

# Rachunek prawdopodobo- bieństwa i statystyka

Wykład 11

# Funkcja wiarygodności

**Definicja:** Niech będzie dana próba losowa prosta o liczebności  $n$  z rozkładu  $f(x; \theta)$ .

**Funkcją wiarygodności** dla próby  $x_i$  nazywamy wielkość:


$$\mathcal{L}(\vec{x}; \theta) = \prod_{i=1}^n f(x_i; \theta)$$

**Uwaga:** Funkcja wiarygodności to nie to samo co łączna gęstość p-twa  $L(\vec{x}; \theta)$

**Twierdzenie (Cramera-Rao):** Minimalna wartość wariancji  $\mathcal{V}_{\min}$  dowolnego nieobciążonego estymatora parametru  $\theta$  dana jest przez:

$$\mathcal{V}[\hat{\theta}] \geq \mathcal{V}_{\min}[\hat{\theta}] = \left\{ \mathcal{E} \left[ \left( \frac{\partial}{\partial \theta} \ln L(\vec{x}, \theta) \right)^2 \right] \right\}^{-1} = \left\{ \mathcal{E} \left[ -\frac{\partial^2}{\partial \theta^2} \ln L(\vec{x}, \theta) \right] \right\}^{-1}$$

Ponieważ:

$$\int_{-\infty}^{\infty} L(\vec{x}; \theta) d\vec{x} = 1 \Rightarrow 0 = \int_{-\infty}^{\infty} \frac{\partial \ln L(\vec{x}; \theta)}{\partial \theta} L(\vec{x}; \theta) d\vec{x} = \mathcal{E} \left[ \frac{\partial \ln L(\vec{x}; \theta)}{\partial \theta} \right]$$
$$\int_{-\infty}^{\infty} \left( \frac{\partial \ln L(\vec{x}; \theta)}{\partial \theta} \right)^2 L(\vec{x}; \theta) d\vec{x} = - \int_{-\infty}^{\infty} \frac{\partial^2 \ln L(\vec{x}; \theta)}{\partial \theta^2} L(\vec{x}; \theta) d\vec{x}$$


# Twierdzenie Cramera-Rao

Estymator o minimalnej wariancji nazywamy **efektywnym** (najefektywiejszym)

**Efektywnością estymatora** nazywamy stosunek jego wariancji do  $\mathcal{V}_{\min}$ .

W przypadku  $n$  parametrów rozkładu  $\vec{\theta} = (\theta_1, \dots, \theta_n)$  nierówność Cramera-Rao ma charakter macierzowy, a minimalna wariancja wynosi:

$$\mathbf{V}_{\min} [\hat{\vec{\theta}}] = \left[ \mathcal{E} \left[ \left( \frac{\partial}{\partial \theta_i} \ln L(\vec{x}, \vec{\theta}) \right) \left( \frac{\partial}{\partial \theta_j} \ln L(\vec{x}, \vec{\theta}) \right) \right] \right]^{-1} = \left[ \mathcal{E} \left[ - \frac{\partial^2 \ln L(\vec{x}, \vec{\theta})}{\partial \theta_i \partial \theta_j} \right] \right]^{-1}$$

Twierdzenie Cramera-Rao stwierdza, że  $\mathbf{V} - \mathbf{V}_{\min}$  gdzie  $V_{ij} = \text{cov}(\hat{\theta}_i, \hat{\theta}_j)$  jest macierzą dodatnio półokreśloną, w szczególności

$$\mathcal{V}[\hat{\theta}_i] \geq [\mathbf{V}_{\min}]_{ii}$$

Uwaga: Często wykorzystujemy  $\mathbf{V}_{\min}$  jako przybliżenie macierzy kowariancji wstawiając w drugich pochodnych zamiast parametru jego estymatę.

# Metoda największej wiarygodności

**Zasada największej wiarygodności:** za estymatę nieznanego parametru  $\theta$  powinniśmy wybrać taką liczbę  $\hat{\theta}$  dla której funkcja wiarygodności osiąga maksimum:

$$\mathcal{L}(\vec{x}; \hat{\theta}) = \max$$

A więc:  $\frac{\partial}{\partial \theta} \mathcal{L}(\vec{x}; \theta) = 0$  przy warunku  $\left. \frac{\partial^2}{\partial \theta^2} \mathcal{L}(\vec{x}; \theta) \right|_{\theta=\hat{\theta}} < 0$

Często stosujemy następujące równanie do znalezienia estymaty MNW:

$$\frac{\partial}{\partial \theta} \ln \mathcal{L}(\vec{x}; \theta) = \sum_{i=1}^n \frac{\partial}{\partial \theta} \ln f(x_i; \theta) = 0 \quad \text{przy warunku} \quad \left. \sum_{i=1}^n \frac{\partial^2}{\partial \theta^2} \ln f(x_i; \theta) \right|_{\theta=\hat{\theta}} < 0$$

W przypadku  $k$  parametrów  $\vec{\theta} = (\theta_1, \dots, \theta_k)$  musimy rozwiązać układ  $k$  równań:

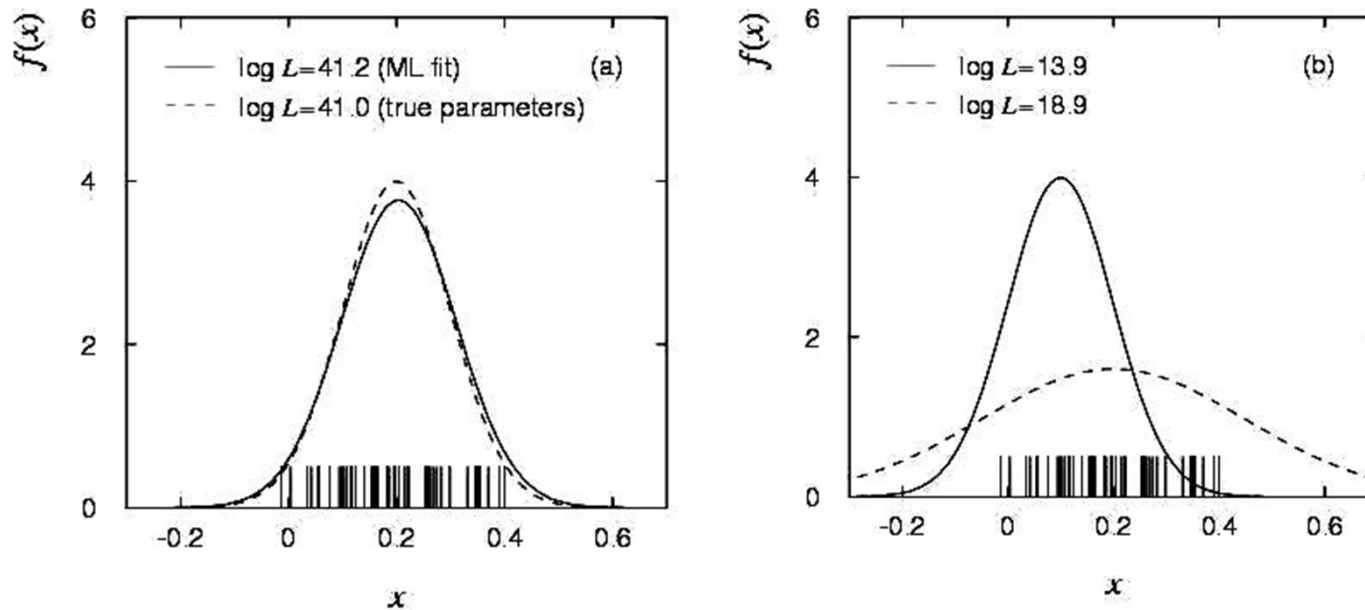
$$\frac{\partial}{\partial \theta_j} \ln \mathcal{L}(\vec{x}; \vec{\theta}) = \sum_{i=1}^n \frac{\partial}{\partial \theta_j} \ln f(x_i; \vec{\theta}) = 0$$

przy warunku ujemnej określoności macierzy:

$$\left. \sum_{i=1}^n \frac{\partial^2}{\partial \theta_j \partial \theta_k} \ln f(x_i; \theta) \right|_{\vec{\theta}=\hat{\vec{\theta}}}$$

# Metoda największej wiarygodności

Jeśli oszacowana wartość parametru jest bliska wartości prawdziwej, to oczekujemy dużego p-twa otrzymania z eksperymentu danych takich jakie rzeczywiście uzyskaliśmy.



Wygenerowanych 50 przypadków z rozkładu normalnego o  $\mu = 0.2$  i  $\sigma = 0.1$

Wyniki otrzymane z maksymalizacji funkcji wiarygodności  $\hat{\mu} = 0.204$  oraz  $\hat{\sigma} = 0.106$

Odstępstwa od wartości prawdziwych są miarą błędów statystycznych.

W przypadku estymat parametrów bardzo odbiegających od wartości prawdziwych otrzymujemy znacznie mniejsze wartości funkcji wiarygodności.

# Własności estymatorów MNW

Przykład: Wyznaczenie estymatora parametrów  $\tau$  i  $\lambda$  rozkładu wykładniczego.

$$\mathcal{L}(t; \lambda) = \prod_{i=1}^n \frac{1}{\tau} \exp\left(-\frac{t_i}{\tau}\right) \Rightarrow \ln \mathcal{L} = -n \ln \tau - \frac{1}{\tau} \sum_{i=1}^n t_i$$
$$\frac{\partial \ln \mathcal{L}}{\partial \tau} = -\frac{n}{\tau} + \frac{1}{\tau^2} \sum_{i=1}^n t_i \Rightarrow -\frac{n}{\hat{\tau}} + \frac{1}{\hat{\tau}^2} \sum_{i=1}^n t_i = 0 \Rightarrow \hat{\tau} = \frac{1}{n} \sum_{i=1}^n t_i = \bar{t}$$

Podobnie wyznaczamy estymator parametru  $\lambda$ :

$$\mathcal{L}(t; \lambda) = \prod_{i=1}^n \lambda \exp(-\lambda t_i) \Rightarrow \ln \mathcal{L} = n \ln \lambda - \lambda \sum_{i=1}^n t_i$$
$$\frac{\partial \ln \mathcal{L}}{\partial \lambda} = \frac{n}{\lambda} - \sum_{i=1}^n t_i \Rightarrow \frac{n}{\hat{\lambda}} - \sum_{i=1}^n t_i = 0 \Rightarrow \hat{\lambda} = \frac{n}{\sum_{i=1}^n t_i} = \frac{1}{\bar{t}}$$

Widać, że estymator jest niezmienniczy względem transformacji  $\alpha(\xi) = 1/\xi$

Jest to ogólna cecha estymatorów MNW, tzn. jeśli znamy estymator parametru  $\theta$  a interesuje nas funkcja tego parametru  $\alpha(\theta)$  to przy założeniu, że  $\partial \alpha / \partial \theta \neq 0$  mamy

$$0 = \frac{\partial \mathcal{L}}{\partial \theta} = \frac{\partial \mathcal{L}}{\partial \alpha} \frac{\partial \alpha}{\partial \theta} \Rightarrow \frac{\partial \mathcal{L}}{\partial \alpha} = 0$$

# Szacowanie błędów estymatorów MNW

Ponieważ w ogólności  $\mathcal{E}[\alpha(\hat{\theta})] \neq \alpha(\mathcal{E}[\hat{\theta}])$  (z wyjątkiem przekształcenia liniowego), więc oczekujemy, że estymatory MNW są z reguły obciążone.

Przykład: nieobciążony estymator parametru  $\tau$   $\mathcal{E}[\hat{\tau}] = \tau$

i tylko asymptotycznie nieobciążony estymator parametru  $\lambda$ :  $\mathcal{E}[\hat{\lambda}] = \frac{n}{n-1} \lambda$

Wariancja estymatora największej wiarygodności:

$$\mathcal{V}[\hat{\theta}] = \int (\hat{\theta}(\bar{x}) - \langle \hat{\theta} \rangle)^2 L(\bar{x}; \theta) d\bar{x}$$

Wariancja przyjmuje postać funkcji ocenianego parametru. Aby uzyskać wartość liczbową musimy wstawić jego estymatę ( a więc jest to przybliżenie).

W przypadku  $k$  parametrów musimy znaleźć macierz kowariancji:

$$\mathcal{V}[\hat{\theta}_i, \hat{\theta}_j] = \int (\hat{\theta}_i(\bar{x}) - \langle \hat{\theta}_i \rangle) (\hat{\theta}_j(\bar{x}) - \langle \hat{\theta}_j \rangle) L(\bar{x}; \vec{\theta}) d\bar{x}$$

W ten sposób można wyznaczyć wariancję estymatora tylko w prostych przypadkach.

Najczęściej powyższe całki są trudne/niemożliwe do rozwiązania analitycznie i musimy stosować bądź przybliżenia, bądź metodę Monte Carlo.

# Szacowanie błędów estymatorów MNW

**Przykład:** Wariancja estymatora parametru rozkładu wykładniczego:

$$\begin{aligned}\mathcal{V}[\hat{\tau}] &= \int_0^{\infty} \left( \frac{1}{n} \sum_{i=1}^n t_i - \tau \right)^2 \prod_{j=1}^n \frac{1}{\tau} \exp\left(-\frac{t_j}{\tau}\right) d\vec{t} = \\ &= \frac{1}{\tau^n} \left( \int_0^{\infty} \left( \frac{1}{n} \sum_{i=1}^n t_i \right)^2 \prod_{j=1}^n \exp\left(-\frac{t_j}{\tau}\right) d\vec{t} - 2\tau \int_0^{\infty} \left( \frac{1}{n} \sum_{i=1}^n t_i \right) \prod_{j=1}^n \exp\left(-\frac{t_j}{\tau}\right) d\vec{t} + \tau^2 \int_0^{\infty} \prod_{j=1}^n \exp\left(-\frac{t_j}{\tau}\right) d\vec{t} \right) = \\ &= \frac{1}{\tau^n} \left( \frac{1}{n^2} n 2\tau^3 \tau^{n-1} + \frac{1}{n^2} n(n-1) \tau^2 \tau^2 \tau^{n-2} - \frac{2\tau}{n} n \tau^2 \tau^{n-1} + \tau^2 \tau^n \right) = \frac{\tau^2}{n}\end{aligned}$$

W przypadku dużej próbki danych możemy znaleźć estymator wariancji estymatora parametru MNW korzystając z warunku nierówności Cramera-Rao:

$$\hat{\mathcal{V}}[\hat{\theta}] = - \left( \frac{\partial^2 \ln \mathcal{L}}{\partial \theta^2} \Big|_{\theta=\hat{\theta}} \right)^{-1}$$

lub w przypadku większej liczby parametrów:

$$\hat{\mathcal{V}}[\hat{\theta}_i, \hat{\theta}_j] = - \left( \frac{\partial^2 \ln \mathcal{L}}{\partial \theta_i \partial \theta_j} \Big|_{\vec{\theta}=\hat{\vec{\theta}}} \right)^{-1}$$



# Zachowanie asymptotyczne $\mathcal{L}(\theta)$

Przykład: Estymator wariancji estymatora parametru rozkładu wykładniczego.

$$\hat{\mathcal{V}}[\hat{\tau}] = -\left(\frac{\partial^2 \ln \mathcal{L}}{\partial \tau^2} \Big|_{\tau=\hat{\tau}}\right)^{-1} = \frac{\hat{\tau}^2}{n} \qquad \hat{\mathcal{V}}[\hat{\lambda}] = -\left(\frac{\partial^2 \ln \mathcal{L}}{\partial \lambda^2} \Big|_{\lambda=\hat{\lambda}}\right)^{-1} = \frac{\hat{\lambda}^2}{n}$$

Uwaga: Estymatory metody największej wiarygodności są zgodne.

Zachowanie funkcji wiarygodności jako funkcji parametru  $\theta$  w okolicach wartości tego parametru określone jego estymatą MNW:

$$\ln \mathcal{L}(\theta) = \underbrace{\ln \mathcal{L}(\hat{\theta})}_{\ln \mathcal{L}_{\max}} + \underbrace{\frac{\partial \ln \mathcal{L}}{\partial \theta} \Big|_{\theta=\hat{\theta}}}_{=0} (\theta - \hat{\theta}) + \frac{1}{2} \frac{\partial^2 \ln \mathcal{L}}{\partial \theta^2} \Big|_{\theta=\hat{\theta}} (\theta - \hat{\theta})^2 + \mathcal{O}((\theta - \hat{\theta})^3)$$

$$\ln \mathcal{L}(\theta) \approx \ln \mathcal{L}_{\max} - \frac{(\theta - \hat{\theta})^2}{2\hat{\mathcal{V}}[\hat{\theta}]} \quad \Rightarrow \quad \mathcal{L}(\theta) \approx \mathcal{L}_{\max} \exp\left[-\frac{(\theta - \hat{\theta})^2}{2\hat{\mathcal{V}}[\hat{\theta}]}\right]$$

Funkcja wiarygodności jako funkcja parametru  $\theta$  ma w okolicach maksimum w przybliżeniu kształt rozkładu Gaussa.

# Szacowanie błędów estymatorów MNW

Metoda graficzna szacowania błędów statystycznych estymatorów MNW.

$$\ln \mathcal{L}(\theta) \approx \ln \mathcal{L}_{\max} - \frac{(\theta - \hat{\theta})^2}{2\hat{\sigma}_{\hat{\theta}}^2} \Rightarrow \ln \mathcal{L}(\hat{\theta} \pm \hat{\sigma}_{\hat{\theta}}) \approx \ln \mathcal{L}_{\max} - \frac{1}{2}$$

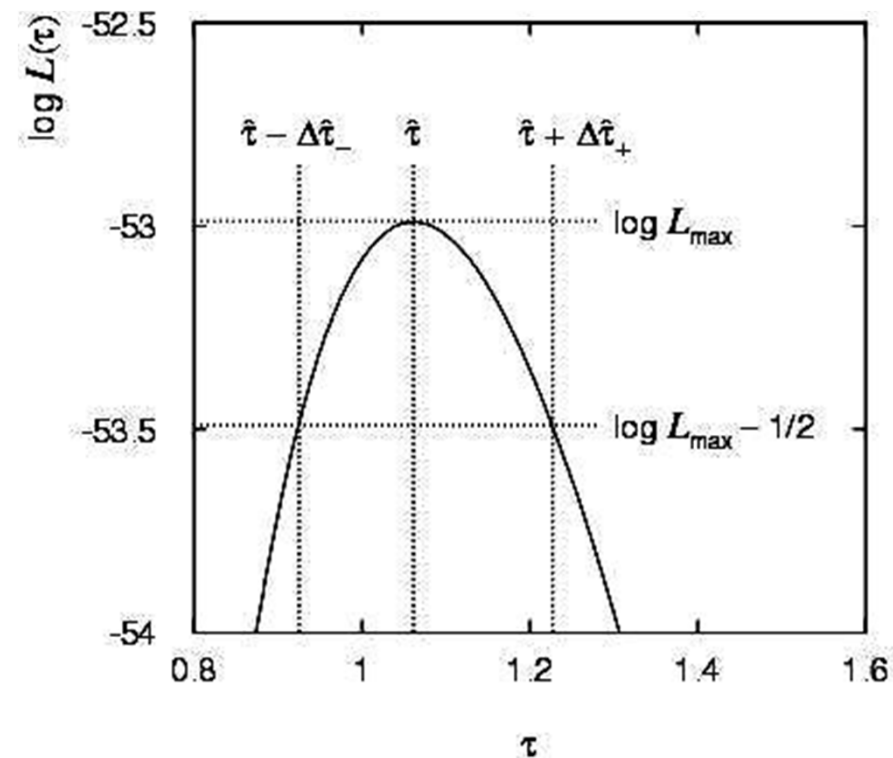
Przykład: Estymator wariancji estymatora parametru rozkładu wykładniczego.

$$\hat{\tau} = 1.062$$

$$\Delta \hat{\tau}_- = 0.137$$

$$\Delta \hat{\tau}_+ = 0.165$$

$$\hat{\sigma}_{\hat{\tau}} \approx \Delta \hat{\tau}_- \approx \Delta \hat{\tau}_+ \approx 0.15$$



Odstępstwo od paraboli ze względu na małą statystykę (n=50)

# Metoda największej wiarygodności

Przykład: Wyznaczenie parametrów  $\mu$  oraz  $\sigma$  rozkładu normalnego.

$$\mathcal{L}(\mathbf{x}; \mu, \sigma) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{(x_i - \mu)^2}{2\sigma^2}\right\} = \left(\frac{1}{\sqrt{2\pi}\sigma}\right)^n \exp\left\{-\frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}\right\}$$

$$\ln \mathcal{L} = -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

Obliczamy pochodne funkcji wiarygodności po parametrach  $\mu$  oraz  $\sigma$ :

$$\begin{cases} \frac{\partial \ln \mathcal{L}}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) \\ \frac{\partial \ln \mathcal{L}}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu)^2 \end{cases} \Rightarrow \begin{cases} \frac{1}{\hat{\sigma}^2} \sum_{i=1}^n (x_i - \hat{\mu}) = 0 \Rightarrow \hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i \\ -\frac{n}{2\hat{\sigma}^2} + \frac{1}{2\hat{\sigma}^4} \sum_{i=1}^n (x_i - \hat{\mu})^2 = 0 \Rightarrow \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{\mu})^2 \equiv S_x^2 \end{cases}$$

Estymatory wariancji estymatorów parametrów  $\mu$  oraz  $\sigma$ :

$$\hat{\mathcal{V}}[\hat{\mu}] = -\left(\frac{\partial^2 \ln \mathcal{L}}{\partial \mu^2} \Big|_{\substack{\mu=\hat{\mu} \\ \sigma=\hat{\sigma}}}\right)^{-1} = -\left(-\frac{n}{\sigma^2} \Big|_{\substack{\mu=\hat{\mu} \\ \sigma=\hat{\sigma}}}\right)^{-1} = \frac{\hat{\sigma}^2}{n} \quad \hat{\mathcal{V}}[\hat{\sigma}^2] = -\left(\frac{\partial^2 \ln \mathcal{L}}{\partial (\sigma^2)^2} \Big|_{\sigma^2=\hat{\sigma}^2}\right)^{-1} = \frac{2\hat{\sigma}^4}{n}$$

# Metoda największej wiarygodności

Przykład: Opór każdego z  $n$  różnych oporników zmierzono niezależnie 2 razy. Dokładność każdego z pomiarów jest taka sama, a prawdziwe wartości oporu nie są znane.

Przyjmując, że każdy z pomiarów opisany jest rozkładem Gaussa o tej samej dyspersji  $\sigma$ , ale różnych wartościach oczekiwanych  $\mu_i$  ( $i = 1, \dots, n$ ), odpowiadających różnym oporom, znajdź estymatory wielkości  $\mu_i$  i  $\sigma$ .

$$\mathcal{L}(x, y; \bar{\mu}, \sigma) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(x_i - \mu_i)^2}{2\sigma^2}\right) \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{(y_j - \mu_j)^2}{2\sigma^2}\right) =$$

$$= \frac{1}{(\sqrt{2\pi\sigma})^n} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu_i)^2\right) \frac{1}{(\sqrt{2\pi\sigma})^n} \exp\left(-\frac{1}{2\sigma^2} \sum_{j=1}^n (y_j - \mu_j)^2\right)$$

$$\ln \mathcal{L} = -\frac{1}{2} \ln 2\pi - \frac{1}{2} n \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu_i)^2 - \frac{1}{2} \ln 2\pi - \frac{1}{2} n \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mu_i)^2$$

$$\frac{\partial \ln \mathcal{L}}{\partial \mu_i} = \frac{x_i - \mu_i}{\sigma^2} + \frac{y_i - \mu_i}{\sigma^2} \Rightarrow \frac{x_i - \hat{\mu}_i}{\hat{\sigma}^2} + \frac{y_i - \hat{\mu}_i}{\hat{\sigma}^2} = 0 \Rightarrow \boxed{\hat{\mu}_i = \frac{1}{2}(x_i + y_i)}$$

$$\frac{\partial \ln \mathcal{L}}{\partial \sigma^2} = -\frac{1}{2} n \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \mu_i)^2 - \frac{1}{2} n \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (y_i - \mu_i)^2$$

$$-\frac{n}{\hat{\sigma}^2} + \frac{1}{2\hat{\sigma}^4} \sum_{i=1}^n [(x_i - \hat{\mu}_i)^2 + (y_i - \hat{\mu}_i)^2] = 0 \Rightarrow \boxed{\hat{\sigma}^2 = \frac{1}{4n} \sum_{i=1}^n (x_i - y_i)^2}$$

# Metoda największej wiarygodności

Przykład: Wyznaczenie estymatora parametru rozkładu Poissona.

$$\mathcal{L}(\mathbf{k}; \mu) = \prod_{i=1}^n \frac{\mu^{k_i}}{k_i!} e^{-\mu} \Rightarrow \ln \mathcal{L} = \sum_{i=1}^n \left( \ln \frac{\mu^{k_i}}{k_i!} - \mu \right) = \sum_{i=1}^n k_i \ln \mu - \sum_{i=1}^n \ln k_i! - n\mu$$

$$\frac{\partial \ln \mathcal{L}}{\partial \mu} = \frac{1}{\mu} \sum_{i=1}^n k_i - n \Rightarrow \frac{1}{\hat{\mu}} \sum_{i=1}^n k_i - n = 0 \Rightarrow \hat{\mu} = \frac{1}{n} \sum_{i=1}^n k_i$$

Wartość oczekiwana i wariancja:

$$\mathcal{E}[\hat{\mu}] = \left\langle \frac{1}{n} \sum_{i=1}^n k_i \right\rangle = \frac{1}{n} \sum_{i=1}^n \langle k_i \rangle = \frac{1}{n} n\mu = \mu$$

$$\begin{aligned} \mathcal{V}[\hat{\mu}] &= \sum_{k=0}^{\infty} \left[ (\hat{\mu} - \mu)^2 L(\mathbf{k}; \mu) \right] = \sum_{k=0}^{\infty} \left[ \left( \frac{1}{n} \sum_{i=1}^n k_i - \mu \right)^2 \prod_{l=1}^n \frac{\mu^{k_l}}{k_l!} e^{-\mu} \right] = \sum_{k=0}^{\infty} \left[ \left( \frac{1}{n} \sum_{i=1}^n (k_i - \mu) \right)^2 \prod_{l=1}^n \frac{\mu^{k_l}}{k_l!} e^{-\mu} \right] = \\ &= \sum_{k=0}^{\infty} \left[ \frac{1}{n^2} \left( \sum_{i=1}^n (k_i - \mu)^2 + \sum_{i \neq j=1}^n (k_i - \mu)(k_j - \mu) \right) \prod_{l=1}^n \frac{\mu^{k_l}}{k_l!} e^{-\mu} \right] = \\ &= \frac{1}{n^2} \sum_{k=0}^{\infty} \left( \sum_{i=1}^n (k_i - \mu)^2 \prod_{l=1}^n \frac{\mu^{k_l}}{k_l!} e^{-\mu} \right) = \frac{1}{n^2} n \mathcal{V}[\mathbf{k}] = \frac{\mu}{n} \end{aligned}$$

# Średnia ważona

Dana jest próbka prosta złożona z  $n$  elementów  $x_i$  ( $i=1, \dots, n$ ), każdy z rozkładu normalnego o różnej i znanej dyspersji  $\sigma_i$ , ale nieznannej i identycznej wartości oczekiwanej  $\mu$ . (np. pomiary danej wielkości za pomocą różnych przyrządów).

$$\mathcal{L}(\vec{x}; \mu, \sigma_i) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma_i^2}\right)$$

$$\ln \mathcal{L} = -\frac{n}{2} \ln 2\pi - \frac{1}{2} \sum_{i=1}^n \ln \sigma_i^2 - \frac{1}{2} \sum_{i=1}^n \frac{(x_i - \mu)^2}{\sigma_i^2} \quad \Rightarrow \quad \frac{\partial \ln \mathcal{L}}{\partial \mu} = \sum_{i=1}^n \frac{(x_i - \mu)}{\sigma_i^2}$$

$$\sum_{i=1}^n \frac{(x_i - \hat{\mu})}{\sigma_i^2} = 0 \quad \Leftrightarrow \quad \sum_{i=1}^n \frac{x_i}{\sigma_i^2} = \hat{\mu} \sum_{i=1}^n \frac{1}{\sigma_i^2} \quad \Rightarrow \quad \hat{\mu} = \sum_{i=1}^n \frac{x_i}{\sigma_i^2} / \sum_{i=1}^n \frac{1}{\sigma_i^2}$$

Średnia ważona:  $\hat{\mu} = \sum_{i=1}^n w_i x_i$  gdzie  $w_i = \frac{\frac{1}{\sigma_i^2}}{\sum_{j=1}^n \frac{1}{\sigma_j^2}}$

# Średnia ważona

Wartość oczekiwana i wariancja:

$$\int_{-\infty}^{\infty} \exp(-ax^2) dx = \sqrt{\frac{\pi}{a}}$$

$$\mathcal{E}[\hat{\mu}] = \sum_{i=1}^n w_i \langle x_i \rangle = \mu \sum_{i=1}^n w_i = \mu$$

$$\int_{-\infty}^{\infty} x^2 \exp(-ax^2) dx = \frac{1}{2a} \sqrt{\frac{\pi}{a}}$$

$$\begin{aligned} \mathcal{V}[\hat{\mu}] &= \int_{-\infty}^{\infty} (\hat{\mu} - \mu)^2 L(x; \mu, \sigma) dx = \int_{-\infty}^{\infty} \left( \sum_{i=1}^n w_i x_i - \mu \right)^2 \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_j}} \exp\left(-\frac{(x_j - \mu)^2}{2\sigma_j^2}\right) dx = \\ &= \int_{-\infty}^{\infty} \left( \sum_{i=1}^n w_i (x_i - \mu) \right)^2 \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_j}} \exp\left(-\frac{(x_j - \mu)^2}{2\sigma_j^2}\right) dx = \\ &= \int_{-\infty}^{\infty} \left( \sum_{i=1}^n w_i^2 (x_i - \mu)^2 + \sum_{i \neq k=1}^n w_i w_k (x_i - \mu)(x_k - \mu) \right) \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma_j}} \exp\left(-\frac{(x_j - \mu)^2}{2\sigma_j^2}\right) dx = \\ &= \sum_{i=1}^n w_i^2 \sigma_i^2 \prod_{\substack{j=1 \\ j \neq i}}^n \frac{1}{\sqrt{2\pi\sigma_j}} \sqrt{2\pi\sigma_j} = \sum_{i=1}^n w_i^2 \sigma_i^2 = \sum_{i=1}^n \left( \frac{\frac{1}{\sigma_i^2} \sigma_i}{\sum_{j=1}^n \frac{1}{\sigma_j^2}} \right)^2 = \frac{1}{\sum_{j=1}^n \frac{1}{\sigma_j^2}} \end{aligned}$$

# Metoda największej wiarygodności

Przykład: Prędkość dźwięku mierzona w powietrzu dwiema różnymi metodami wynosi:  $v_1=340 \pm 9$  [m/s] oraz  $v_2=350 \pm 18$  [m/s]. Znajdź najlepszą estymatę prędkości dźwięku.

Obliczamy wagi:  $w_1 = \frac{1}{9^2} = 0.013$        $w_2 = \frac{1}{18^2} = 0.003$

Średnia ważona prędkość dźwięku oraz jej błąd:

$$v_w = \frac{w_1 v_1 + w_2 v_2}{w_1 + w_2} = 342 \text{ [m/s]} \quad \sigma_w = \sqrt{(w_1 + w_2)^{-1}} = 8 \text{ [m/s]}$$