

Wykład 5

26 października 2012

13:53

4. Kwantowy efekt Aharonova

Rozważmy układ w stanie podstawowym $|0\rangle$

ewoluujący zgodnie z hamiltonianem H

$$|\psi(t)\rangle = e^{-iH \cdot t} |0\rangle =$$

$$= a_0(t)|0\rangle + \sum_{i>0} a_i(t)|i\rangle$$

Mierzmy układ w bazie $|0\rangle, |1\rangle, |2\rangle, \dots$

Przyp. że porostanie w stanie podstawowym:

$$p_0 = |\langle 0 | \psi(t) \rangle|^2 = |\langle 0 | e^{-iHt} |0\rangle|^2$$

Dla krótkich t mamy rozwinięcie:

$$p_0 = \langle 0 | 1 - iHt - \frac{H^2 t^2}{2} |0\rangle \langle 0 | 1 + iHt - \frac{H^2 t^2}{2} |0\rangle$$

$$= 1 - it \langle H \rangle + it \langle H \rangle + \langle H \rangle^2 t^2 - t^2 \langle H^2 \rangle + O(t^4)$$

$$\approx 1 - t^2 \Delta^2 H + O(t^4)$$

Robimy pomiar N krotnie w czasie t

Jakie jest prawdop. że porostanie w stanie $|0\rangle$

$$p_0^{(N)} \approx \left(1 - \left(\frac{t}{N}\right)^2 \Delta^2 H + O\left(\left(\frac{t}{N}\right)^4\right) \right)^N \approx$$

$$\approx 1 - \frac{t^2}{N} \Delta^2 H \xrightarrow{N \rightarrow \infty} 1$$


Stan się ewoluje, czesty pomiar

"zamrozi" go w stanie podstawowym

"Ruch jest zamarznięciem", ...

II Klasyczna teoria estymacji

1. Estymacja parametru (podejście klasyczne - nie Bayesowskie)



$p_{\Theta}(x)$ - rodzina rozkładów prawdopodobieństwa opisującą zmienną losową X

Chcemy wywnioskować θ na podstawie X

$\tilde{\Theta}(x)$ - estymator, ma nam dać informację o θ

Przykład

$$X = (x_1, \dots, x_N)$$

$$x_i = \theta + w_i$$

niezależne zmienną losową

$$w_i \sim N(0, \sigma^2)$$

rozkład Gaussa | średnia | wariancja

$$x_i \sim N(\theta, \sigma^2)$$

$$p_{\Theta}(x) = p_{\Theta}(x_1) \cdot \dots \cdot p_{\Theta}(x_N)$$

$$p_{\Theta}(x_i) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \theta)^2}{2\sigma^2}}$$

Miemy (x_1, \dots, x_N)

Jaki byłby „dobry” estymator Θ

• $\tilde{\Theta}(x) = x_1$

• $\tilde{\Theta}(x) = \frac{\sum_i x_i}{N}$

1.1 Optymalne estymatory

Nieobciążoność estymatora

$$\langle \tilde{\Theta} \rangle = \Theta \quad \text{tzn.} \quad \int_{\Theta} \tilde{\Theta}(x) p_{\Theta}(x) dx = \Theta$$

Średnio daje prawdziwą wartość

• $\tilde{\Theta}(x) = x_1 \quad \langle \tilde{\Theta} \rangle = \langle x_1 \rangle = \Theta \quad \text{OK}$

• $\tilde{\Theta}(x) = \frac{\sum_i x_i}{N} \quad \langle \tilde{\Theta} \rangle = \frac{1}{N} \sum_i \langle x_i \rangle = \Theta \quad \text{OK}$

Optymalność estymatora

Wariancja estymatora

$$\Delta^2 \tilde{\Theta} = \langle (\tilde{\Theta} - \Theta)^2 \rangle = \int (\tilde{\Theta}(x) - \Theta)^2 p_{\Theta}(x) dx$$

Chcemy aby $\Delta^2 \tilde{\Theta}$ było jak najmniejsza

Uwaga: najmniej nielini estymator; który będzie

dobry dla pewnych wartości Θ a gorszy dla innych.

Typowy przykład $\tilde{\Theta} = \Theta_0$ nie zależy od danych

- to jest przykład estymatora obciążonego

Zaczynamy bardziej interesować się:

„Minimum variance unbiased estimator” (MVU)

Nieobciążony estymator z minimalną wariancją

- minimalna wariancja dla wszystkich θ

Przykład

$$x_i \sim N(\theta, \sigma^2)$$

$$\tilde{\theta}(x_1, \dots, x_N) = \frac{1}{N} \sum_i x_i$$

$$\begin{aligned} \Delta^2_{\tilde{\theta}} &= \left\langle \left(\frac{1}{N} \sum_i x_i - \theta \right)^2 \right\rangle = \frac{1}{N^2} \langle (x_1 - \theta + x_2 - \theta + \dots + x_N - \theta)^2 \rangle = \\ &= \frac{1}{N^2} N \sigma^2 = \frac{\sigma^2}{N} \quad \text{jest MVU} \\ &\quad \text{(dowód poniżej)} \end{aligned}$$

$$\left\{ \begin{array}{l} \text{gdyby wziąć } \tilde{\theta}(x_1, \dots, x_N) = x_1 \quad \Delta^2_{\tilde{\theta}} = \sigma^2 \end{array} \right.$$

Przykład: (MVU może nie istnieć)

$$x_1 \sim N(\theta, 1)$$

$$x_2 = \begin{cases} N(\theta, 1) & \theta \geq 0 \\ N(\theta, 2) & \theta < 0 \end{cases}$$

Dla $\theta \geq 0$ najlepszy estymator to $\tilde{\theta} = \frac{1}{2}(x_1 + x_2)$, $\hat{\theta}$

Dla $\theta < 0$ najlepszy estymator to $\tilde{\theta} = \frac{2}{3}x_1 + \frac{1}{3}x_2$, $\hat{\theta}$

Sam niechciałem ale mi nie udało się estymator

do którego minimalna wariancja dla wszystkich θ

Jaka szkoda optymalnych estymatorów?

1.2 Ograniczenie Cramera-Rao (CR)

Chcemy mieć ograniczenie na najlepszy możliwy estymator nieobciążony

wtedy jeśli istnieje estymator osiągający ograniczenie

wtedy jest optymalny

Intuicja: $p_{\theta}(x)$ im bardziej różnił się

...

zmieni się z θ tym większa precyzja estymacji;
 w granicznym przypadku się $\frac{d}{d\theta} p_{\theta}(x)$

Zaliczenia

$$\langle \tilde{\theta} \rangle = \int dx \tilde{\theta}(x) p_{\theta}(x) = \theta \quad - \text{nieobciążoność}$$

w zjednoczonej dziedzinie
potrzebować;

$$(*) \frac{d\langle \tilde{\theta} \rangle}{d\theta} = \int dx \tilde{\theta}(x) \frac{d p_{\theta}(x)}{d\theta} = 1 \quad - \text{lokalna nieobciążoność}$$

$$(**) \int dx \frac{d p_{\theta}(x)}{d\theta} = 0 \quad - \text{warunek regularności}$$

|| jeśli mamy zależności
 korelacji ciłowania
 i różnicowania,

$$\frac{d}{d\theta} \int dx p_{\theta}(x) = \frac{d}{d\theta} 1 = 0 \quad \text{spełniony}$$

Wyprawochena:

$$\underbrace{\int dx p_{\theta}(x) (\tilde{\theta}(x) - \theta)^2}_{\Delta^2 \tilde{\theta}} \cdot \underbrace{\int dx \frac{1}{p_{\theta}(x)} \left(\frac{d p_{\theta}(x)}{d\theta} \right)^2}_F$$

$$= \int dx \left[\sqrt{p_{\theta}(x)} (\tilde{\theta}(x) - \theta) \right]^2 \cdot \int dx \left(\frac{1}{\sqrt{p_{\theta}(x)}} \frac{d p_{\theta}(x)}{d\theta} \right)^2$$

$$\stackrel{C-S}{\geq} \left(\int dx (\tilde{\theta}(x) - \theta) \frac{d p_{\theta}(x)}{d\theta} \right)^2 = \underbrace{\left(\int dx \tilde{\theta}(x) \frac{d p_{\theta}(x)}{d\theta} \right)}_{1 \quad (*)} - \underbrace{\theta \left(\int dx \frac{d p_{\theta}(x)}{d\theta} \right)}_{0 \quad (**)}$$

$$| \Delta^2 \tilde{\theta} \geq \frac{1}{F} | \quad F = \int dx \frac{1}{p_{\theta}(x)} \left(\frac{d p_{\theta}(x)}{d\theta} \right)^2$$

$$\Delta^2 \tilde{\theta} \geq \frac{1}{F} \quad \left. \begin{array}{l} F = \int dx \frac{1}{p_\theta(x)} \left(\frac{d p_\theta(x)}{d\theta} \right)^2 \\ \text{Informacja Fishera} \end{array} \right\}$$

F w ogólnosci zależy od θ

Uwaga:

Mocno spójni inne równoważne postaci F

$$F = \left\langle \left(\frac{d}{d\theta} \log p_\theta(x) \right)^2 \right\rangle = \int dx p_\theta(x) \frac{1}{p_\theta(x)^2} \left(\frac{d p_\theta(x)}{d\theta} \right)^2 = \int \frac{1}{p_\theta(x)} \left(\frac{d p_\theta(x)}{d\theta} \right)^2$$

$$F = - \left\langle \frac{d^2}{d\theta^2} \log p_\theta(x) \right\rangle$$

↑ jawnie widzi addytywność

Jesli miydeany estymator nie obciaony dla

Lotarego $\Delta^2 \tilde{\theta} = \frac{1}{F}$ wtedy je jest

optymalny. Minimum wtedy $\tilde{\theta}$ jest "eficient".

Addytywność F

Jesli $p_\theta^{(12)}(x_1, x_2) = p_\theta^{(1)}(x_1) \cdot p_\theta^{(2)}(x_2)$ wtedy

$$F^{(12)} = F^{(1)} + F^{(2)}$$

Wniosek: N niezaleznych realizacji zmiennej

losowej X : $F^{(N)} = N \cdot F$

$$\Delta^2 \tilde{\theta} \geq \frac{1}{N \cdot F}$$

Przyklad

$$x_i \sim N(\theta, \sigma^2)$$

$$i = 1, \dots, N$$

$$\dots \quad 1 \quad - \frac{(x_i - \theta)^2}{2 \sigma^2}$$

$$p_{\theta}(x_i) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x_i^2}{2\sigma^2}}$$

$$F = \left\langle \left(\frac{d}{d\theta} \log p_{\theta}(x_i) \right)^2 \right\rangle = \int p_{\theta}(x) \left(\frac{x-\theta}{\sigma^2} \right)^2 = \frac{\sigma^2}{\sigma^4} = \frac{1}{\sigma^2}$$

Mając N realizacji :

$$\Delta^2 \tilde{\theta} \geq \frac{1}{NF} = \frac{\sigma^2}{N}$$

Czyli tyle ile uzyskaliśmy z estymatorem $\tilde{\theta} = \frac{\sum x_i}{N}$
 ,
 efficient estimator

Wyszukiwanie maksimuma CR

Potrzącać na wyznaczenie maksimumu C-5 wyszczególnić:

$$\lambda(\theta) \sqrt{p_{\theta}(x)} (\hat{\theta}(x) - \theta) = \frac{1}{\sqrt{p_{\theta}(x)}} \frac{d p_{\theta}(x)}{d\theta}$$

$$\boxed{\frac{d}{d\theta} \log p_{\theta}(x) = \lambda(\theta) (\hat{\theta}(x) - \theta)}$$

Jeli między $\lambda(\theta)$, $\hat{\theta}(x)$ nie ma zależności
 spełnione wyszczególnić C-R

Przykład

$$x_i = N(\theta, \sigma^2)$$

$$p_{\theta}(x) = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i - \theta)^2}{2\sigma^2}}$$

$$\log p_{\theta}(x) = -\frac{N}{2} \log 2\pi\sigma^2 - \sum_{i=1}^N \frac{(x_i - \theta)^2}{2\sigma^2}$$

$$\frac{d}{d\theta} \log p_{\theta}(x) = \sum_{i=1}^N \frac{(x_i - \theta)}{\sigma^2} = \lambda(\theta) (\hat{\theta}(x) - \theta)$$

$$\text{jeli weźmiemy } \hat{\theta}(x) = \bar{x} = \frac{\sum x_i}{N}, \lambda(\theta) = \frac{N}{\sigma^2}$$

jeśli weźmiemy $\hat{\theta}(x) = \sum \frac{x_i}{N}$, $\lambda(\theta) = \frac{N}{\sigma^2}$

Ogólnie:

$$\log p_{\theta}(x) = \lambda(\theta) \hat{\theta}(x) + a(\theta) + b(x), \quad \begin{matrix} a' = -\lambda \cdot \theta \\ \lambda' = \lambda \end{matrix}$$

$$p_{\theta}(x) = e^{a(\theta)} e^{b(x)} e^{\lambda(\theta) \hat{\theta}(x)}$$

Szerokość rodziny tzw. exponential family

$$p_{\theta}(x) = e^{a(\theta) + b(x) + c(\theta) d(x)}$$

gdzie żeby estymacja θ była efficient $\theta = - \frac{\frac{da}{d\theta}}{\frac{dc}{d\theta}}$

Jeśli $-\frac{\frac{da}{d\theta}}{\frac{dc}{d\theta}} \neq \theta$ wtedy nie istnieje estymator θ

który jest efficient ale istnieje dla funkcji od parametru $\eta(\theta) = - \frac{\frac{da}{d\theta}}{\frac{dc}{d\theta}}$ $\hat{\eta}$

$\hat{\eta}$ estymacja θ^2 jeśli $x_i = N(\theta, \sigma^2)$