

## Podejmowanie decyzji statystycznych

**12.1.** Sprzedawca jest zainteresowany maksymalizacją zysku ze sprzedaży pewnego, łatwo psującego się towaru. Zakup jednego opakowania kosztuje go \$20, zaś sprzedaje je za \$50. Po jednym dniu niesprzedany towar należy wyrzucić jako niezdatny do spożycia. W ciągu stu dni sprzedawca zaobserwował, że klienci kupowali następujące ilości towaru:

Ilość towaru	10	11	12	13
Ilość dni	15	20	40	25

Ile towaru powinien sprzedawca zamówić, by mógł oczekiwać największego zysku?

**12.2.** Przedsiębiorca zainteresowany jest zatrudnieniem w swojej firmie samochodowej kilku mechaników. Na kolejny rok przewidywane są następujące ilości godzin pracy dla mechaników:

Ilość godzin	10000	12000	14000	16000
Prawdopodobieństwo	.2	.3	.4	.1

Planowana zapłata za jedną godzinę pracy mechanika wynosi \$9 zaś spodziewany zysk z jednej godziny pracy — \$16. Mechanik może pracować 40 godzin w tygodniu oraz ma prawo do dwutygodniowego urlopu. Na podstawie podanych informacji podać optymalną liczbę mechaników, która powinna być zatrudniona.

**12.3.** Przedsiębiorstwo lotnicze otrzymuje propozycję zakupu dziesięciu używanych samolotów, przy czym wszystkie są mniej więcej w takim samym stanie technicznym. Pewna nieznaną liczbą  $\theta$  tych samolotów może latać 1000 godzin bez potrzeby większych napraw i każdy z takich samolotów przyniesie zysk w wysokości  $1000p$ ; każdy z pozostałych samolotów dozna jakiegoś poważniejszego uszkodzenia w ciągu pierwszych 1000 godzin eksploatacji, co przyniesie przedsiębiorstwu stratę w wysokości  $1000q$ . Należy zdecydować, czy przyjąć czy odrzucić ofertę. Przed podjęciem decyzji przedsiębiorstwo może otrzymać pewne dalsze informacje, a mianowicie za cenę  $1000r$  może otrzymać jeden samolot do prób, eksploatować go przez 1000 godzin i uzależnić swoją decyzję od tego, czy ten samolot latał 1000 godzin bez awarii, czy nie. Podać wszystkie reguły decyzyjne i ich ryzyka. Wybrać optymalną regułę decyzyjną.

**12.4.** Pewna osoba zamierza sprzedawać napój *Migotka* w trakcie meczu piłki nożnej i musi zawnocześnie zdecydować o wielkości zamówienia. Przypuśćmy, że na każdym sprzedawanym w trakcie gry litrze zyskuje  $m$ , zaś traci  $c$  na każdym zamówionym, lecz nie sprzedanym. Załóżmy, że popyt na *Migotkę* w trakcie gry, mierzony w litrach, jest ciągłą zmienną losową  $X$  o funkcji gęstości  $f$  i dystrybucie  $F$ . Przy jakiej wysokości zamówienia oczekiwany zysk będzie maksymalny?

**12.5.** Rozważmy zagadnienie decyzyjne, w którym  $\Theta = \{\theta_1, \theta_2\}$  oraz  $\mathcal{D} = \{d_1, d_2, d_3\}$ , funkcja straty określona jest w następujący sposób:

	$d_1$	$d_2$	$d_3$
$\theta_1$	0	10	3
$\theta_2$	10	0	3

Niech obserwowana zmienna losowa  $X$  ma rozkład

$$P(X = 1|\theta = \theta_1) = 0.75; \quad P(X = 0|\theta = \theta_1) = 0.25; \quad P(X = 1|\theta = \theta_2) = 0.25; \quad P(X = 0|\theta = \theta_2) = 0.75$$

Zmienna losowa może być obserwowana  $n$  krotnie. Niech  $P\{\theta = \theta_1\} = p = 1 - P\{\theta = \theta_2\}$  ( $0 \leq p \leq 1$ ). Określić bayesowską regułę decyzyjną na podstawie obserwacji  $X_1, \dots, X_n$  i naszkicować jej ryzyko jako funkcję prawdopodobieństwa  $p$ . Zakładając, że koszt każdej obserwacji wynosi  $c$  wyznaczyć optymalną wielkość  $n$ . Wyznaczyć optymalną wielkość próby, gdy koszt obserwacji o wartości 1 wynosi  $c_1$ , zaś koszt obserwacji o wartości 0 wynosi 0.

**12.6.** Niech  $X_1, X_2, \dots, X_n$  będzie próbką losową z rozkładu  $N(\mu, \sigma^2)$  o nieznanymi  $\mu$  i  $\sigma^2$  i niech rozkład *a priori* tych parametrów będzie taki, że  $\mu$  i  $\log \sigma$  są niezależne, a brzegowy rozkład każdej z tych wielkości jest jednostajny. Pokazać, że estymatorem bayesowskim parametru  $\mu$  przy kwadratowej funkcji strat  $L(\hat{\mu}, \mu) = (\hat{\mu} - \mu)^2$  jest  $\bar{X}$ . Ile wynosi ryzyko bayesowskie tego estymatora?

**12.7.** Niech  $X$  będzie zmienną losową o rozkładzie  $N(\theta, 1)$  i niech strata spowodowana szacowaniem  $\theta$  za pomocą  $\hat{\theta}(X)$  ma postać

$$\begin{aligned} a\{\hat{\theta}(X) - \theta\}, & \text{ gdy } \hat{\theta}(X) \geq \theta, \\ b\{\theta - \hat{\theta}(X)\}, & \text{ gdy } \hat{\theta}(X) < \theta, \end{aligned}$$

gdzie  $a > 0$  oraz  $b > 0$ . Pokazać, że ryzyko estymatora  $\hat{\theta}_k$  postaci

$$\hat{\theta}_k(X) = X - k$$

wyraża się wzorem

$$(a + b)\{\varphi(k) + k\Phi(k)\} - ka,$$

gdzie  $\varphi$  i  $\Phi$  są odpowiednio gęstością i dystrybuantą rozkładu  $N(0, 1)$ . Następnie pokazać, że w klasie  $\{\hat{\theta}_k : k \text{ rzeczywiste}\}$  istnieje estymator o jednostajnie minimalnym ryzyku i że to minimalne ryzyko jest równe

$$(a + b)\varphi\left[\Phi^{-1}\left(\frac{a}{a + b}\right)\right].$$

**12.8.** Bochenek chleba musi ważyć co najmniej  $w$  gramów. W pewnej piekarni ciężar chleba w dużym wypieku jest zmienną losową o rozkładzie  $N(\mu, 1/\tau)$ . Parametr  $\mu$  jest wielkością regulowaną, natomiast  $\tau$  zmienia się od wypieku do wypieku według rozkładu chi-kwadrat o  $\nu$  stopniach swobody. Koszt produkcji bochenka chleba, gdy średni ciężar jest równy  $\mu$  wynosi  $k + l\mu$ , a cena zbytu bochenka o prawidłowym ciężarze jest równa  $m$ . Bochenki o zbyt małym ciężarze nie przynoszą zysku. Pokazać, że średni zysk na bochenku, gdy wypiek ustawiony jest na wielkość  $\mu$ , wynosi

$$m\Psi\{(\mu - w)\sqrt{n}\} - (k + l\mu),$$

gdzie  $\Psi$  jest rozkładem  $t$  o  $\nu$  stopniach swobody. Wyznaczyć na tej podstawie najlepszą wartość  $\mu$ .

**12.9.** W procesie mierzenia zawartości RNA w pewnych komórkach pojawia się trudność związana z tym, że dwie komórki mogą znajdować się tak blisko siebie, iż stają się nierozróżnialne. Wykonuje się dwa niezależne pomiary  $X_1$  i  $X_2$ , przy czym każdy z nich może odnosić się do jednej lub dwóch (niezależnych) komórek. Należy zdecydować, czy dana para pomiarów dotyczy dwóch pojedynczych komórek, jednej pojedynczej komórki i jednej pary, czy też dwóch par komórek.

Przypuśćmy, iż wiadomo, że zawartość pojedynczej komórki, mierzona w odpowiednich jednostkach, ma rozkład o gęstości  $xe^{-x}$  ( $x \geq 0$ ) i że prawdopodobieństwo *a priori* tego, że pomiar dotyczy dwóch komórek zamiast jednej wynosi  $\pi$ . Przypuśćmy również, że strata jest równa zero, gdy decyzja jest prawidłowa i jest równa jedności, gdy decyzja jest błędna. Naszkicować na płaszczyźnie  $(x_1, x_2)$  rozwiązanie bayesowskie tego zagadnienia.

**12.10.** Za pomocą pewnego odbiornika rejestruje się  $n$  kolejnych pomiarów  $X_1, X_2, \dots, X_n$  intensywności sygnału radiowego. Jeżeli był nadawany pewien sygnał, to wynik pomiaru ma postać  $X_j = a_j + \varepsilon_j$ , gdzie  $a_1, a_2, \dots, a_n$  są znane, a losowe zakłócenia  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  są realizacją wielowymiarowej zmiennej losowej o rozkładzie normalnym ze średnią równą zero i z macierzą kowariancji  $V$ . Jeżeli sygnał nie był nadawany, to  $X_j = \varepsilon_j$  ( $j = 1, 2, \dots, n$ ). Należy zdecydować, czy sygnał został rzeczywiście nadany. Prawdopodobieństwo *a priori* tego zdarzenia wynosi  $p$ . Straty związane z nieprawidłowym orzeczeniem, że sygnał został lub nie został nadany, są równe odpowiednio  $L - 1$  i  $L_2$ . Wyznaczyć regułę decyzyjną realizującą minimum oczekiwanych strat.

Przypuśćmy, że decyzję podejmuje się zgodnie z tą optymalną regułą i że  $pL_2 = (1 - p)L_1$ . Jak wygląda optymalny ciąg  $\{a_i\}$  sygnałów, jeżeli analiza mocy transmisji prowadzi do ograniczenia  $\sum a_i^2 = 1$ ?

**12.11.** W celu podjęcia decyzji, którą z dwóch odmian pszenicy wprowadzić do masowej produkcji, wykonuje się eksperyment polegający na tym, że każdą z odmian bada się na  $n$  poletkach doświadczalnych. Obserwowane plony  $X_{ij}$  ( $i = 1, 2, j = 1, 2, \dots, n$ ) są niezależnymi zmiennymi losowymi o rozkładzie normalnym ze średnimi  $\mu_i$  i wariancją  $\sigma^2$ , przy czym rozkład *a priori* parametru  $(\mu_1, \mu_2)$  jest taki, że  $\mu_1$  i  $\mu_2$  są niezależne i mają rozkłady brzegowe normalne o średnich równych odpowiednio  $\alpha_1$  i  $\alpha_2$  i wariancji  $\sigma_0^2$ . Wyznaczyć rozkład *a posteriori*  $(\mu_1, \mu_2)$  przy założeniu, że wariancja  $\sigma^2$  jest znana. Pokazać, że gdy funkcje strat mają postać  $L_i = -k\mu_i$  ( $i = 1, 2$ ), wtedy oczekiwane ryzyko osiąga minimum dla decyzji: wybrać odmianę 1, gdy  $X_1 - X_2 > c$  lub odmianę 2, gdy  $X_1 - X_2 < c$ , gdzie  $nX_i = \sum_j X_{ij}$  oraz  $c = (\alpha_2 - \alpha_1)\sigma^2/(n\sigma_0^2)$ .

**12.12.** Niech  $(X_n)$  będzie ciągiem niezależnych zmiennych losowych o rozkładzie Poissona z jednakową średnią  $\theta$ . W celu oszacowania  $\theta$  obserwuje się ten ciąg sekwencyjnie. Zakładamy, że: początkowa wiedza o  $\theta$  opisana jest za pomocą niewłaściwego rozkładu *a priori* o stałej gęstości na przedziale  $(0, \infty)$ ; strata spowodowana oszacowaniem  $\theta$  przez  $\hat{\theta}$  wynosi  $(\hat{\theta} - \theta)^2$ ; koszt każdej obserwacji jest równy  $c$ . Udowodnić, że optymalna bayesowska sekwencyjna reguła decyzyjna ma postać: przerwać obserwacje, gdy tylko  $\sum_{i=1}^n X_i + 1 < cn^2(n + 1)$  i za oszacowanie  $\theta$  przyjąć  $\sum_{i=1}^n (X_i + 1)/n$ .

**12.13.** Niech  $X_1, X_2, \dots, X_{10}$  będzie próbką losową z rozkładu normalnego  $N(0, \theta)$ . Wyznaczyć rozkład *a posteriori* parametru  $\theta$ , gdy rozkład *a priori* tego parametru jest taki sam jak rozkład zmiennej losowej  $\theta_0 \nu_0 / \chi^2(\nu_0)$ , gdzie  $\theta_0$  i  $\nu_0$  są dodatnimi stałymi.

Wyznaczyć najlepszy bayesowski estymator punktowy  $\hat{\theta}$ , gdy funkcja straty ma postać  $(\hat{\theta} - \theta)^2$ . Wykazać, że gdy  $\nu_0 \rightarrow 0$  przy stałym  $\theta_0$ , wtedy

$$\hat{\theta} \rightarrow \frac{1}{8} \sum X_i^2.$$

Porównując estymator  $\frac{1}{8} \sum X_i^2$  z estymatorem różniącym się od niego pewnym mnożnikiem pokazać, że jest to estymator niedopuszczalny.