



Sygnały losowe i ich analiza

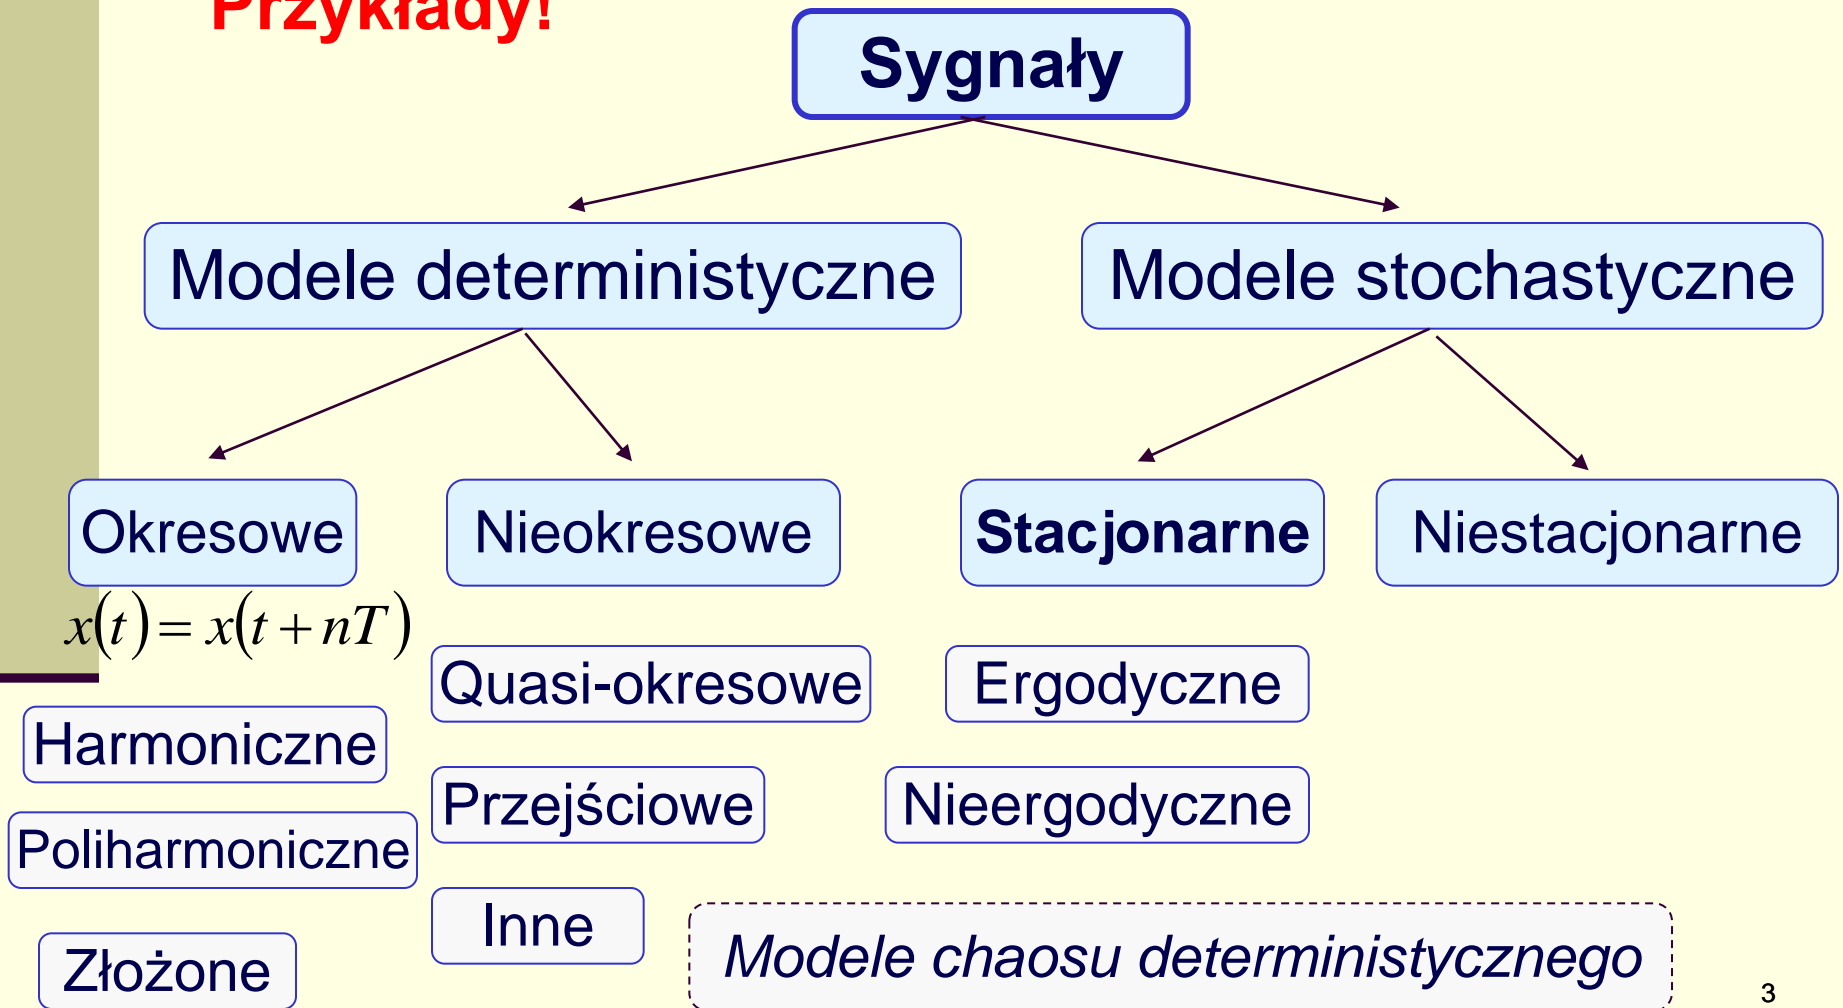


Sygnały biologiczne



Modele sygnałów

Przykłady!




Sygnał losowy a sygnał stochastyczny

sygnał deterministyczny

(próbki można przewidywać z dużą dokładnością)

sygnał losowy

(niemożliwe przewidywanie wartości próbek sygnału, można tylko określić zadane parametry sygnału)




Sygnały losowe stacjonarne i ergodyczne

Sygnały stacjonarne

Momenty statystyczne wyznaczane dla danej realizacji w czasie (np. średnia, wariancja) nie podlegają zmianom w czasie.

Sygnały ergodyczne


Momenty statystyczne (np. średnia, wariancja) wyznaczane w czasie i dla różnych zbiorów realizacji są sobie równe.



Sygnały losowe stacjonarne i ergodyczne

Sygnał losowy jest ergodyczny jeżeli:

$$\frac{1}{N} \sum_{t=0}^{t=N-1} X_{i=const}(t) = \frac{1}{N} \sum_{i=0}^{i=N-1} X_i(t_n = const)$$



Sygnał losowy (parametry)

Dokładny przebieg **sygnału losowego**, nie jest możliwy do wyznaczenia - można charakteryzować tylko jego odpowiednio zdefiniowane parametry statystyczne.

Jako zapis (obserwacja) pewnego procesu losowego, **sygnał losowy** można interpretować jako zmienną losową i opisywać ją za pomocą wielkości i zależności probabilistycznych tj.


- **wartość oczekiwana,**
- **odchylenie standardowe,**
- **funkcja autokorelacji.**

Dla **stacjonarnych** sygnałów losowych parametry te nie zmieniają się w funkcji czasu.

Przykład - sygnał EEG


Dla sygnału elektroencefalograficznego można zastosować model stochastyczny.

Sygnał EEG jest wynikiem aktywności elektrycznej wielkiej liczby* komórek neuronowych.



*) W niektórych pracach dowodzi się, że procesy percepcji neuronowej polegają na synchronizacji czasowej specjalizowanych populacji komórek neuronowych

Rytm serca




Rytm prawidłowy –
charakter zmienności o
naturze „fraktalnej”


Rytm nieprawidłowy
(niewydolność serca) –
widoczne oscylacje szybkości
rytmu ($\sim 1/\text{min}$)

www.physionet.org

Rytm serca



Rytm serca w poważnej niewydolności serca – rytm zbyt regularny



Arytmia serca (fibrylacja przedsionków) – sygnał ma charakter losowy

www.physionet.org

Sygnał losowy – wartość oczekiwana

Wartość oczekiwana - sygnał ciągły:

$$E\{x(t)\} = \int_{-\infty}^{+\infty} xp(x)dx = x$$

```
#Python  
#see also random?  
x=random.randn(1000)  
expected=x.mean()
```

Wartość oczekiwana (estymata)- sygnał dyskretny:

$$E\{x(n)\} = \sum_{n=-N}^{n=N} x(n)p(n) = \frac{1}{2N+1} \sum_{n=-N}^{n=N} x(n) = x$$

kolejne próbki sygnału są
jednakowo prawdopodobne

Sygnał losowy - wariancja

Wariacja (średnia kwadratów odchyleń od wartości oczekiwanej)- **sygnał ciągły**:

$$\sigma^2 = E\left\{[x(t) - x]^2\right\} = \int_{-\infty}^{+\infty} [x(t) - x]^2 p(x) dx$$

Wariancja - sygnał dyskretny:

#Python

```
x=random.randn(1000)
std_dev=x.std()
variance=x.var()
```

$$\sigma^2 = \frac{1}{2N+1} \sum_{n=-N}^{n=N} [x(n) - x]^2 = \frac{1}{2N+1} \sum_{n=-N}^{n=N} x^2(n) - x^2$$

Sygnał losowy – funkcja autokorelacji

Sygnał ciągły:

$$R(\tau) = \int_{-\infty}^{\infty} x(t)x(t + \tau)dt$$

Sygnał dyskretny:


$$R(m) = \sum_{n=-\infty}^{n=\infty} x(n)x(n + m)$$

```
#Python
x=random.randn(1000)
R=correlate(x,x,mode='full')
plot(R)


#usuń składową DC
x=x-x.mean()
R=correlate(x,x,mode='full')
plot(R)
```

Pamiętaj o usunięciu składowej stałej sygnału!

Funkcja autokorelacji sygnału losowego (rozkład Gaussa $N(\mu, \sigma)=N(0,1)$)



Funkcja autokorelacji sygnału harmonicznego




Funkcja autokorelacji - ćwiczenie

Ćwiczenie komputerowe: funkcja autokorelacji

1. Załaduj zadany sygnał EKG ('ecg_s.mat').
2. Napisz procedurę do wyznaczania i wyświetlania funkcji autokorelacji sygnału dyskretnego o zadanej długości N .
3. Porównaj długość otrzymanej funkcji autokorelacji z długością sygnału.
4. Jakie własności funkcji autokorelacji zauważasz?
5. Zastanów się jakie zastosowanie może mieć funkcja autokorelacji w przetwarzaniu sygnałów?

Funkcja autokorelacji sygnału EKG



Funkcja korelacji wzajemnej

Sygnały ciągłe:

$$R_{xy}(\tau) = \int_{-\infty}^{\infty} x(t)y(t + \tau)dt$$

Sygnały dyskretne:

$$R_{xy}(m) = \sum_{n=-\infty}^{n=\infty} x(n)y(n + m)$$

#Python

```
R=correlate(x,y,mode='full')
```


Pamiętaj o usunięciu składowej stałej sygnałów!

Funkcja korelacji wzajemnej - ćwiczenie

Ćwiczenie komputerowe: Detekcja zespołu QRS za pomocą wzorca QRS


1. Załaduj zadany sygnał EKG ('ecg_mit.mat').
2. Wyznacz wzorzec zespołu QRS. Zastosuj ten wzorzec do detekcji zespołów QRS w sygnale EKG.
3. Zachowaj otrzymane wyniki do porównania z innymi metodami detekcji zespołu QRS w sygnale EKG.

Funkcja korelacji wzajemnej




Funkcja korelacji wzajemnej

```
kor=xcorr(ECGsignal,QRSpattern)
```




Funkcja korelacji wzajemnej

```
kor=xcorr(ECGsignal,QRSpattern);
```



Funkcja korelacji wzajemnej

Wyznaczanie opóźnienia w sygnale radarowym:



Gęstość widmowa mocy sygnału losowego (ang. *power spectral density* - *PSD*)


- **Funkcja autokorelacji** sygnału losowego jest przebiegiem **deterministycznym** zatem, można wyznaczyć widmo Fouriera tego przebiegu i badać rozkład mocy sygnału w dziedzinie częstotliwości

$$FT\{R_{xx}(\tau)\} = X(j\omega)X^*(j\omega) = |X(j\omega)|^2$$


Ćwiczenie komputerowe: Wyznacz PSD sygnału EKG przez wyznaczenie kwadratu widma a następnie zastosuj funkcję 'psd'. Porównaj otrzymane wyniki.

Power Spectral Density - PSD

FFT



PSD



Współczynnik korelacji

Podobieństwo dwóch sygnałów można badać za pomocą współczynnika korelacji:

$$r_{xy} = \frac{\sigma_{xy}}{\sqrt{\sigma_x \sigma_y}} = \frac{\sum_{n=1}^N [x(n) - \bar{x}][y(n) - \bar{y}]}{\sqrt{\sum_{n=1}^N [x(n) - \bar{x}]^2 \sum_{n=1}^N [y(n) - \bar{y}]^2}}$$

kowariancja

$$-1 \leq r_{xy} \leq 1$$

#Python


corrcoef?

Współczynnik korelacji - przykład

Wyznacz współczynnik korelacji pomiędzy danymi a i b :

$$a = [1, 2, 3]$$

$$b = [-3, 4, 2]$$



$$r_{xy} \cong 0.6934$$

$$r_{xy} = \frac{\sum_{n=1}^N [x(n) - \bar{x}][y(n) - \bar{y}]}{\sqrt{\sum_{n=1}^N [x(n) - \bar{x}]^2 \sum_{n=1}^N [y(n) - \bar{y}]^2}}$$

Współczynnik korelacji

Ćwiczenie: Utwórz trzy wektory:

1. Wektor x_1 którego elementami jest wzrost osób w grupie wyrażony w metrach
2. Wektor x_2 którego elementami jest waga osób wg porządku z wektora x_1 (nie oszukiwać!)
3. Wektor x_3 którego elementami jest rozmiar buta osób w grupie

Wyznacz: współczynniki korelacji pomiędzy tymi wektorami i wskaż która para wektorów jest „najbardziej podobna”

Rozkłady zmiennych losowych ciągłych

**Rozkład równomierny
(jednostajny):**

$$p(x) = \begin{cases} \frac{1}{x_1 - x_0} & \text{dla } x_0 \leq x \leq x_1 \\ 0 & \text{dla innych } x \end{cases}$$


Rozkład Laplace'a:

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


**Rozkład normalny
(Gausa):**

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


Rozkłady zmiennych losowych



Szum o rozkładzie Gaussa (biały)




```
#Python  
sigma=1  
x=sigma*random.randn(1000)  
bins=linspace(-5,5,50)  
hist(x,bins, normed='True')
```




$x = 0, \sigma = 1$

Szum o rozkładzie równomiernym




```
#Python  
range=1  
y=range*random.rand(1000)  
bins=linspace(-1,1.5,50)  
hist(y,bins, normed='True')
```



$x = 0.5 !$

Proces Markowa

$$p[x(n)/x(n-1), x(n-2), \dots, x(1)] = p[x(n)/x(n-1)]$$



Czy ciąg $\{RR_1, RR_2, \dots, RR_n, \dots\}$ jest procesem Markowa?

Rozkłady punktowe - rozkład Poissona

Rozkład Poissona ma zastosowanie w obserwacji niezależnych zjawisk o małym prawdopodobieństwie sukcesu (np. zjawiska rozpadu promieniotwórczego).


Prawdopodobieństwo zaobserwowania j zdarzeń w zadanym przedziale czasu Δt :

$$p[Z(\Delta t) = j] = \frac{(\lambda \Delta t)^j}{j!} e^{-\lambda \Delta t}, \quad \lambda > 0 \quad \Rightarrow \quad \begin{aligned} E(Z) &= \lambda \\ D^2(Z) &= \lambda \end{aligned}$$

gdzie λ oznacza średnią liczbę zdarzeń występujących w czasie Δt .


Zastosowanie: w modelowaniu interwałów R-R sygnału EKG, sygnału EMG, serii impulsów wytwarzanych w komórkach neuronowych, kontroli jakości,

Rozkład Poissona



Proces Poissona opisuje tzw. procesy bez pamięci, w których liczba bieżących zdarzeń w jednostce czasu nie zależy od ich liczby w przeszłości

Przykład procesu Poissona (Heart Rate Variability – HRV)



Zagadnienie regresji liniowej

Rozpatrzmy przypadek regresji liniowej:

$$y = \alpha_0 + \alpha_1 x + \varepsilon$$

gdzie:


x - zmienna niezależna,

y - zmienna zależna,

ε - zakłócenia (np. błąd pomiaru),

α_0, α_1 - współczynniki regresji.

Regresja liniowa



Estymacja liniowej funkcji regresji

Zadanie regresji:

Założmy, że mamy P obserwacji $(x_1, y_1), (x_2, y_2), \dots, (x_P, y_P)$, poszukujemy współczynników a_0, a_1 , dla których uzyskamy najdokładniejszy opis zależności pomiędzy zmiennymi x i y .

Rozwiązanie:

Estymaty współczynników można wyznaczyć na drodze poszukiwania minimum sumy kwadratów błędów:

$$\varepsilon_i = y_i - (\alpha_0 + \alpha_1 x) = y_i - \hat{y}_i$$

obserwacja

model regresji liniowej

Estymacja liniowej funkcji regresji

Suma kwadratów błędów (ang. summed squared error - SSE)

$$SSE = \sum_{i=1}^P \varepsilon_i^2 = \sum_{i=1}^P \left(y_i - (\hat{\alpha}_0 + \hat{\alpha}_1 x_i) \right)^2$$

zgodnie z ideą metody sumy najmniejszych kwadratów błędów zaproponowanej przez Gaussa w XIX wieku; poszukujemy minimum tego wyrażenia.

Estymacja liniowej funkcji regresji

Minimum znajdujemy wyznaczając pochodne cząstkowe względem obu współczynników i przyrównujemy je do zera:

$$\left\{ \begin{array}{l} \frac{\partial(SEE)}{\partial \hat{\alpha}_0} = \frac{\partial}{\partial \hat{\alpha}_0} \left(\sum_{i=1}^P (y_i - \hat{\alpha}_0 - \hat{\alpha}_1 x_i)^2 \right) = 0 \\ \frac{\partial(SEE)}{\partial \hat{\alpha}_1} = \frac{\partial}{\partial \hat{\alpha}_1} \left(\sum_{i=1}^P (y_i - \hat{\alpha}_0 - \hat{\alpha}_1 x_i)^2 \right) = 0 \end{array} \right\}$$


tzw. układ normalny
równań

Estymacja liniowej funkcji regresji

Układ normalny równań posiada rozwiązanie:

$$\left\{ \begin{array}{l} \hat{\alpha}_0 = y_{\acute{s}r} - \hat{\alpha}_1 x_{\acute{s}r} \\ \hat{\alpha}_1 = \frac{\sum_{i=1}^P (x_i - x_{\acute{s}r})(y_i - y_{\acute{s}r})}{\sum_{i=1}^P (x_i - x_{\acute{s}r})^2} \end{array} \right.$$

Estymacja liniowej funkcji regresji



Source: Wikipedia

Estymacja liniowej funkcji regresji

Regresja wyższych rzędów:

$$y_i = \alpha_0 + \alpha_1 x_{i1} + \alpha_1 x_{i1} + \dots + \alpha_N x_{iN}, \quad i = 1, \dots, P$$

tj.

$$y_i = \alpha_0 + \sum_{j=1}^N \alpha_j x_{ij}, \quad i = 1, \dots, P$$

Podobnie jak dla regresji pierwszego rzędu, poszukujemy współczynników przez przyrównanie do zera pochodnych cząstkowych:

$$\frac{\partial(SEE)}{\partial \hat{\alpha}_j} = 0, \quad j = 0, \dots, N$$

i otrzymujemy $N+1$ równań z $N+1$ niewiadomymi.

Inne modele regresji

Regresja wielomianowa:

$$y_i = \alpha_0 + \alpha_1 x_{i1}^1 + \alpha_1 x_{i2}^2 + \dots + \alpha_N x_{iN}^N, \quad i = 1, \dots, P$$

Przykłady regresji nieliniowej:

$$y_i = \alpha_0 e^{\alpha_1 x_i}$$

$$y_i = \alpha_0 \alpha_1^{x_i}$$

$$y_i = \frac{\alpha_0}{1 + \alpha_1 e^{x_i}}$$

Rekonstrukcja trajektorii układu dynamicznego

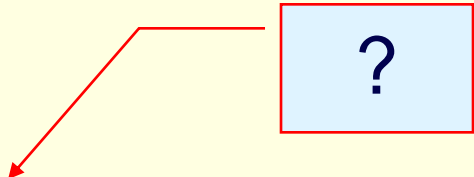
Takens (1981) udowodnił, że można odtwarzać własności trajektorii układu dynamicznego na podstawie próbek jednowymiarowego zapisu aktywności badanego układu:

$$\mathbf{y}(k) = [y(k), y(k - \Delta t), \dots, y(k - (D - 1)\Delta t)]^T$$

dla odpowiednio dużego wymiaru D wektora $\mathbf{y}(k)$ (ang. *time delay embedding*)


Rekonstrukcja trajektorii układu dynamicznego

Praktyczne znaczenie tw. Takensa dla badania układów dynamicznych to dowód o istnieniu zależności:



$$y((k + 1)\Delta t) = F(y(k))$$

na podstawie, której można wyznaczać prognozę próbki $y(k+1)\Delta t$ sygnału odwzorowującego zachowanie badanego układu.

Rekonstrukcja trajektorii dla rytmu serca



Normalny rytm serca



Fibrylacja komór

Δt – pierwsze zero funkcji autokorelacji ciągu $y(k)$

Chaos deterministyczny


Rozważmy prosty układ dynamiczny:

$$x(n+1) = ax(n)(1 - x(n))$$

Symulujący zmianę liczności x populacji w ograniczonym środowisku. Liczność ta jest znormalizowana do zakresu $\langle 0, 1 \rangle$, zatem parametr a przyjmuje wartości z zakresu $\langle 0, 4 \rangle$.

Jest to tzw. **równanie logistyczne**.


Chaos deterministyczny



tzw. odwzorowanie
kwadratowe

$$x(n+1) = 3.6x(n)(1-x(n))$$

Chaos deterministyczny



Chaos deterministyczny

Właściwości procesów charakteryzujących się deterministycznym ruchem chaotycznym:

- mogą być generowane przez proste układy dynamiczne*,
- dynamika ma „nieprzewidywalny” charakter losowy (tzw. **dziwne atraktory** – tj. orbity ograniczone, rozbieżne i nieokresowe) → demo Matlab
- dynamika silnie zależna od warunków początkowych („**efekt motyla**”)

**) R, May: „ ... lepiej by nam się żyło gdyby uwzględniano fakt, że proste układy dynamiczne niekoniecznie prowadzą do prostej ewolucji dynamicznej.”*

Analiza sygnałów losowych

1. Sygnały losowe a sygnały deterministyczne
2. Momenty statystyczne
3. Funkcja autokorelacji
4. Funkcja korelacji wzajemnej
5. Współczynnik korelacji
6. Gęstość widmowa mocy
7. Rozkłady statystyczne
8. Dynamika systemów