

WYKŁAD 1, 04.10.2010

1. **Lemat o minimaxie** -  $\sup_{\pi} \inf_{\delta} L(\pi, \delta) \leq \inf_{\delta} \sup_{\pi} L(\pi, \delta)$ , gdzie  $L : \Pi \times \Delta \rightarrow \mathbb{R}$ .
2. **Gra ma wartość**, jeśli  $\sup_{\pi} \inf_{\delta} L(\pi, \delta) = \inf_{\delta} \sup_{\pi} L(\pi, \delta)$ .
3.  $\delta^*$  jest **minimaxowa**, jeśli  $\sup_{\pi} L(\pi, \delta^*) = \inf_{\delta} \sup_{\pi} L(\pi, \delta)$ .
4.  $\pi^*$  jest **maximinowe**, jeśli  $\inf_{\delta} L(\pi^*, \delta) = \sup_{\pi} \inf_{\delta} L(\pi, \delta)$ .
5.  $\delta^*$  jest  **$\pi^*$ -optymalna** ( $\pi^*$ -bayesowska), jeśli  $L(\pi^*, \delta^*) = \inf_{\delta} L(\pi^*, \delta)$ .
6.  $(\pi^*, \delta^*)$  jest **siodłem** (punktem siodłowym, in. punktem równowagi Nasha) gry, jeśli  $\forall \pi, \delta L(\pi, \delta^*) \leq L(\pi^*, \delta^*) \leq L(\pi^*, \delta)$ , in.  $\sup_{\pi} L(\pi, \delta^*) = L(\pi^*, \delta^*) = \inf_{\delta} L(\pi^*, \delta)$ .
7. **Tw. o siodle** - Ustalmy  $\pi^*, \delta^*$ . N.w.s.r.:
  - (a)  $\sup_{\pi} L(\pi, \delta^*) \leq \inf_{\delta} L(\pi^*, \delta)$
  - (b)  $(\pi^*, \delta^*)$  jest siodłem
  - (c)  $(\pi^*, \delta^*)$  jest siodłem i  $\delta^*$  jest  $\pi^*$ -optymalne
  - (d)  $\pi^*$  jest maximinowe,  $\delta^*$  jest minimaxowa i gra ma wartość
  - (e)  $\pi^*$  jest maximinowe,  $\delta^*$  jest minimaxowa i gra ma wartość  $= L(\pi^*, \delta^*)$
8. **Wniosek** - Jeżeli  $\delta^*$  jest t. że ma stałe ryzyko tzn.  $\forall \pi_1, \pi_2 L(\pi_1, \delta^*) = L(\pi_2, \delta^*)$  oraz  $\exists \pi^*$  t. że  $\delta^*$  jest  $\pi^*$ -optymalna, to  $(\pi^*, \delta^*)$  jest siodłem.
9.  $H$  - zb. czystych strategii natury ( $\theta \in H$  - nieznan parameter rozkładu prawdopodobieństwa),  $A$  - zb. czystych strategii statystyka ( $a \in A$  - akcje statystyka). Zrandomizowane strategie natury (zbiór  $\Pi = H^*$ ); zrandomizowane strategie statystyka ( $\Delta = A^*$ ); funkcja straty z przestrzeni zrandomizowanych.
10. **Def.**  $L(\pi, \delta) = E_{\pi \times \delta} L(\theta, a)$ .
11. **Twierdzenie von Neumanna** - Jeżeli mamy grę  $(H, A, L)$  ze skończonymi zb.  $H$  i  $A$ , to gra  $(H^*, A^*, L)$  ma punkt siodłowy.

12. **Oznaczenia:**  $H$  - zbiór czystych strategii natury,  $A$  - zbiór akcji statystyka,  $X$  - przestrzeń obserwacji (polska),  $\{P_\theta : \theta \in H\}$  - rozkłady prawdopodobieństwa na  $X$ ,  $X \sim P_\theta$ ,  $L : H \times A \rightarrow \mathbb{R}$  - funkcja straty,  $\Pi = \{\pi : \text{rozkład prawdopodobieństwa na } H\} = H^*$ ,  $D$  - zbiór reguł decyzyjnych,  $D^*$  - rodzina rozkładów prawdopodobieństwa na zbiorze wszystkich reguł decyzyjnych (niezrandomizowanych).
13. **Reguła decyzyjna** (czysta strategia statystyka, np. estymator, test)  $d : x \in X \rightarrow d(x) \in A$ .
14. **Ryzyko:**  $R(\theta, d) = E_\theta L(\theta, d(X)) = \int_X L(\theta, d(x)) P_\theta(dx)$ .
15. Gra  $(H, D, R)$  zamiast  $(H, A, L)$ , gdzie  $D = \{d : X \rightarrow A \text{ mierzalne, takie że ryzyko } R(\theta, d) \text{ jest dobrze zdefiniowane}\}$ ;  $R : H \times D \rightarrow \mathbb{R}$ .
16. **Ryzyko bayesowskie**  $f(\pi, d) = \int_H R(\theta, d) \pi(d\theta)$ .
17. Gra: niezrandomizowana  $(H, D, R)$ , gra zrandomizowana  $(H^*, D^*, R^*)$ ,  $d^*$  - zrandomizowana reguła decyzyjna.
18.  $R^*(\pi, d^*) = \int_D r(\pi, d) d^*(dd)$
19.  $\delta : X \rightarrow A^*$  - zbiór rozkładów prawdopodobieństwa na  $A$ ,  $x \in X \rightarrow \delta(x)$  - miara probabilistyczna na zbiorze akcji  $A$ .  
 $r(\pi, \delta) = \int_X \int_X \int_A L(\theta, a) \delta(x, da) P_\theta(dx) \pi(d\theta)$ .
20. **Tw. Walda-Wolfowitza** Dla każdej reguły zrandomizowanej  $d^* \in D^*$  istnieje reguła behawiorystyczna  $\delta \in \tilde{D}$  taka że  $R^*(\pi, d^*) = r(\pi, \delta)$ .
21. **Zbiór ryzyka - dwie hipotezy proste**  $\{R(\cdot, d), d \in D\} = \{(\alpha(d), \beta(d)), d \in D\}$ , gdzie  $\alpha(d) = R(0, d) = \int_{\{x:d(x)=1\}} p_0(x) dx$  - błąd I rodzaju,  $\beta(d) = R(1, d) = \int_{\{x:d(x)=0\}} p_1(x) dx$  - błąd drugiego rodzaju. Albo też:  $\alpha(\delta) = \int_X \delta(x) p_0(x) dx$ ,  $\beta(\delta) = \int_X (1 - \delta(x)) p_1(x) dx$ .

22. **Oznaczenia c.d.:**  $d$  - przestrzeń niezrandomizowanych reguł,  $\Delta$  - przestrzeń zrandomizowanych (behawiorystycznych) reguł decyzyjnych  $x \in X \rightarrow \delta(x)$  - miara probabilistyczna na  $A$ .  
 $R : H \times \Delta \rightarrow \mathbb{R}$ ,  $R(\theta, \delta) = \int_X \int_A L(\theta, a) \delta(x, da) P_\theta(dx)$ .
23. **Def.**  $\delta_1 \preceq \delta_2 \Leftrightarrow \forall \theta R(\theta, \delta_1) \leq R(\theta, \delta_2)$ ,  $\delta_1 \prec \delta_2 \Leftrightarrow \delta_1 \preceq \delta_2$  i  $\exists \theta R(\theta, \delta_1) < R(\theta, \delta_2)$ ,  $\delta_1 \sim \delta_2 \Leftrightarrow \delta_1 \preceq \delta_2$  i  $\delta_2 \preceq \delta_1$ .
24. **Def.**  $C \subseteq \Delta$ , mówimy, że  $C$  jest klasą **zupelną**, jeśli  $\forall \delta \notin C \exists \delta' \in C$  taka że  $\delta' \prec \delta$ .  $C$  jest klasą **istotnie zupelną**, jeśli  $\forall \delta \exists \delta' \in C$  taka że  $\delta' \preceq \delta$ .
25. **Def.** Reguła  $\delta$  jest **dopuszczalna**, jeśli nie istnieje reguła ściśle lepsza od niej tzn. nie istnieją  $\delta'$  taka że  $\delta' \prec \delta$ . Oznaczenie:  $Adm$  - rodzina reguł dopuszczalnych.
26. **Lemat** jeśli  $C$  jest zupelna, to  $Adm \subseteq C$ .
27. **Lemat** Jeśli  $C$  jest istotnie zupelna,  $\delta \in Adm \setminus C$ , to  $\exists \delta' \in C$ ,  $\delta' \sim \delta$ .
28. **Def. Zbiór ryzyk:**  $R = \{R(\delta) : \delta \in \Delta\} \subseteq \mathbb{R}^k$ .
29. **Stw.**  $R$  jest wypukły, domknięty i ograniczony.
30. **Def. Reguła  $\delta$  jest bayesowska** względem rozkładu a priori  $\pi$  na  $H$ , jeśli  $r(\pi, \delta) = \inf_{\delta} R(\pi, \delta)$ .
31. **Stw.** Jeśli reguła  $\delta$  jest bayesowska względem  $\pi$ ,  $(\pi_i > 0 \forall i)$ , to  $\delta \in Adm$ .
32. **Stw.** Jeżeli reguła  $\delta$  jest dopuszczalna, a to jest bayesowska względem pewnego rozkładu a priori  $\pi$ .
33. **Def.** Jeżeli  $Z \subset \mathbb{R}^k$  jest wypukły, domknięty, ograniczony, to dolny brzeg tego zbioru określamy  $\lambda(Z) := \{\alpha : Z \cap Q_\alpha = \{a\}\}$ .
34. **Uwaga**  $\lambda(Z) \subseteq \delta(Z)$ .
35. **Lemat** Każdy domknięty, wypukły, ograniczony zbiór  $Z$  ma  $\lambda(Z) \neq \emptyset$ .

WYKŁAD 4, 25.10.2010

36. **Tw. Rao-Blackwella** Mamy zbiór  $A \in \mathbb{R}^d$ .  $L(\theta, a)$  - wypukła funkcja a dla każdego  $\theta \in \Theta$ . Niech  $T$  będzie statystyką dosteczną dla rodziny  $P_\theta$ .  $d \in D$  (niezrandomizowana decyzja)  $\Rightarrow d_0(x) = E(d(X)|T = t)$  jest nie gorsza niż  $d$ .
37. **Def. Statystyka dostateczna** -  $T : X \rightarrow \mathbb{R}^d$ .  $\forall A \in B(X) P_\theta(X \in A|T = t)$  - nie zależy od  $\theta \Leftrightarrow f_\theta(x) = g_\theta(T(X))h(X)$  - kryterium faktoryzacji,  $g_\theta$  - zależy od  $\theta$  przez statystykę.
38. **Twierdzenie** Mamy  $A = (-\infty, \infty)$ ,  $\forall \theta \in \Theta L(\theta, a)$  jest wypukła.  $\exists \theta_0$  taka że  $L(\theta_0, a) \rightarrow \infty$ ,  $|a| \rightarrow \infty$ , to klasa reguł niezrandomizowanych jest istotnie zupełna dla  $(\Theta, D, R)$ .
39. **Uwaga**  $L(\theta_0, a) \geq c|a| + b \forall a \in A$ .
40. **Twierdzenie o rozdzielaniu zbiorów wypukłych** Jeśli  $U, W \in \mathbb{R}^d$  są wypukłe i  $intU \cap intW = \emptyset$ , to  $\exists \bar{\pi} \in \mathbb{R}^d$ ,  $\pi \neq 0$  takie że  $\pi(u) \leq c \leq \pi(w) \forall u \in U \forall w \in W \{u : \pi(u) = c\}$ .

WYKŁAD 5, 08.11.2010

41. **Rodziny wykładnicze**  $f_\theta(x) = \exp\{\langle \phi(\theta), T(x) \rangle - A(\theta)\}h(x)$ , gdzie  $\theta \in \Theta \subseteq \mathbb{R}^k$ .  
**Naturalna parametryzacja** rodziny wykładniczej.:  $\eta = \phi(\theta)$ ,  $f_\eta(x) = \exp\{\langle \eta, T(x) \rangle - A(\eta)\}h(x)$ .
42. **Przykład**  
 Weźmy  $X_1, \dots, X_n$  obserwacji,  $x|\theta \sim f_\theta(x)$ ,  $f_\theta(x) = \exp\{\langle \theta, T(x) \rangle - A(\theta)\}h(x)$  - **rozkład obserwacji**  
 $\theta|\mu, \nu$ ,  $\nu \in \mathbb{R}^k$ ,  $\nu \in \mathbb{R}$  - k+1 parametrów,  $\Pi(\theta) = \exp\{\langle \theta, \mu \rangle - \nu A(\theta)\}$  - **rozkład a priori**  
 $f_\theta(x_1, \dots, x_n) \sim \exp\{\langle \theta, \sum T(x_i) \rangle - nA(\theta)\}$  - **rozkład łączny**  
 $\Pi(\theta|x, \mu, \nu) = f_\theta(x_1, \dots, x_n)\Pi(\theta|\mu, \nu) = \exp\{\langle \theta, \mu + \sum T(x_i) \rangle - (n + \nu)A(\theta)\}$  - **rozkład a posteriori**  
 Rozkłady a priori i a posteriori są **sprzężone**.
43. **Funkcje tworzące momenty**  $mT(x)^{(t)} = Ee^{\langle t, T(x) \rangle}$ .

WYKŁAD 6, 15.11.2010

44. Model hierarchiczny (bayesowski). Łańcuchy Markowa: algorytm Metropolis - Hastingsa, próbnik Gibbsa.

WYKŁAD 7, 22.11.2010

45. Gra w kodowanie.

46. **Podstawy statystyki bayesowskiej** - konstrukcja modelu bayesowskiego:

$X$  - przestrzeń obserwacji

$\{P_\theta : \theta \in \Theta\}$  - rodzina rozkładów prawdopodobieństwa na  $X$  (niewiele tracimy od razu posługując się gęstościami)

$\mu$  - miara na  $X$  (mamy  $\sigma$  ciało)

$f_\theta$  - gęstość  $P_\theta$  względem  $\mu$ ;  $P_\theta(A) = \int_A f_\theta(x)\mu(dx)$

$\Theta$  - przestrzeń parametrów  $\pi$  - rozkład prawdopodobieństwa na  $\Theta$

$\nu$  - miara na  $\Theta$

$\pi$  - gęstość  $\pi$  względem  $\nu$  (a priori).

47. **Def.**  $f(\theta, x) = (df)\pi(\theta)f_\theta(x)$  - łączna gęstość na  $\Theta \times X$  względem miary  $\nu \times \mu$ .

48.  $f(x|\theta) = \frac{f(\theta, x)}{\pi(\theta)} = f_\theta(x)$

Wzór Bayesa, rozkład a posteriori ( $\pi_x(\theta)$ ):  $f(\theta|x) = \frac{f(x|\theta) \cdot \pi(\theta)}{f(x)}$  - rozkład łączny w liczniku; gdzie  $f(x) = \int_\Theta f_\theta(x)\pi(\theta)\nu(d\theta)$ .

49. **Model statystyczny** - podanie rodziny rozkładów prawdopodobieństwa zależnych od  $\theta$ . **Model bayesowski** - rozkład łączny, dwuwymiarowy.

50.  $L(\theta, a)$  - argumenty: parametr i akcja, którą podejmujemy,  $L : \Theta \times A \rightarrow \mathbb{R}$ , gdzie  $A$  - zbiór akcji. **Reguła zrandomizowana**  $\delta : X \rightarrow A$ .

51. Reguła jest  $\pi^*$ -bayesowska, jeśli minimalizuje ryzyko bayesowskie, tzn. jeśli  $r(\pi, \delta_\pi) \inf_\delta r(\pi, \delta)$ .

52. **R - ryzyko niebayesowskie**

$$R(\theta, \delta) = E_\theta L(\theta, \delta(x)) = \int_X L(\theta, \delta(x))f_\theta(x)\mu(dx) = E[L(\theta, \delta(x))|\nu = \theta].$$

53. **Ryzyko bayesowskie**  $r(\pi, \delta) = EL(\nu, \delta(x)) = \int_\Theta R(\theta, \delta)\pi(\theta)\nu(d\theta) = \int_\Theta \int_X L(\theta, \delta(x))f_\theta(x)\mu(dx)\pi(\theta)\nu(d\theta) = (*)$ .

54. **Podstawowe tw. statystyki bayesowskiej** Jeżeli  $\forall x \exists a^* = \delta^*(x)$  taka że  $E[L(\nu, \delta^*(x))|X = x] = \inf_{a \in A} E[L(\delta, a)|X = x]$  to  $\delta^*$  jest regułą bayesowską.  $E[L(\nu, a)|X = x] = \int_\Theta L(\theta, a)\pi_x(\theta)d\theta$  - w zadaniach chcemy minimalizować tę całkę (po skorzystaniu z tw. Fubiniego mamy, że  $(*) = r(\pi, \delta) = \int_X \int_\Theta L(\theta, \delta(x))\pi_x(\theta)d\theta f(x)dx$ ).

55. **Optymalna reguła a priori**  $a^* = \operatorname{argmin} \int_\Theta L(\theta, a)\pi(\theta)d\theta$ .

56. **Teorio-decyzyjne podstawy analizy dyskryminacyjnej:** obserwujemy obiekt należący do jednej z podpopulacji  $1, \dots, k$  i mamy zdecydować, do której należy na podstawie obserwowanych cech  $X = (X_1, \dots, X_d)$ , np. diagnoza medyczna, bankowość, rozpoznawanie symboli.

57. Matematycznie:

$X$  - wektor losowy w  $\mathbb{R}^d$   $X$  ma w podpopulacji  $i$  rozkład  $f_i$  (gęstość)

$\pi_i$  - prawdopodobieństwo a priori, że obiekt należy do  $i$ -tej podpopulacji

$\pi_1 + \dots + \pi_k = 1$ . Zakładamy, że  $f_1, \dots, f_k$  i  $\pi_1, \dots, \pi_k$  - znane.

$\Theta = \{1, \dots, k\}$ ,  $\theta = i$ . Musimy wybrać, z którego rozkładu prawdopodobieństwa pochodzi obserwacja, z której podpopulacji:  $A = \Theta$  lub  $A = \Theta \cup \{0\}$  (0 - zawieszanie decyzji)

**Funkcja strat** - macierz  $L(i, j)$ ,  $i \in \Theta$ ,  $j \in A$ .

58. **Wzór Bayesa** (dyskretna wersja):  $\pi(i|x) = \frac{f_i(x)\pi_i}{f(x)}$ ,  $f(x) = \sum_{i=1}^k f_i(x)\pi_i$ .

59. **Reguła klasyfikacyjna**  $\delta : X \rightarrow A$ .

60. **Ryzyko bayesowskie**

$$r(\pi, \delta) = r(\delta) = EL(I, \delta(X)) = \sum_{i=1}^k \pi_i \int_X f_i(x) L(i, \delta(x)) dx.$$

61. **Reguła bayesowska**  $\delta^*$  - minimalizująca ryzyko bayesowskie.

62. **Ryzyko a posteriori**  $\sum_{i=1}^k \pi(i|x) L(i, j) \rightarrow \min j \in A$ .

63. **Wniosek (podstawowa reguła bayesowska)**

$$\delta^*(x) = \arg \min_j \sum_{i=1}^k \pi(i|x) L(i, j).$$

64. **Klasyczny przykład** (wielowymiarowe rozkłady normalne): lda ( $f_i = N(\mu_i, V)$ ), qda ( $f_i = N(\mu_i, V_i)$ ) - dwie podstawowe funkcje.

65. **Obszar decyzyjny**  $D_j = \{x : \delta^*(x) = j\}$ .

66. **Estymacja nieznanymi rozkładów w klasach**  $f_i$ .

67. **Modele liniowe** Predykcja:  $X = (X_1, \dots, X_n)$ ,  $Y$  - zmienna losowa. Szukamy  $Y = h(X) = c_0 + \sum_{i=1}^n c_i X_i$ .

68. **Def.**  $\hat{Y} = h(X)$  jest **najlepszym liniowym predyktorem Y (BLP(Y))**, jeśli:

- $h : \mathbb{R}^n \rightarrow \mathbb{R}$  jest funkcją liniową
- $E(Y - h(X))^2 \leq E(Y - g(X))^2, \forall g: \mathbb{R}^n \rightarrow \mathbb{R}$ , liniowa

69. **Twierdzenie**  $\hat{Y} = h(X) = c_0 + \sum_{i=1}^n c_i X_i$  jest BLP(Y), jeśli  $(c_0, c_1, \dots, c_n)$  spełniają układ równań:

$$\begin{cases} \sum_{i=1}^n Cov(X_i, X_k) = Cov(X_k, Y), & k = 1, \dots, n \\ c_0 = EY - \sum_{i=1}^n c_i EX_i. \end{cases}$$

70. **Def.**  $\hat{Y} = g(X)$  jest **nieobciążonym predyktorem Y**, jeśli  $E_m(Y - g(X)) = 0 \forall m$ .

71. **Def.**  $\hat{Y} = BLUP(Y)$  - **best linear unbiased predictor**, jeśli:

- $h(X)$  jest nieobciążony
- $h : \mathbb{R}^n \rightarrow \mathbb{R}$  jest funkcją liniową
- $E_m(Y - h(X))^2 \leq E_m(Y - g(X))^2, \forall g(X) = \tilde{Y}$  - nieobciążony, liniowy.

72. **Uwaga**  $Y \rightarrow m$ , to  $BLUP \rightarrow BLUE$ .

73. **Def.**  $\hat{m} = g(X)$  nazywamy **nieobciążonym estymatorem m**, jeżeli  $E_m g(X) = m$ .

74. **Def.**  $\hat{m} = BLUE(m)$ , jeśli:

- jest liniową funkcją
- jest nieobciążony
- $Var_m h(X) \leq Var_m g(X) \forall g(X) = \tilde{m}$  - nieobciążony, liniowy.

75. Od tej pory przyjmujemy założenia:

- (i)  $E_m X_i = E_m Y = m$
- (ii)  $Cov_m(X_i, X_k) = Cov(X_i, X_k)$
- (iii)  $Cov_m(X_i, Y) = Cov(X_i, Y)$ .

76. **Twierdzenie** Przy warunkach (i)–(iii)  $h(X) = c_0 + \sum_{i=1}^n c_i X_i$  jest BLUP(Y), jeżeli:

(W1):  $c_0 = 0, \sum_{i=1}^n c_i = 1$

(W2):  $\exists \lambda \in \mathbb{R} \sum_{i=1}^n c_i Cov(X_i, X_k) - Cov(X_k, Y) = \lambda, k = 1, \dots, n$ .

77. **Twierdzenie** Przy warunkach (i) – (iii), jeżeli  $BLUP(Y) = h(X, m)$  i jeżeli uda nam się policzyć  $\hat{m} = BLUE(m)$ , to  $BLUP(Y) = h(X, \hat{m})$ .

78. Predyktory (od najlepszego do najgorszego):

- **BP** - najlepszy predyktor wśród wszystkich funkcji  $X$ ;  $r^*(x) = E(Y|X)$  - wartość oczekiwana a posteriori w modelach bayesowskich. Trzeba znać rozkłady prawdopodobieństwa  $f_\theta(x)$ ,  $\pi(\theta)$ ,  $E(\theta_j|X_{j1}, \dots, X_{jn_j})$ .
- **BLP** - best linear predictor, najlepszy predyktor wśród liniowych,  $r^* = bx^* + a^*$ .  $b^* = \frac{COV(Y,X)}{VarX}$ ,  $a^* = EY - b^*$ . Dla  $X = \mathbb{R}^n$   $r^*(x) = a^* + \sum_{i=1}^n b_i^* x_i$ .  
Wówczas skalarnie:  
 $\sum_{i=1}^n b_i^* Cov(X_i, X_k) = Cov(X_k, Y)$ ,  $k = 1, \dots, n$ ,  
 $a^* = EY - \sum_{i=1}^n b_i^* EX_i$ .  
 $BLP(X_{n+1}) = BLP(\mu(\theta)) = z\bar{X} + (1-z)m$ , gdzie  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ ,  
 $z = \frac{na^2}{na^2+s^2}$  - współczynnik zaufania.  
Trzeba znać  $a^2$ ,  $s^2$ ,  $m$ .
- **BLUP** - trzeba znać komponenty wariancyjne (i BLUE - best linear unbiased estimator)
- **EBLUP** - nic nie trzeba znać, trzeba wierzyć w model.

79. Model bayesowski - podstawowy model statystyki bayesowskiej:

$$(X_1, \dots, X_n, X_{n+1}) \sim_{i.i.d.} f_\theta(\cdot)$$

$$\pi(\cdot) - \text{gęstość a priori } \theta: f(\theta, x_1, \dots, x_n, x_{n+1}) = \pi(\theta)\pi_i f_\theta(x_i).$$

$$\text{Dobrze jest operować skrótami: } u(\theta) = E(X_i|\theta) = \int x_i f_\theta(x_i) dx_i.$$

$$\sigma^2(\theta) = Var(X_i|\theta)$$

$$m = E\mu(\theta) = EX_i$$

$$\text{Komponenty wariancyjne, } VarX_i = s^2 + a^2:$$

$$a^2 = Var\mu(\theta)$$

$$s^2 = E\sigma^2(\theta) = \int \sigma^2(\theta)\pi(\theta)d\theta.$$



80. Model Bühlmanna Strauba:

- $\theta_1, X_{11}, \dots, X_{1n_1}$   
 $\dots$   
 $\theta_p, X_{p1}, \dots, X_{pn_p}$   
gdzie  $X_{ij}$  - szkody  $j$ -tego klienta w  $i$ -tym roku,  $\theta_j$  - zmienna strukturalna dla  $j$ -tego wiersza
- założenie bayesowskie, łączny rozkład:  $f((\theta_j), (x_{ji})) = \Pi_j \pi(\theta_j \Pi_i f_{\theta_j}(x_{ji}))$
- empiryczne podejście bayesowskie:  
 $\mu(\theta_j) = E(X_{ji}|\theta_j), \frac{\sigma^2(\theta_j)}{w_{ji}} = Var(X_{ji}|\theta_j), m = EX_{ji} = E\mu(\theta), s^2 = E\sigma^2(\theta_j), a^2 = Var\mu(\theta_j).$
- $BLP(\mu(\theta_j)) = z_j \bar{X}_j + (1 - z_j)m$ , gdzie  $\bar{X}_j = \sum_{i=1}^{n_j} \frac{w_{ji}}{w_j} X_{ji}, z_j = \frac{w_j a^2}{w_j a^2 + s^2}$  - współczynnik zaufania  
 $BLUE(m) = \sum_j \frac{z_j}{z_j} \bar{X}_j$  (trzeba znać  $s^2$  i  $a^2$ )  
 $BLUP(\mu(\theta_j)) = z_j \bar{X}_j + (1 - z_j)\hat{m}$  (jw.)  
 $EBLUP(\mu(\theta_j)) = \hat{z}_j \bar{X}_j + (1 - \hat{z}_j)\tilde{m}$ , gdzie  $z_j = \frac{w_j \hat{a}^2}{w_j \hat{a}^2 + \hat{s}^2}, \tilde{m} = \sum_j \frac{\hat{z}_j}{z_j} \bar{X}_j$  ( $\tilde{m} - m$  z dwoma daszkami).

81. Estymacja komponentów wariancyjnych

- $SSW = \sum_j \sum_i w_{ji} (X_{ji} - \bar{X}_j)^2, E(SSW) = (n. - p)s^2$ , nieobciążony estymator  $s^2$ :  $\hat{s}^2 = \frac{1}{n. - p} SSW$
- $SSB = \sum_j w_j \cdot (\bar{X}_j - \bar{X})^2$ , gdzie  $\bar{X} = \sum_j \frac{w_j}{w_{..}} \bar{X}_j = \sum_j \sum_i \frac{w_{ji}}{w_{..}} X_{ji}, \hat{a}^2 = \frac{w_{w..}}{w_{..} - \sum_j w_j^2} (SSB - \frac{p-1}{n. - p} SSW)$
- metoda oparta na pseudoestymatorach (REML)  $\tilde{a}^2 = \frac{1}{p-1} \sum_{j=1}^p z_j (\bar{X}_j - \hat{m})^2, E\tilde{a}^2 = a^2.$

82. Modele liniowe mieszane:

$X_{ji} = m + (\mu(\theta_j) - m) + (X_{ji} - \mu(\theta_j)) = m + u_j + \varepsilon_{ji}$ , gdzie:  
 $E u_j = 0, E \varepsilon_{ji} = 0, u$  z  $\varepsilon$  nieskorelowane i między sobą też,  $Var u_j = a^2, Var \varepsilon_{ji} = \frac{s^2}{w_j}.$

Model rozkłada się na addytywne efekty:  $m$  (odpowiada za średnią ogólną - liczba);  $u_j$  (odpowiada za odchyłki wierszowe - zmienna losowa);  $\varepsilon_{ji}$  (odpowiada za odchyłki pojedynczej obserwacji z wiersza - błąd losowy)

83. Model jednokierunkowej klasyfikacji z efektami losowymi, mieszany model liniowy  $y = X\beta + Zu + \varepsilon.$

Po skalaryzacji:  $l^T \beta + k^T u = \sum_{i=1}^p l_i \beta_i + \sum_{j=1}^q k_j u_j = \mu$

Szukamy  $BLP(\mu), BLUP(\mu), BLUE(l^T \beta)$  a potem  $BLP(\mu)$  (lemat z ćwiczeń).

84. **Bayesowska rekonstrukcja obrazów** (image restoration) -  $(S, E)$ , gdzie  $S$  - zbiór wierzchołków (piksli),  $E$  - zbiór krawędzi,  $s \in S, t \in S, s \sim t \equiv \{s, t\} \in E, \delta t = \{s \sim t\}$ .  
 $A$  - alfabet kolorów,  $x : S \rightarrow A, x$  - konfiguracja (obraz),  $x = (x_s, s \in S), x \in X = A^S$ .
85. **Rozkład Gibbsa**  $\pi(x) = \frac{1}{Z_\beta} e^{-\beta H(x)}$ ,  $H(x)$  - energia,  $\beta = 1/T, T$  - temperatura,  $Z_\beta = \sum_{x \in X} e^{-\beta H(x)}$ .
86. **Idea:** Wybieramy  $\pi$  - rozkład Gibbsa, jako rozkład a priori na  $X$ . Obraz „prawdziwy”, „idealny”:  $x \in X$ ; „zazumiony”, „zniekształcony”:  $y \in Y = B^S$ .
87. **Def. Rozkład Gibbsa** z interakcjami między najbliższymi sąsiadami:  
 $H(x) = \sum_{s \sim t} J_{st}(x_s, x_t) + \sum_s h_s(x_s)$ .  
 $\pi(x|y) \propto f(y|x) \pi(x)$  - rozkład a posteriori.
88. **Próbnik Gibbsa**  $H(x) = \sum_{s \sim t} J(x_s, x_t) + \sum_s h_s(x_s), \pi(x_s|x_{-s}) = \pi(x_s|x_{\delta_s})$ .

89. Bayesowski model rekonstrukcji obrazów:

- **wiarogodność:**  $f(y|x) = \pi_{s \in S} f(y_s|x_s)$
- **rozkład a priori** (rozkład Gibbsa):  $\pi(x) = \frac{1}{Z_\beta} \exp[-\beta \sum_{s \sim t} J(x_s, x_t)]$
- **rozkład a posteriori:**  $\pi(X|y) = \frac{1}{Z_\beta^p} \exp[-\beta \sum_{s \sim t} J(x_s, x_t) + \sum_s h(x_s|y_s)]$   
 $(h(x_s|y_s) = h_s(x_s)), \pi(x|y) = \pi(x) \cdot f(y|x), h(x_s|y_s) = \log f(y_s|x_s)$   
 (było:  $\sum_s h_s(x_s) =: \sum_s \ln f(y_s|x_s) = \log f(y|x)$ ).

90. **Cel - obliczanie rozkładu a posteriori:**  $\pi(x_s = a|x_{-s}, y) = \pi(x_s = a|x_{-s}) = \frac{1}{Z_{\beta(s)}} \exp[-\beta \sum_{t:t \sim s} J(a, x_t) + h_s(a)] = \pi(x_s = a|x_{\delta_s})$ .

91. **Próbnik Gibbsa** - podstawowe narzędzie w statystyce bayesowskiej. Należy do rodziny MCMC (Markov Chain Monte Carlo).

92. MCMC - podstawy teoretyczne

$X$  - dowolny (skończony dla uproszczenia),  $\pi$  - rozkład „docelowy” (a posteriori,  $\pi(x) = P(X = x), x \in X$ )

- **Generujemy łańcuch Markowa**  $X_0, X_1, \dots, X_n, \dots$  na  $X$  taki że  $P(X_n = x) \rightarrow_{n \rightarrow \infty} \pi(x), X_n \rightarrow_{n \rightarrow \infty} \pi$ .
- **Własność Markowa**  $P(X_{n+1} = y|X_n = x, X_{n-1}, \dots, X_0 = x_0) = P(X_{n+1} = y|X_n = x) = P(x, y)$ . W klasycznym MCMC posługujemy się jednorodnymi łańcuchami Markowa.  
 $P(x, y)$  - prawdopodobieństwo przejścia,  
 $X$  - przestrzeń konfiguracji.
- **Def.**  $\pi$  jest **rozkładem stacjonarnym** dla  $P$ , jeśli  $\pi^T P = \pi^T$ , tzn.  $\pi(y) = \sum_{x \in X} \pi(x) P(x, y)$  ( $X_n \sim \pi \Rightarrow \pi, P(X_{n+1} = y) = \sum_{x \in X} P(X_n = x) \cdot P(X_{n+1} = y|X_n = x)$ ).
- **Uwaga** Jeśli  $X_0 \sim \pi$  to  $X_0, X_1, \dots, X_n, \dots$  jest **procesem stacjonarnym**, w szczególności  $X_n \sim \pi$ .
- **Twierdzenie (ergodyczne)** Jeżeli  $X$  jest skończona,  $\pi$  jest rozkładem stacjonarnym, łańcuch jest nieprzywiedlny i nieokresowy to  $P(X_n = x) \rightarrow_{n \rightarrow \infty} \pi(x) \forall x$  dla dowolnego rozkładu początkowego  $X_0 \sim \pi_0$ .
- **Twierdzenie odwrotne** Jeśli  $P(X_n = x) \rightarrow_{n \rightarrow \infty} \pi_\infty(x) \forall x$ , to  $\pi^T P = \pi_\infty^T$  (rozkład stacjonarny).
- $P$  jest **nieprzywiedlny**, jeśli  $\forall x, y \in X \exists n P^n(x, y) > 0$  ( $P^n(x, y) = P(X_n = y|X_0 = x)$ ).
- łańcuch nieprzywiedlny jest **nieokresowy**, jeśli  $\forall x, y \in X \exists n_0 \forall n \geq n_0 P^n(x, y) > 0$  (można dojść po dowolnej liczbie kroków, byle dostatecznie dużej).

- **Twierdzenie MPWL**  $g : X \rightarrow \mathbb{R}$   
 $\frac{1}{n} \sum_{i=0}^{n-1} g(X_i) \xrightarrow{n \rightarrow \infty} E_{\pi} g = \sum_{x \in X} g(x) \pi(x)$  p.n.  
dla dowolnego rozkładu początkowego.
- **Twierdzenie CTG**  $\sqrt{n}(\frac{1}{n} \sum_{i=0}^{n-1} g(x_i) - E_{\pi} g) \rightarrow_d N(0, \sigma_{as}^2(g))$ .  
 $\sigma_{as}^2(g) = Var_{\pi} g(X) + 2 \sum_{n=1}^{\infty} Cov_{\pi}(g(X_0), g(X_n))$ .
- **Def.**  $P$  jest  $\pi$ -odwracalna, jeśli  $\pi(x)P(x, y) = \pi(y)P(y, x)$ .
- Łańcuch stacjonarny jest **odwracalny**, jeśli:  
 $P(X_n = x, X_{n+1} = y) = P(X_n = y, X_{n+1} = x)$   
 $(X_0, X_1, \dots, X_n) =^d (X_n, X_{n-1}, \dots, X_0)$ .
- **Stwierdzenie** Jeśli  $P$  jest  $\pi$ -odwracalna to  $\pi^T P = \pi^T$ .

### 93. Algorytm Metropolisa-Hastingsa

- Mamy prawdopodobieństwa przejścia  $Q = (Q(x, y))$  takie, że umiemy generować łańcuch Markowa o przejściach  $Q$ . Zakładamy symetrię  $Q(x, y) = Q(y, x)$ . Rozkład  $U(X)$  (jednostajny) jest stacjonarny.
- **Krok algorytmu** ( $X_n = x$ ):  
1) Gen  $Y \sim Q(x, \cdot)$  - generowanie „propozycji”  
2) Obliczamy  $a(x, Y) = \frac{\pi(Y)}{\pi(x)} \wedge 1$   
3) z prawdopodobieństwem  $a(x, Y)$  bierzemy  $X_{n+1} := Y$  (akceptacja),  
 $1 - a(x, Y)$  bierzemy  $X_{n+1} := x$  (odrzuć).
- **Modyfikacja Hastingsa:**  $Q$  nie musi być symetryczna:  
 $a(x, Y) = \frac{\pi(Y)Q(Y, X)}{\pi(X)Q(x, Y)} \wedge 1$ .
- Łańcuch Metropolisa-Hastingsa ma prawdopodobieństwa przejścia  $P(x, y) = Q(x, y)a(x, y)$  ( $y \neq x$ ).
- **Twierdzenie**  $P$  jest  $\pi$ -odwracalny.
- **Wniosek** Jeśli  $Q$  jest nieprzywiedlna i  $\pi$  nie jest jednostajny to łańcuch Metropolisa-Hastingsa zmierza do  $\pi$ :  $P(X_n = x) \xrightarrow{n \rightarrow \infty} \pi(x)$ .
- **Uwaga** Jeśli  $P(x, x) > 0$  (po jednym kroku) to łańcuch jest nieokresowy.
- **Uwaga** Jeżeli  $\pi_{\beta}(x) = \frac{1}{Z_{\beta}} e^{-\beta H(x)}$  i  $\beta \rightarrow \infty$ , to  
 $\pi_{\beta}(x) = \frac{1}{|X_{min}|}$ , gdy  $H(x) = H_{min}$  lub 0 gdy  $H(x) > H_{min}$ .  
 $H_{min} = \min_{x \in X} H(x)$ ,  $X_{min} = \{x : H(x) = H_{min}\}$ .
- **Symulowane wyżarzanie** (simulated annealing,  $Met + \beta \rightarrow \infty$ ).

94. **Bayesowski model rekonstrukcji obrazów:**

$$x \in X = A^S, x = (x_s)_{s \in S}, \pi(x) = \frac{1}{Z} e^{-H(x)}$$

$$H(x) = \beta \sum_{s \sim t} J(x_s, x_t) + \sum_s h(x_s | y_s)$$

$$h(x_s | y_s) = \log f(y_s | x_s), J(x_s, x_t) = \psi(|x_s - x_t|).$$

95. **Szum Piossonowski:**

- $x_s \in \mathbb{R}_+ = (0, \infty)$ ,  $X = \mathbb{R}_+^S$ ,  $x_s$  – intensywności rozkładu Poissona
- $y_s | x_s \sim Poiss(x_s)$ ,  $f(y_s | x_s) = e^{-x_s} \frac{x_s^{y_s}}{y_s!}$ ,  $y_s \in \{0, 1, \dots\}$ ,  $h(x_s | y_s) = -x_s + y_s \log x_s$
- $x_s = \lambda(x_s)$ ,  $\lambda = (\lambda(1), \dots, \lambda(k))$  – paleta intensywności,  $z_s \in \{1, \dots, k\}$  – etykiety intensywności
- wprowadza się dodatkowe zmienne, które ułatwiają obliczenia; zmienne pomocnicze  $(z, \lambda)$ ,  $z = \varepsilon^S$  – etykiety umieszczenie etykietek w węzłach;  $\lambda = \mathbb{R}_+^\varepsilon$  – umieszczenie intensywności w etykietkach,  $x_s = \lambda(z_s)$
- **energia Potts**=energia a priori (rozkład a priori na  $z$ ) + energia a posteriori; rozkład a priori na  $\lambda$  jest rozkładem jednostajnym (na prostej)  
 $H(z, \lambda) = \beta \sum_{st} 1(z_s \neq z_t) + \sum_s [-\lambda(z_s) + y_s \log \lambda(z_s)]$
- **Próbnik Gibbsa**  $z \sim \pi(z | \lambda)$  ( $\pi(z_s | z_{-s}, \lambda)$ ),  $\lambda \sim \pi(\lambda | z)$ ,  $\lambda$  ustalone.

96. **PET** - positron emission tomography.