

Prawdopodobieństwo i statystyka

Wykład XIII:
Prognoza. Warunkowa wartość oczekiwana

26 stycznia 2015

Zagadnienie prognozowania

- Przypuśćmy, że mamy dany ciąg liczb x_1, x_2, \dots, x_n , stanowiących wyniki pomiaru pewnej zmiennej w czasie wielkości x , w chwilach $t_1 < t_2 < \dots < t_n$. Inaczej mówiąc, mamy dany „szereg czasowy”.
- Zagadnienie prognozowania: Niech $T > t_n$. Jaką wartość przyjmie badana wielkość w chwili T ?
- Jeżeli x jest funkcją tylko czasu t , tzn. $x_k = f(t_k)$, $k = 1, 2, \dots, t_n$, możemy próbować odgadnąć postać funkcji f , np.
 - znajdując współczynniki wielomianu interpolacyjnego,
 - lub amplitudę, częstość i przesunięcie sygnału sinusoidalnego,
 - lub parametry przekształcenia S , którego kolejne iteracje $S(t_0), S^2(t_0), \dots, S_n(t_0)$ dają nam kolejne wartości x_1, x_2, \dots, x_n .
- To jest jednak rzadka sytuacja. Na ogół musimy zakładać, że liczby x_1, x_2, \dots, x_n są wartościami ciągu zmiennych losowych.

Pojęcie prognozy (predykcji)

Postawienie zagadnienia: znamy rozkład łączny zmiennych losowych $X_1, X_2, \dots, X_n, Y_1, Y_2, \dots, Y_m$, gdzie X_1, X_2, \dots, X_n reprezentują „przeszłość”, a Y_1, Y_2, \dots, Y_m - „przyszłość”. Na podstawie przeszłości chcemy ocenić **wartości przyszłe w postaci funkcji $f(X_1, X_2, \dots, X_n)$** . Jako „miarę jakości” prognozy przyjmujemy **„błąd średniokwadratowy”**

$$\begin{aligned} E\|(Y_1, Y_2, \dots, Y_m)^T - f(X_1, X_2, \dots, X_n)\|^2 \\ = \sum_{i=1}^m E(Y_i - f_i(X_1, X_2, \dots, X_n))^2. \end{aligned}$$

Pokażemy, że błąd średniokwadratowy jest minimalizowany przez

$$f_i(X_1, X_2, \dots, X_n) = E(Y_i | (X_1, X_2, \dots, X_n)), i = 1, 2, \dots, m.$$

Rozkłady warunkowe

Niech \vec{Y} i \vec{Z} będą wektorami losowymi o wartościach w \mathbb{R}^m i \mathbb{R}^n , określonymi na tej samej przestrzeni probabilistycznej (Ω, \mathcal{F}, P) . Jeżeli $P(\vec{Z} = \vec{z}) > 0$, to **rozkładem warunkowym wektora \vec{Y} gdy $\vec{Z} = \vec{z}$** nazywamy prawdopodobieństwo

$$\mathbb{R}^m \supset A \mapsto P_{\vec{Y}|\vec{Z}=\vec{z}}(A) = P(\vec{Y} \in A | \vec{Z} = \vec{z}) \left(= \frac{P(\vec{Y} \in A, \vec{Z} = \vec{z})}{P(\vec{Z} = \vec{z})} \right).$$

Pytanie: jak określić rozkład warunkowy w ogólnym przypadku?
Jeżeli $P_{(Y,Z)}$ jest absolutnie ciągły z gęstością $p_{Y,Z}(y,z)$, to można określić **gęstość** rozkładu $P_{Y|Z=z}$ za pomocą wzoru

$$p_{Y|Z=z}(y) = \begin{cases} \frac{p_{Y,Z}(y,z)}{\int_{-\infty}^{+\infty} p_{Y,Z}(u,z) du}, & \text{jeśli } \int p_{Y,Z}(u,z) du > 0 \\ \mathbb{1}_{[0,1]}(y), & \text{jeśli } \int p_{Y,Z}(u,z) du = 0 \end{cases}.$$

Definicja i własności warunkowej wartości oczekiwanej

Mając dany rozkład warunkowy $P_{\vec{Y}|\vec{Z}=\vec{z}}(\cdot)$ określamy

$$E(\vec{Y}|\vec{Z} = \vec{z}) := \int \vec{y} P_{\vec{Y}|\vec{Z}=\vec{z}}(d\vec{y}),$$
$$E(\vec{Y}|\vec{Z}) := E(\vec{Y}|\vec{Z} = (\cdot)) \circ \vec{Z}.$$

- Jeżeli $E|U| < +\infty$ i $E|V| < +\infty$, to

$$E(\alpha U + \beta V|\vec{Z}) = \alpha E(U|\vec{Z}) + \beta E(V|\vec{Z}).$$

- Jeżeli $E|Y| < +\infty$ i $|h(\vec{Z})| \leq C$, to

$$E(h(\vec{Z}) \cdot Y|\vec{Z}) = h(\vec{Z}) \cdot E(Y|\vec{Z}).$$

Warunkowa wartość oczekiwana jako rzut ortogonalny

- Jeżeli $EY^2 < +\infty$ i $E(h(\vec{Z}))^2 < +\infty$, to

$$E(h(\vec{Z}) \cdot Y | \vec{Z}) = h(\vec{Z}) \cdot E(Y | \vec{Z}).$$

- Jeżeli $EY^2 < \infty$, to

$$\text{Var}(Y) = E(Y - E(Y | \vec{Z}))^2 + \text{Var}(E(Y | \vec{Z})).$$

Twierdzenie (Warunkowa wartość oczekiwana jako minimalizator)

Niech $EY^2 < +\infty$ i \vec{Z} przyjmuje wartości w \mathbb{R}^n . Wówczas $E(Y | \vec{Z})$ jest jedynym minimalizatorem funkcjonau

$$h \mapsto E(Y - h(\vec{Z}))^2,$$

gdy h przebiega zbiór $\{h : \mathbb{R}^n \rightarrow \mathbb{R}^1 ; E(h(\vec{Z}))^2 < +\infty\}$.

Warunkowa wartość oczekiwana jako rzut ortogonalny - cd.

Uwaga: w terminach przestrzeni Hilberta $L^2(\Omega, \mathcal{F}, P)$ warunkowa wartość oczekiwana jest **rzutem ortogonalnym na podprzestrzeń** funkcji postaci $\{h(\vec{Z})\}$, czyli funkcji $\sigma(\vec{Z})$ -mierzalnych. W tym kontekście (niemal) oczywiste są następujące fakty:

- Jeżeli $E|Y| < +\infty$ i $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$, to

$$E\left(E(Y|\vec{Z})|g(\vec{Z})\right) = E(Y|g(\vec{Z})).$$

- Jeżeli \vec{Z} jest funkcją stałą, to $E(Y|\vec{Z}) = EY$.
- Co by było, gdybyśmy minimalizowali $E|Y - h(\vec{Z})|$?

Prognoza liniowa

W zagadnieniu prognozy zmiennych Y_1, Y_2, \dots, Y_m , na podstawie X_1, X_2, \dots, X_n poszukujemy najlepszego przybliżenia zmiennych Y_i w postaci $f_i(X_1, X_2, \dots, X_n)$, gdzie f_i spełnia tylko ogólne warunki całkowalności, należy więc do bardzo szerokiej klasy funkcji.

Z **prognozą liniową** mamy do czynienia, gdy poszukujemy najlepszego przybliżenia w klasie funkcji

$$f_i(X_1, X_2, \dots, X_n) = \sum_{j=1}^n \alpha_{i,j} X_j, \quad i = 1, 2, \dots, m.$$

To na ogół dużo łatwiejsze zadanie!

Uwaga: Istnieje ważna klasa szeregów czasowych, dla których oba pojęcia prognozy pokrywają się: są to **procesy gaussowskie**.

Procesy gaussowskie

Definicja zmiennych losowych gaussowskich

Mówimy, że zmienne losowe X_1, X_2, \dots, X_n są **gaussowskie**, jeśli ich dowolna kombinacja liniowa $\alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_n X_n$ ma **jednowymiarowy rozkład normalny**, tzn.

$$\alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_n X_n \sim \mathcal{N}(m_{\vec{\alpha}}, \sigma_{\vec{\alpha}}^2),$$

gdzie $\vec{\alpha} = (\alpha_1, \alpha_2, \dots, \alpha_n)^T$.

Dopuszczamy przypadek $\sigma_{\vec{\alpha}}^2 = 0$. Z definicji $\mathcal{N}(m, 0) = \delta_m$.

Rodziny gaussowskie

Rodzinę zmiennych losowych $\{X_i\}_{i \in \mathbb{I}}$ nazywamy gaussowską, jeśli dla każdego skończonego podzbioru $\{i_1, i_2, \dots, i_n\} \subset \mathbb{I}$ zmienne $X_{i_1}, X_{i_2}, \dots, X_{i_n}$ są gaussowskie.

Procesy gaussowskie - cd.

Biorąc $\vec{\alpha} = (0, \dots, 0, 1, 0, \dots, 0)^T$, otrzymujemy rozkład normalny dla składowych $X_k \sim \mathcal{N}(m_k, \sigma_k^2)$. W ogólności,

$$m_{\vec{\alpha}} = E(\alpha_1 X_1 + \alpha_2 X_2 + \dots + \alpha_n X_n) = E\langle \vec{\alpha}, \vec{X} \rangle = \langle \vec{\alpha}, E\vec{X} \rangle.$$

Podobnie

$$\sigma_{\vec{\alpha}}^2 = \text{Var}(\langle \vec{\alpha}, \vec{X} \rangle) = \langle \vec{\alpha}, \text{Cov}(\vec{X}) \vec{\alpha} \rangle.$$

Twierdzenie (Transformacja liniowa zmiennych gaussowskich)

Jeżeli wektor losowy $\vec{X} = (X_1, X_2, \dots, X_n)^T$ ma składowe gaussowskie, przy czym $E\vec{X} = \vec{m}$ i $\text{Cov}(X) = \Sigma$ i jeżeli $A: \mathbb{R}^n \rightarrow \mathbb{R}^m$ jest odwzorowaniem liniowym, to składowe wektora $A(\vec{X})$ też są gaussowskie, przy czym

$$EA(\vec{X}) = A(\vec{m}), \text{Cov}(A(\vec{X})) = A\Sigma A^T.$$

Konstrukcja zmiennych gaussowskich

Twierdzenie (Konstrukcja zmiennych gaussowskich)

Jeżeli $\vec{m} \in \mathbb{R}^n$ i Σ jest macierzą $n \times n$, symetryczną i nieujemnie określoną, to istnieje wektor losowy \vec{X} o **składowych gaussowskich**, który spełnia związki

$$E\vec{X} = \vec{m}, \quad \text{Cov}(\vec{X}) = \Sigma.$$

Twierdzenie (Charakterystyka rozkładu łącznego zmiennych gaussowskich)

Rozkład łączny zmiennych losowych gaussowskich (X_1, X_2, \dots, X_n) (nazywany n -wymiarowym rozkładem normalnym) jest w pełni określony przez swoją wartość oczekiwaną \vec{m} i macierz kowariancji Σ . Piszemy $\vec{X} \sim \mathcal{N}(\vec{m}, \Sigma)$.

Niezależność zmiennych gaussowskich

Twierdzenie (Absolutna ciągłość rozkładu normalnego)

Rozkład normalny jest absolutnie ciągły dokładnie wtedy, gdy macierz Σ jest nieosobliwa ($\det(\Sigma) \neq 0$). W takim przypadku gęstość zadana jest wzorem:

$$p_{\vec{m}, \Sigma}(\vec{x}) = \frac{1}{(\sqrt{2\pi})^d} \frac{1}{\sqrt{\det \Sigma}} \exp\left(-\frac{1}{2} \langle \vec{x} - \vec{m}, \Sigma^{-1} (\vec{x} - \vec{m}) \rangle\right).$$

Twierdzenie (Niezależność zmiennych gaussowskich)

Zmienne gaussowskie X_1, X_2, \dots, X_n są niezależne dokładnie wtedy, gdy są nieskorelowane:

$$\text{cov}(X_i, X_j) = 0, \quad i, j = 1, 2, \dots, n, \quad i \neq j.$$

Prognoza dla zmiennych gaussowskich

Twierdzenie (Prognoza dla zmiennych gaussowskich)

Jeżeli zmienne $X_1, X_2, \dots, X_n, Y_1, Y_2, \dots, Y_m$ są gaussowskie, to prognoza liniowa Y_1, Y_2, \dots, Y_m na podstawie X_1, X_2, \dots, X_n pokrywa się z pełną prognozą (tzn. przybliżeniem Y_1, Y_2, \dots, Y_m za pomocą zmiennych postaci $h(X_1, X_2, \dots, X_n)$).

Uwaga: Jeżeli w schemacie prognozy

$$X_1, X_2, \dots, X_n, Y_1, Y_2, \dots, Y_m$$

zmienne są gaussowskie, to prognoza (liniowa) Y_1, Y_2, \dots, Y_m na podstawie X_1, X_2, \dots, X_n jest również wektorem o składowych gaussowskich. **Jak określić wektor prognozy?**