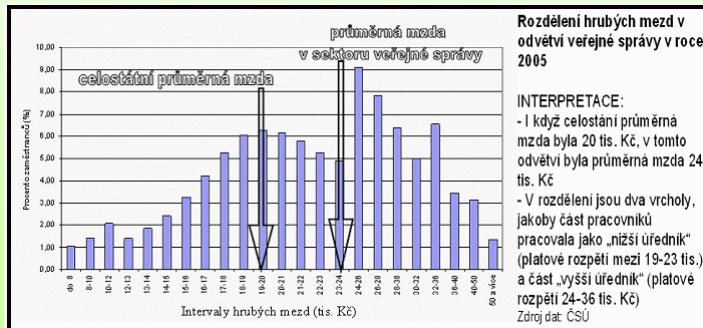
- Diskrétní (je možné je spočítat)
- Spojité (údaje, které lze měřit -přečíst na stupnici)

Určete typ dat:

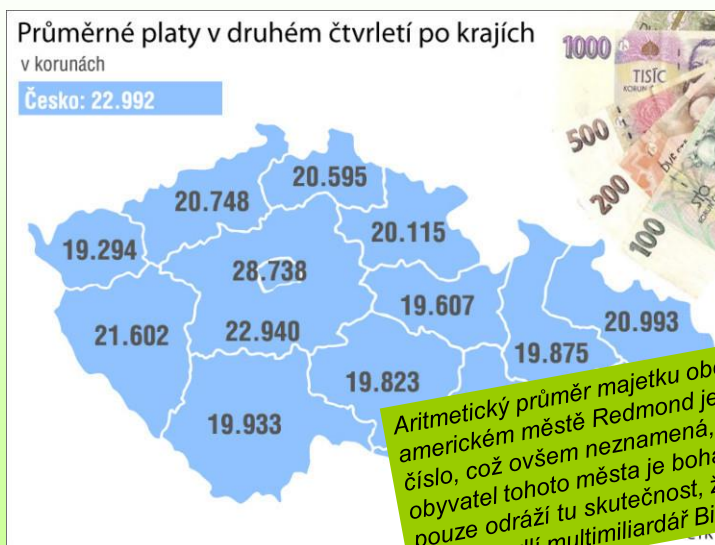
věk člověka, výška, počet podlaží, teplota, pohlaví, zaměstnání, účel budovy,
barva očí, dosažené vzdělání, počet studentů, známka ze zkoušky,

Třídění – rozdělení dat do tříd

1. Tříd musí být „tak akorát“
cílem je potlačit kolísání četností, ale nesmíme setřít charakteristické rysy
2. Třídy musí být disjunktní
3. Stejná šířka intervalu



Základní popisné statistiky



Charakteristiky polohy

- **aritmetický průměr** mean (data)
výběrový průměr je nejlepší nestranný konzistentní odhad střední hodnoty základního souboru.
Citlivý na outliery - vychýlené hodnoty můžeme odfiltrvat pomocí percentilu apod. (86% percentil říká, že 86% prvků leží pod touto hodnotou a 14% nad ní)
- **modus** mode (data)
 - Nejčastěji se vyskytující hodnota
 - min. modus = 1, max. modus = N
 - může jich být víc
 - odpovídá vrcholu histogramu četností
- **medián (50 % kvantil)** median (data)
 - polovina pozorování menší než medián, polovina větší
 - střed uspořádaného základního souboru
 - i pro pouze „seřazená“ data (na ordinální stupnici) – např. jídlo je vynikající (1), dobré (2), ucházející (3), bez chuti (4), nic moc (5), hnusné (6), vyvolávající zvracení (7)
 - v případě „ulítlé“ hodnoty lepší vypovídající hodnota než průměr – robustní charakteristika


Míry rozptýlení

$$\sigma^2 = \frac{\sum_{i=1}^N (X_i - \mu)^2}{N}$$

- **rozptyl (variance)** var (data)
 - průměrná hodnota druhé mocniny odchylky od průměru
- **směrodatná odchylka** std (data)
 - odmocnina z rozptylu
 - čím menší, tím nižší variabilita dat
- **variační koeficient** – porovnává variabilitu nestejně velkých objektů (myš a slon) – bezrozměrné číslo
$$CV = \frac{\sigma}{X}$$
- **Qvartilové rozpětí**
| kvartil 75 % - kvartil 25 % |

- směrodatná odchylka
 - empirické pravidlo: většina hodnot se neodlišuje od průměru o více než jednu směrodatnou odchylku a skoro všechny hodnoty jsou v pásmu od dvou směrodatných odchylek od průměru.

normální rozdělení:



Darwin (1809 - 1882) byl prvním člověkem, který evoluci vnímal jako proces v první řadě statistický.

Výpočetní složitost algoritmů

Složitost algoritmu udává, jak je daný algoritmus rychlý (kolik provede elementárních operací) vzhledem k množině vstupních dat.

Asymptotická složitost - rozdělení algoritmů do tříd složitostí, u kterých platí, že od určité velikosti dat, je algoritmus dané třídy vždy pomalejší než algoritmus třídy předchozí, bez ohledu na to, jestli je některý z počítačů výkonnější.

$$1 \ll \log(n) \ll n \ll n \cdot \log(n) \ll n^k \ll k^n \ll n! \ll n^n$$

$O(f(n))$ znamená, že

algoritmus probíhá asymptoticky stejně rychle nebo rychleji než $f(n)$


Pro počet operací $g(n)$ platí

$$\exists n_0, c; \forall n > n_0 \text{ je } c \cdot f(n) < g(n)$$

```
n=1:1:10;
plot(n,n,'r',n,n.*log(n),'g','LineWidth',2)
figure
plot(n,n.^2,'m',n,2.^n,'c')
```

Násobení matic

```
for i=10:1000;  
tic;  
soucin(i);  
time(i) = toc;  
end  
plot(time);
```




- `function[out]=soucin(n)`
- `%soucin dvou nahodne vygenerovanych matic nxn`
- `out = rand(n,n)*rand(n,n);`

soucintictoc.m

Merge sort ?

```
time=zeros(1,100)  
for n=1:100:50000  
L=randi(50,n,1);  
tic  
sort(L);  
time(n)=toc;  
end  
plot(time)
```



- $A + B \cdot n \cdot \log(n)$

vyp_slozitost.m


Faktoriál

https://cs.wikipedia.org/wiki/Rekurze_%28programov%C3%A1n%C3%AD%29

```
clear;
for n=1:200
    tic
    factorial(n);
    time1(n)=toc;
    tic
    factorial2(n);
    time2(n)=toc;
end
```

```
end
```

```
plot(1:200,time1,'r',1:200,time2,'g','LineWidth',2)
```



```
function [out]=factorial2(n)
if n==0
    out=1;
else out=factorial2(n-1)*n;
end
```

vyp_slozitost2.m