

Náhodné signály

Honza Černocký, ÚPGM

Signály ve škole a v reálném světě

Deterministické

- Rovnice
- Obrázek
- Algoritmus
- Kus kódu




Můžeme **vypočítat**

Málo informace !

Náhodné

- Nevíme přesně
- Pokaždé jiné
- Především u „přírodních“ a „biologických“ signálů
- Můžeme **odhadovat parametry**




Příklady




- Řeč
- Hudba
- Video
- Kursy měn
- Technické signály (diagnostika)
- Měření (jakýchkoliv veličin)
- Prostě skoro vše ...

Matematicky

- Pouze pro diskrétní čas (vzorky)
- Systém náhodných veličin definovaných pro každé n
- Prozatím se na ně budeme dívat nezávisle.




Množina realizací



Souborové odhady





- Fixovat n a vybrat všechny hodnoty
- Odhadovat – odhad bude platný jen pro toto n

Podle oboru hodnot


- Diskrétní obor hodnot $\xi[n] \in [h_1, h_2, \dots, h_H]$
 - Házení mincí
 - Kostka
 - Ruleta
 - Bity z přenosového kanálu
- Reálný obor hodnot $\xi[n] \in \mathcal{R}$
 - Síla větru
 - Audio
 - Kurs CZK/EUR
 - atd

Diskrétní data

- 50 let hraní rulety – $\Omega = 50 \times 365$ realizací
- Za den $N=1000$ her


$$\xi[n] \in [h_1, h_2, \dots, h_H] = [0, 1, 2, \dots, 36]$$

| | | | | | | | | | | | | | | | | | | | |
|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|----|
| 30 | 34 | 10 | 14 | 29 | 35 | 6 | 35 | 33 | 30 | 35 | 30 | 9 | 11 | 11 | 13 | 17 | 22 | 33 | 21 |
| 33 | 23 | 35 | 0 | 15 | 15 | 17 | 8 | 12 | 23 | 24 | 24 | 26 | 12 | 16 | 21 | 9 | 7 | 14 | 18 |
| 4 | 4 | 13 | 28 | 15 | 9 | 19 | 29 | 25 | 35 | 22 | 36 | 12 | 34 | 4 | 17 | 31 | 7 | 35 | 15 |
| 33 | 34 | 6 | 3 | 8 | 29 | 5 | 2 | 10 | 26 | 12 | 32 | 28 | 31 | 36 | 26 | 36 | 5 | 34 | 35 |
| 23 | 17 | 21 | 28 | 16 | 28 | 1 | 2 | 9 | 36 | 7 | 3 | 3 | 36 | 34 | 28 | 18 | 33 | 14 | 3 |
| 3 | 34 | 18 | 29 | 12 | 26 | 9 | 23 | 3 | 12 | 9 | 15 | 17 | 0 | 34 | 1 | 6 | 35 | 28 | 24 |
| 10 | 36 | 9 | 17 | 25 | 30 | 16 | 9 | 2 | 10 | 10 | 9 | 11 | 17 | 10 | 25 | 23 | 23 | 24 | 25 |
| 20 | 10 | 34 | 12 | 5 | 8 | 20 | 10 | 26 | 9 | 23 | 2 | 7 | 4 | 1 | 30 | 22 | 13 | 4 | 15 |
| 35 | 19 | 17 | 27 | 14 | 2 | 9 | 4 | 8 | 24 | 16 | 14 | 13 | 13 | 32 | 21 | 27 | 30 | 5 | 33 |
| 35 | 0 | 33 | 4 | 0 | 33 | 20 | 10 | 1 | 9 | 12 | 0 | 34 | 32 | 1 | 18 | 0 | 11 | 12 | 35 |
| 5 | 5 | 4 | 13 | 27 | 4 | 3 | 33 | 29 | 13 | 20 | 15 | 19 | 6 | 29 | 12 | 22 | 2 | 2 | 4 |
| 35 | 13 | 11 | 30 | 16 | 28 | 0 | 1 | 1 | 4 | 22 | 27 | 21 | 17 | 11 | 28 | 15 | 3 | 3 | 8 |
| 35 | 28 | 15 | 35 | 15 | 35 | 4 | 5 | 17 | 36 | 17 | 30 | 1 | 32 | 27 | 26 | 13 | 17 | 3 | 2 |
| 17 | 11 | 14 | 15 | 12 | 33 | 5 | 31 | 15 | 28 | 12 | 35 | 8 | 22 | 33 | 3 | 0 | 25 | 33 | 31 |
| 29 | 20 | 35 | 19 | 14 | 26 | 1 | 31 | 23 | 14 | 1 | 2 | 33 | 17 | 2 | 0 | 14 | 24 | 2 | 13 |



Spojité data

- $\Omega = 1068$ realizací tečení vody kohoutkem
- Každá realizace má 20ms, $F_s = 16\text{kHz}$, takže $N = 320$.



Popis náhodného signálu funkcemi

- Distribuční funkce – CPDF (cumulative probability distribution function)

$$F(x, n) = \mathcal{P}\{\xi[n] < x\}$$

- x není nic náhodného, je to hodnota, pro kterou distribuční funkci zkoumáme, měříme. Např. „jaké procento populace je menší než 165 cm?“ $x=165$

Odhad pravděpodobností čehokoliv

$$\text{probability} = \frac{\text{count}}{\text{total}}$$



LAŠA

VM HHHHHHHHHHHH

KOF. O3 H

PAR. ¹²² H

KOF. O3 H H H

KAVA H H H

ML. H H H

V.M. H H H H

POC. H H

Sul. H H

Soda O3 +

POC. 25, +

HRANOL. +

TATAZKA +

KINDONKY +

SEK. ¹⁰ +

SEK. 10, +


Sul. 10

ČOC. +

HHHHHH HHHHH


Odhad distribuční funkce z dat

$$\hat{F}(x, n) = \frac{\text{count}(\xi_\omega[n] < x)}{\Omega}$$



Jaké dílky na ose x ?


- Dostatečně jemné
- Ale nemá cenu, pokud bude odhad pořád stejný...




Kolikrát byla hodnota menší než $x=165$?

$P = 4 / 10, F(x,n) = 0.4$

Odhad ruleta



Odhad voda



Pravděpodobnosti hodnot

- Pro diskrétní obor hodnot OK $\mathcal{P}(X_i, n)$
- Celková masa pravděpodobností je 1

$$\sum_{\forall i} \mathcal{P}(X_i, n) = 1$$

- Odhad opět pomocí countů

$$\mathcal{P}(\hat{X}_i, n) = \frac{\text{count}(X_i, n)}{\text{total}[n]}$$




0

1

2

36

Výsledek pro ruletu



$$\sum_{\forall i} \mathcal{P}(X_i, n) = 1$$


Spojité obor hodnot

$$\mathcal{P}(x, n) = ???$$

- Nemá význam nebo nula ...

=> Potřebujeme **hustotu pravděpodobnosti!**

Příklady z reálného světa ...



Kolik km auto ujelo v čase t ???



Jaká je hmotnost kvasu tady,
v souřadnicích x, y, z ???



Rychlost

$$v(t) = \frac{dl(t)}{dt} = \frac{l(t_2) - l(t_1)}{t_2 - t_1} = \frac{\Delta l}{\Delta t}$$




Hustota

$$\rho(x, y, z) = \frac{dm}{dV} = \frac{m(x_1 \dots x_2, y_1 \dots y_2, z_1 \dots z_2)}{(x_2 - x_1)(y_2 - y_1)(z_2 - z_1)} = \frac{\Delta m}{\Delta V}$$

Funkce hustoty rozdělení pravděpodobnosti

$$p(x, n) = \frac{dF(x, n)}{dx}$$



Probability distribution function - PDF

Nedá se odhadnout jednodušeji?

$$v(t) = \frac{dl(t)}{dt} = \frac{l(t_2) - l(t_1)}{t_2 - t_1} = \frac{\Delta l}{\Delta t}$$


$$\rho(x, y, z) = \frac{dm}{dV} = \frac{m(x_1 \dots x_2, y_1 \dots y_2, z_1 \dots z_2)}{(x_2 - x_1)(y_2 - y_1)(z_2 - z_1)} = \frac{\Delta m}{\Delta V}$$

$$p(x, n) = \frac{\text{probability}}{\text{normalization}}$$

Pravděpodobnosti **hodnot** jsou nesmysl, ale můžeme použít pravděpodobnosti **intervalů – chlívků!**

Histogram


$$\text{histogram}(x \in \textit{interval}, n) = \text{count}(x \in \textit{interval}, n)$$



Chlívky !


Pravděpodobnost

$$\mathcal{P}(x \in interval, n) = \frac{\text{count}(x \in interval, n)}{\Omega}$$



Hustota pravděpodobnosti

$$p(x \in interval, n) = \frac{\text{count}(x \in interval, n)}{\Omega|interval|}$$




Jak je to s celkem ?



$$\int_t v(t) = ??$$



$$\iiint_V \rho(x, y, z) = ??$$



$$\int_{x=-\infty}^{+\infty} p(x, n) = 1$$

Kontrola opět pomocí
chlívků...

Sdružená funkce hustoty rozdělení pravděpodobnosti

- Jsou nějaké vztahy mezi vzorky v různých časech ?
- Jsou nezávislé nebo je mezi nimi souvislost ?


$$\mathcal{P}(X_i, X_j, n_1, n_2)$$

$$p(x_i, x_j, n_1, n_2)$$

K čemu to bude dobré ?

- Hledání závislostí
- Spektrální analýza

Dva různé časy ...



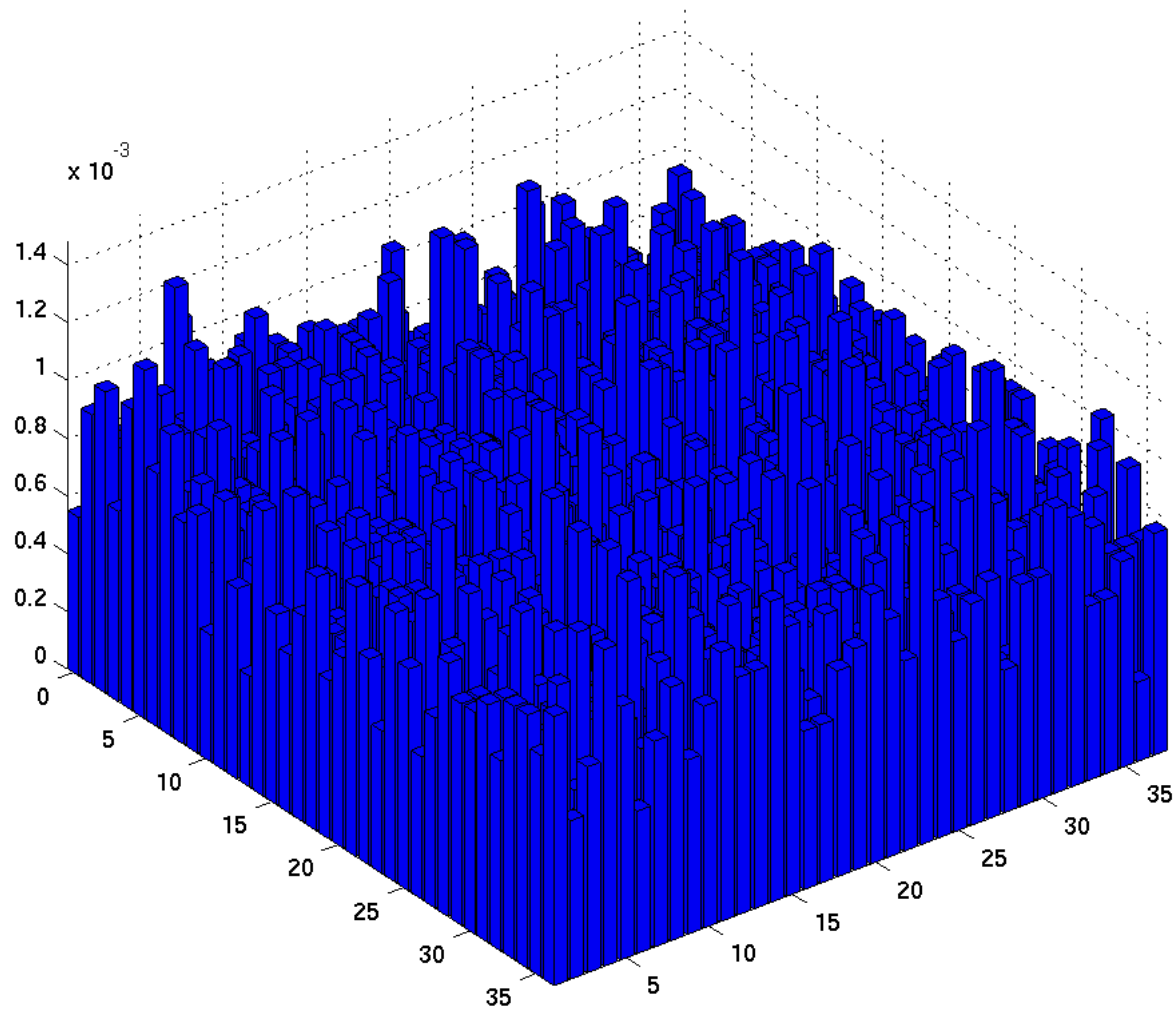
Odhad – opět otázky, tentokrát se spojkou „a“



Něco v
čase n_1
a
něco v
čase n_2


joint probability = $\frac{\text{count that something happened simultaneously in } n_1 \text{ AND } n_2}{\text{total}}$

Sdružené counts: $n_1=10$, $n_2=11$




Sdružené pravděpodobnosti: $n_1=10$, $n_2=11$

$$\hat{\mathcal{P}}(X_i, X_j, n_1, n_2) = \frac{\text{count}(\xi[n_1] = X_i \text{ AND } \xi[n_2] = X_2)}{\Omega}$$




Sdružené pravděpodobnosti: $n_1=10$, $n_2=10$

$$\hat{\mathcal{P}}(X_i, X_j, n_1, n_2) = \frac{\text{count}(\xi[n_1] = X_i \text{ AND } \xi[n_2] = X_2)}{\Omega}$$



Sdružené pravděpodobnosti: $n_1=10$, $n_2=13$

$$\hat{\mathcal{P}}(X_i, X_j, n_1, n_2) = \frac{\text{count}(\xi[n_1] = X_i \text{ AND } \xi[n_2] = X_2)}{\Omega}$$



Spojité obor hodnot

- Pravděpodobnosti přímo nepůjdou ...


Histogram

=> pravděpodobnosti 2D chlívků

=> hustota pravděpodobnosti v chlívkách


Sdružený histogram – counts, $n_1=10, n_2=11$

$\text{histogram}(x_1 \in \text{interval}_1, x_2 \in \text{interval}_2, n_1, n_2) = \text{count}(x_1 \in \text{interval}_1, n_1 \text{ AND } x_2 \in \text{interval}_2, n_2)$




Sdružené pravděpodobnosti chlívků, $n_1=10$, $n_2=11$

$$\mathcal{P}(x_1 \in interval_1, x_2 \in interval_2, n_1, n_2) = \frac{\text{count}(x_1 \in interval_1, n_1 \text{ AND } x_2 \in interval_2, n_2)}{\Omega}$$




Sdružená funkce hustoty rozdělení pravděpodobnosti, $n_1=10$, $n_2=11$

$$p(x_1 \in interval_1, x_2 \in interval_2, n_1, n_2) = \frac{\text{count}(x_1 \in interval_1, n_1 \text{ AND } x_2 \in interval_2, n_2)}{\Omega |interval_1| |interval_2|}$$




Sdružená funkce hustoty rozdělení pravděpodobnosti, $n_1=10$, $n_2=10$

$$p(x_1 \in interval_1, x_2 \in interval_2, n_1, n_2) = \frac{\text{count}(x_1 \in interval_1, n_1 \text{ AND } x_2 \in interval_2, n_2)}{\Omega |interval_1| |interval_2|}$$




Sdružená funkce hustoty rozdělení pravděpodobnosti, $n_1=10$, $n_2=16$

$$p(x_1 \in interval_1, x_2 \in interval_2, n_1, n_2) = \frac{\text{count}(x_1 \in interval_1, n_1 \text{ AND } x_2 \in interval_2, n_2)}{\Omega |interval_1| |interval_2|}$$



Sdružená funkce hustoty rozdělení pravděpodobnosti, $n_1=10$, $n_2=23$

$$p(x_1 \in interval_1, x_2 \in interval_2, n_1, n_2) = \frac{\text{count}(x_1 \in interval_1, n_1 \text{ AND } x_2 \in interval_2, n_2)}{\Omega |interval_1| |interval_2|}$$



Momenty

- Jednočíselné hodnoty charakterizující náhodný signál.
- Pořád ještě v určitém čase n
- Očekávání (expectation) něčeho

Očekávání = suma přes všechny možné hodnoty x
pravděpodobnost (x)
krát to, co očekáváme

Někdy suma, někdy integrál ...

Střední hodnota




- Očekávaní hodnoty

$$a[n] = E\{\xi[n]\}$$

Střední hodnota

– diskrétní obor hodnot




$$a[n] = \sum_{\forall X_i} \mathcal{P}(X_i, n) X_i$$



$$a[10] = 18.0422$$

Střední hodnota – spojitý obor hodnot

$$a[n] = \int_x p(x, n) x dx$$



$$a[10] = -0.0073$$

Rozptyl (variance)





- Očekávání ustředněné hodnoty na druhou
- Energie, výkon ...

$$D[n] = E\{(\xi[n] - a[n])^2\}$$

Rozptyl

– diskrétní obor hodnot

$$D[n] = \sum_{\forall X_i} \mathcal{P}(X_i, n) (X_i - a[n])^2$$







$$D[10] = 113.8563$$

Rozptyl


– spojitý obor hodnot

$$D[n] = \int_x p(x, n)(x - a[n])^2 dx$$



$$D[10] = 0.0183$$

Souborové odhady



Toto znáte již ze ZŠ ...

- Diskrétní obor hodnot (ruleta)
- $n_1 = 10$

$$\hat{a}[n] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} \xi_{\omega}[n]$$

$$\hat{a}[10] = 18.0422$$

$$\hat{D}[n] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} (\xi_{\omega}[n] - \hat{a}[n])^2$$

$$\hat{D}[10] = 113.8563$$

Toto znáte již ze ZŠ ...

- Spojitý obor hodnot (voda)
- $n_1 = 10$

$$\hat{a}[n] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} \xi_{\omega}[n]$$

$$\hat{a}[10] = -0.0069$$

$$\hat{D}[n] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} (\xi_{\omega}[n] - \hat{a}[n])^2 \quad \hat{D}[10] = 0.0183$$

... Rovnice jsou stejné 😊

Korelační koeficient



- Očekávání násobení dvou hodnot z dvou různých časů

$$R[n_1, n_2] = E\{\xi[n_1]\xi[n_2]\}$$

- Co znamená, když je $R[n_1, n_2]$
 - Velký ?
 - Malý nebo nula ?
 - Velký záporný ?

Diskrétní obor hodnot, $n_1=10, n_2=11$

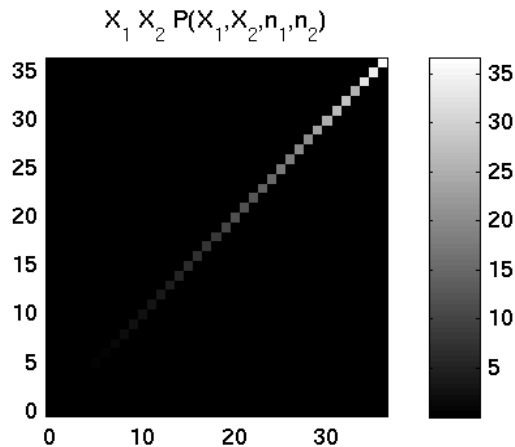


$$R[n_1, n_2] = \sum_{\forall X_1} \sum_{\forall X_2} \mathcal{P}(X_1, X_2, n_1, n_2) X_1 X_2$$



$$R[10, 11] = 324.2020$$

Diskrétní obor hodnot, $n_1=10, n_2=10$




$$R[n_1, n_2] = \sum_{\forall X_1} \sum_{\forall X_2} \mathcal{P}(X_1, X_2, n_1, n_2) X_1 X_2$$



$$R[10, 10] = 439.3770$$

Diskrétní obor hodnot, $n_1=10$, $n_2=13$







$$R[n_1, n_2] = \sum_{\forall X_1} \sum_{\forall X_2} \mathcal{P}(X_1, X_2, n_1, n_2) X_1 X_2$$



$$R[10, 13] = 326.9284$$

Spojitéý obor hodnot, $n_1=10$, $n_2=11$





$$R[n_1, n_2] = \int_{x_1} \int_{x_2} p(x_1, x_2, n_1, n_2) x_1 x_2 dx_1 dx_2$$



$$R[10, 11] = 0.0159$$

Spojitéý obor hodnot, $n_1=10, n_2=10$




$$R[n_1, n_2] = \int_{x_1} \int_{x_2} p(x_1, x_2, n_1, n_2) x_1 x_2 dx_1 dx_2$$



$$R[10, 10] = 0.0184$$

Spojitéý obor hodnot, $n_1=10$, $n_2=16$




$$R[n_1, n_2] = \int_{x_1} \int_{x_2} p(x_1, x_2, n_1, n_2) x_1 x_2 dx_1 dx_2$$



$$R[10, 16] = 0.00038$$


Spojitéý obor hodnot, $n_1=10$, $n_2=23$

$$R[n_1, n_2] = \int_{x_1} \int_{x_2} p(x_1, x_2, n_1, n_2) x_1 x_2 dx_1 dx_2$$



$$R[10, 23] = -0.0139$$

Přímý souborový odhad



Diskrétní obor hodnot

$$\hat{R}[n_1, n_2] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} \xi_{\omega}[n_1] \xi_{\omega}[n_2]$$

$$R[10, 10] = 439.3770$$

$$R[10, 11] = 324.2020$$

$$R[10, 13] = 326.9284$$

Spojité obor hodnot

$$\hat{R}[n_1, n_2] = \frac{1}{\Omega} \sum_{\omega=1}^{\Omega} \xi_{\omega}[n_1] \xi_{\omega}[n_2]$$

$$R[10, 10] = 0.0183$$


$$R[10, 11] = 0.0160$$

$$R[10, 16] = 3.8000e-04$$

$$R[10, 23] = -0.0140$$


Stejné rovnice 😊

Sekvence korelačních koeficientů - ruleta



Užitečné
???

Sekvence korelačních koeficientů - voda



Zajímavé
!!!

Stacionarita

- Chování stacionárního náhodného procesu se nemění v čase (nebo doufáme, že ne ...)
- Veličiny a funkce nejsou závislé na čase n
- Korelační koeficienty nejsou závislé na n_1 a n_2 , ale jen na jejich rozdílu $k = n_2 - n_1$



$$F(x, n) \rightarrow F(x) \quad p(x, n) \rightarrow p(x)$$



$$a[n] \rightarrow a \quad D[n] \rightarrow D \quad \sigma[n] \rightarrow \sigma$$


$$p(x_1, x_2, n_1, n_2) \rightarrow p(x_1, x_2, k)$$

$$R[n_1, n_2] \rightarrow R(k)$$

Je ruleta stacionární ?









Stationary



Je voda stacionární ?


F(x,n) for many ns



p(x,n) for many ns







Stationary

Ergodicita

- Parametry se dají odhadnout z jediné realizace
... nebo alespoň doufáme
... většinou nám stejně nic jiného nezbyvá.

$$\cancel{\xi[n]} \Rightarrow \xi[n]$$



Časové odhady

$$\hat{a} = \frac{1}{N} \sum_{n=0}^{N-1} \xi[n] \quad \hat{D} = \frac{1}{N} \sum_{n=0}^{N-1} [\xi[n] - \hat{a}]^2 \quad \hat{\sigma} = \sqrt{\hat{D}}$$


$$\hat{R}[k] = \frac{1}{N} \sum_{n=0}^{N-1} \xi[n] \xi[n+k]$$

Ruleta

$$a = 18.0348$$

$$D = 114.4742$$

$R[k]$




Voda

$$a = -0.0035$$


$$D = 0.0168$$

$R[k]$




Časový odhad sdružených pravděpodobností ?


$$\hat{\mathcal{P}}(X_i, X_j, k) = \frac{\text{count}(\xi[n] = X_1 \text{ AND } \xi[n+k] = X_2)}{N}$$



Ruleta,
 $k = 0$



Ruleta,
 $k = 1$



Ruleta,
 $k = 3$

Spektrální analýza náhodných signálů

- Nevíme na jakých jsou frekvencích
 - Není žádná základní frekvence
 - Nejsou žádné harmonické
- Fáze nemají smysl
- Spektrum musí udávat jen hustotu výkonu signálu.

=> Spektrální hustota výkonu

(Power spectral density, PSD)

Výpočet PSD z korelačních koeficientů


$$G\left(\frac{k}{N}\right) = DFT\{R[n]\}$$

Normovaná
frekvence

$$G\left(\frac{kF_s}{N}\right) = DFT\{R[n]\}$$

Skutečná
frekvence

PSD voda



???

Odhad PSD ze signálu


$$G\left(\frac{k}{N}\right) = \frac{|DFT\{\xi[n]\}|^2}{N}$$

Normovaná
frekvence

$$G\left(\frac{kF_s}{N}\right) = \frac{|DFT\{\xi[n]\}|^2}{N}$$


Skutečná
frekvence

PSD odhad ze signálu - voda




Welchova metoda – zlepšení spolehlivosti odhadu

- Průměrování přes několik úseků signálu



Bílý šum


- Spektrum bílého světla je ploché
- Spektrální hustota výkonu $G(f)$ bílého šumu by tedy měla být plochá



Korelační koeficienty bílého šumu


$$G\left(\frac{kF_s}{N}\right) = DFT\{R[n]\}$$

- Jak musí vypadat $R[k]$, aby byla jejich DFT konstanta ?




Bílý šum

- Signál, který má jen $R[k]$ nenulový
- A tedy nemá **žádné závislosti mezi vzorky**




Určení PSD bílého šumu pomocí DFT

$$G\left(\frac{kF_s}{N}\right) = \frac{|DFT\{\xi[n]\}|^2}{N}$$



Welch ... help ...



SUMMARY

- Náhodné signály jsou ty, co nás zajímají
 - Jsou kolem nás
 - Nesou informaci
- Diskrétní obor hodnot vs. spojitý
- Nedají se přesně zapsat, jiné způsoby popisu
 - Množina realizací
 - Funkce – distribuční, pravděpodobnosti, hustota pravděpodobnosti
 - Skaláry – momenty
 - Chování mezi dvěma časy – korelační koeficienty

SUMMARY II.

- Počty=County
 - Nějakého jevu „kolikrát je hodnota v intervalu 5 až 10?“
- Pravděpodobnosti
 - se odhadují jako count/total.
- Hustota pravděpodobnosti
 - Se odhaduje jako pravděpodobnost / velikost interval (1D i 2D)
- Je-li k dispozici množina realizací – souborové odhady.

SUMMARY III.

- Stacionarita – nezávisí na čase.
- Ergodicita – vše lze odhadnout z jedné realizace
 - Časové odhady
- Spektrální analýza
 - Spektrální hustota výkonu
 - Z korelačních koeficientů
 - Nebo přímo ze signálu, často potřeba zlepšení spolehlivosti odhadu průměrováním

SUMMARY IV

- Bílý šum
 - Nemá závislosti mezi vzorky (nekorelované vzorky)
 - Takže korelační koeficient $R[0]$ je něco, ostatní nulové
 - Takže je DFT konstantní
 - Bílé světlo má také konstantní spektrum

TO BE DONE

- Dá se nějak modelovat tvorba náhodných signálů ?
- Vzorky při časovém odhadu korelačních koeficientů „ubývají“, co s tím ?
- Dá se bílý šum obarvit ?
- Jak je to přesně se spektrální hustotou výkonu ?
- Dá se toto celé použít pro rozpoznávání / klasifikaci / detekci ?

The END