

PREDYKCJA

W BAYESOWSKIM MODELU NORMALNEJ REGRESJI LINIOWEJ

Łukasz Kwiatkowski

Katedra Ekonometrii i Badań Operacyjnych

Plan wykładu

- 1) Podstawy predykcji bayesowskiej
- 2) Predykcja w BMNRL
- 3) Przykład

Podstawy predykcji bayesowskiej 1

- Ogólne podstawy teoretyczne predykcji na gruncie bayesowskim – na razie bez kontekstu regresji
- **Wektor obserwacji niedostępnych** – podlegających prognozie, „niezaobserwowanych obserwacji”; (a także ewentualnych *braków danych* „w próbie”):

$$y^f = \begin{bmatrix} y_1^f \\ y_2^f \\ \vdots \\ y_h^f \end{bmatrix} \in Y^f \subseteq \mathbb{R}^h$$

→ W przypadku **danych przekrojowych**:

- y_i^f ($i \in \{1, 2, \dots, h\}$) – wartość zmiennej przewidywana dla jakiegoś i -tego „obiektu” (np. prognozowana cena mieszkania) – w regresji: przy **zadanych** wartościach zmiennych objaśniających, charakteryzujących ten obiekt (np. wielkość powierzchni, liczba pokoi, nr piętra)
- h – ilość takich jednocześnie rozważanych prognoz (rozważamy różne obiekty jednocześnie, np. mieszkania o różnych charakterystykach); jeżeli $h = 1$, wówczas y^f jest skalar, więc indeks i w oznaczeniu y_i^f staje się zbędny

→ W przypadku **szeregów czasowych**:

- y_i^f ($i \in \{1, 2, \dots, h\}$) – wartość zmiennej przewidywana na (zwykle) i okresów wprzód poza okres próby (and. *i-step-ahead forecast*), tak więc $y_i^f \equiv y_{T+i}$ (z reguły używa się tego ostatniego symbolu)
- h – maksymalny horyzont prognozy

Podstawy predykcji bayesowskiej 2

➤ Predykcja / Prognozowanie = wnioskowanie o y^f :

- **na gruncie klasycznym** – poprzez charakterystyki tzw. **(teorio-)próbkowego rozkładu predyktywnego**: $p(y^f | y; \theta)$, a dokładniej $p(y^f | y; \theta = \hat{\theta}) \leftarrow$ „zakotwiczony” w pojedynczym punkcie przestrzeni parametrów (ocenie θ); zatem nie uwzględnia niepewności estymacji θ :

✓ Prognoza punktowa: $\hat{y}_i^f \equiv \hat{E}(y_i^f | y; \theta = \hat{\theta}) \rightarrow$ w regresji: $\hat{y}_i^f = x_i^f \hat{\beta}$

✓ Średni błąd predykcji *ex ante*:

$$D(e_i^f) = \sqrt{s^2 \left[1 + x_i^f (X'X)^{-1} x_i^{f'} \right]},$$

gdzie $e_i^f = y_i^f - \hat{y}_i^f$ to błąd prognozy

✓ „Klasyczne” przedziały prognozy – w KMNRL: $\left(\hat{y}_i^f - t_{\frac{\alpha}{2}} \cdot D(e_i^f), \hat{y}_i^f + t_{\frac{\alpha}{2}} \cdot D(e_i^f) \right)$

- **na gruncie bayesowskim** – y^f ma tu taki sam status jak „zwykłe” parametry, θ , tj. stanowi nieobserwowalną (przynajmniej w momencie dokonywania prognozy) zmienną losową:
 - θ – zawsze nieobserwowalne
 - y^f – nieobserwowalne przynajmniej w momencie dokonywania prognozy (w przypadku prognozowania szeregów czasowych wystarczy „zaczekać”; w przypadku danych przekrojowych możemy się nigdy nie doczekać... ;)

➔ Bayesowskie wnioskowanie o y^f (= predykcja) – poprzez tzw. **(bayesowski) rozkład predyktywny**:
 $p(y^f | y)$

Podstawy predykcji bayesowskiej 3

➤ Bayesowskie wnioskowanie o y^f (predykcja) – poprzez tzw. (bayesowski) **rozkład predyktywny**:

$$p(y^f | y)$$

→ Rozkład ten:

- jest rozkładem łącznym wszystkich wielkości prognozowanych („siedzących” w y^f)
- odzwierciedla całą naszą wiedzę (niepewność!) o y^f po wglądzie w dane y (i – jak się za chwilę okaże – także z uwzględnieniem niepewności związanej z parametrami, θ)
- co do konstrukcji jest rozkładem *a posteriori* (warunkowanie względem zaobserwowanych danych), ale termin „rozkład *a posteriori*” rezerwujemy dla $p(\theta | y)$

→ Prognoza bayesowska prowadzi do wyznaczenia całego **rozkładu prawdopodobieństwa** możliwych do zaobserwowania wartości zjawiska (pod warunkiem informacji zawartej w próbie), co idealnie odpowiada paradygmatowi tzw. **prognozowania probabilistycznego** (← *currently, most trendy* ;)

→ ALE: Jak wyznaczyć rozkład predyktywny?

Podstawy predykcji bayesowskiej 4

- Model bayesowski bez predykcji [przypomnienie]:

$$p(y, \theta) = p(y|\theta)p(\theta)$$

- Model bayesowski z uwzględnieniem predykcji:

$$p(y, y^f, \theta) = \underbrace{p(y^f | y, \theta)}_{\substack{\text{(teorio-)} \\ \text{próbkowy} \\ \text{rozkład} \\ \text{predyktywny}}} \underbrace{p(y, \theta)}_{\substack{\text{model} \\ \text{bayes.} \\ \text{bez} \\ \text{predykcji}}}$$

- (Bayesowski) rozkład predyktywny:

$$p(y^f | y) = \int_{\Theta} p(y^f, \theta | y) d\theta = \int_{\Theta} p(y^f | \theta, y) \underbrace{p(\theta | y)}_{\substack{\text{rozkład} \\ \text{a post.}}} d\theta$$

→ Rozkład predyktywny jest *mieszaną* tych tzw. (teorio-)próbkowych rozkładów predyktywnych, z rozkładem *a posteriori* jako rozkładem mieszającym (różne gęstości $p(y^f | \theta, y)$ – z uwagi na możliwe różne wartości θ – są „ważone” gęstością *a posteriori* reprezentującą niepewność co do tych różnych wartości θ). Zatem – w odróżnieniu od (teorio-)próbkowego (in. „klasycznego”) – bayesowski rozkład predyktywny uwzględnia w sobie niepewność związaną z parametrami.

⇒ W konsekwencji można się spodziewać, że bayesowskie rozkłady predyktywne z reguły będą (trochę) bardziej rozproszone od tych wyznaczonych na gruncie „klasycznym” → a to dobrze czy niedobrze?!

Podstawy predykcji bayesowskiej 5

➤ Wnioskowanie o y^f – praktyka:

→ Jeżeli $h > 1$, tj. y^f jest wektorem, a nie skalar, wówczas przechodzimy na brzegowe rozkłady predykcyjne poszczególnych współrzędnych y^f :

$$p(y_i^f | y) = \int_{\mathbb{R}^{h-1}} p(y^f | y) dy_{\setminus i}^f$$

gdzie $y_{\setminus i}^f$ oznacza wektor y^f po usunięciu i -tej współrzędnej.

→ Rozkład brzegowy $p(y_i^f | y)$ uwzględnia w sobie niepewność związaną z pozostałymi współrzędnymi

→ Charakterystyka $p(y_i^f | y)$ poprzez:

▪ Predykcyjne wartości oczekiwane: $E(y_i^f | y)$

▪ Mediany predykcyjne: $Me(y_i^f | y)$

▪ Modalne predykcyjne: $Mo(y_i^f | y)$

▪ Predykcyjne odchylenia standardowe: $D(y_i^f | y)$

▪ Kwantyle predykcyjne: $Q_\alpha(y_i^f | y)$

▪ Predykcyjne przedziały kwantylowe: $\left(Q_{\frac{\alpha}{2}}(y_i^f | y), Q_{1-\frac{\alpha}{2}}(y_i^f | y) \right)$

▪ Przedziały najwyższej gęstości predykcyjnej: $HPredD(y_i^f | y)$

Bayesowskie prognozy punktowe


Przy wielookresowej prognozie szeregów czasowych, zwykle prezentowane w formie wykresu wachlarzowego

Podstawy predykcji bayesowskiej 6

➤ Wykres wachlarzowy (ang. *fan chart*, *fan plot*):

→ Termin sformułowany i spopularyzowany przez Bank Anglii w raportach prognostycznych inflacji, podawanych do informacji publicznej

→ Świetnie nadaje się do graficznej prezentacji wielookresowej, probabilistycznej prognozy szeregu czasowego (czy to bayesowskiej, czy „klasycznej”)



→ R: funkcja **fan** w bibliotece **fanplot** – wymaga wcześniejszego uzyskania losowań z rozkładu predyktywnego

→ Paleta barw – str. 2 w: <http://www.biecek.pl/R/PrzewodnikPoPakiecieRWydanieVinternet.pdf>

Predykcja w BMNRL 1

➤ Przechodzimy do modelu regresji – równanie:

1) W próbie:

- Skalarnie ($t = 1, 2, \dots, T$):

$$y_t = \beta_1 x_{t1} + \beta_2 x_{t2} + \dots + \beta_k x_{tk} + \varepsilon_t = \underbrace{[x_{t1} \ x_{t2} \ \dots \ x_{tk}]}_{\substack{x_t \\ (1 \times k)}} \underbrace{\begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{bmatrix}}_{\substack{\beta \\ (k \times 1)}} + \varepsilon_t = x_t \beta + \varepsilon_t$$

- Macierzowo: $y = X\beta + \varepsilon$

2) Poza próbą – predykcja:

- Pojedyncza współrzędna y_i^f ($i = 1, 2, \dots, h$): $y_i^f = x_i^f \beta + \varepsilon_i^f$, x_i^f – ustalony:

$$x_i^f = [x_{i1}^f \ x_{i2}^f \ \dots \ x_{ik}^f]$$

- Wektor y^f ($h \geq 1$ prognoz):

$$y^f = X^f \beta + \varepsilon^f, \quad \underbrace{X^f}_{(h \times k)} = \begin{bmatrix} x_1^f \\ \vdots \\ x_h^f \\ \text{wiersze} \end{bmatrix}, \quad \underbrace{\varepsilon^f}_{(h \times 1)} = \begin{bmatrix} \varepsilon_1^f \\ \vdots \\ \varepsilon_h^f \end{bmatrix}$$

Predykcja w BMNRL 2

➤ Model bayesowski – z predykcją:

$$p(y, y^f, \theta) = \underbrace{p(y^f | y, \theta)}_{\substack{\text{(teorio-)} \\ \text{próbkowy} \\ \text{rozkład} \\ \text{predyktywny}}} \underbrace{p(y, \theta)}_{\substack{\text{model} \\ \text{bayes.} \\ \text{bez} \\ \text{predykcji}}}$$

a tak naprawdę

$$p(y, y^f, \theta | X, X^f) = p(y^f | y, \theta, X^f) p(y, \theta | X)$$

→ dla zwięzłości zapisu pomijamy dalej warunkowanie względem X oraz X^f

→ $p(y, \theta)$ – omówiony wcześniej (4 przypadki w zależności od rozkładu *a priori*)

→ Pytanie: jak wygląda $p(y^f | y, \theta)$?

Założenia KMNRL – dotyczące rozkładu próbkowego (czyli rozkładu danych pod warunkiem parametrów) „obowiązują” dla wszystkich obserwacji – zarówno tych w próbie, jak i tych spoza niej (w przeciwnym razie model nie byłby spójny!)

Zatem skoro [przypomnienie]: $p(y | \theta) = f_N^T(y | X\beta, \tau^{-1}I_T)$,

więc $p(y^f | y, \theta) = p(y^f | \theta) = f_N^h(y^f | X^f\beta, \tau^{-1}I_h)$

Predykcja w BMNRL 3

➤ Rozkład predykcyjny [przypomnienie]:

$$p(y^f | y) = \int_{\Theta} p(y^f, \theta | y) d\theta = \int_{\Theta} p(y^f | \theta, y) \underbrace{p(\theta | y)}_{\substack{\text{rozkład} \\ \text{a post.}}} d\theta$$

→ Szczegóły odn. $p(y^f | y)$ zależą od przyjętego rozkładu *a priori*:

- 1) Reguła Jeffreysa z zależnością [RJz] – nie rozważamy...
- 2) Reguła Jeffreysa z niezależnością [RJn] – da się wyprowadzić analityczna postać $p(y^f | y)$
- 3) Gamma-normalny z zależnością [GNz] – da się wyprowadzić analityczna postać $p(y^f | y)$
- 4) Gamma-normalny z niezależnością [GNn] – $p(y^f | y)$ nie jest żadnym znanym rozkładem prawdopodobieństwa → konieczność zastosowania podejścia symulacyjnego

Ad [RJn] i [GNz]:
$$p(y^f | y) = f_{St}^h(y^f | \bar{a}^f, \bar{P}^f, \bar{n}),$$

gdzie $\bar{a}^f = X^f \bar{a}, \quad \bar{P}^f = \frac{\bar{n}}{\bar{s}} \bar{G}, \quad \bar{G} = [I_h + X^f \bar{C}^{-1} X^{f'}]^{-1},$

natomiast $\bar{a}, \bar{C}, \bar{n}, \bar{s}$ – patrz wcześniejsze wykłady (RJn i GNz):

RJn	GNz
$\bar{a} = \hat{\beta} = (X'X)^{-1}X'y$	$\bar{a} = \bar{C}^{-1}(Ca + X'X\hat{\beta})$
$\bar{C} = X'X$	$\bar{C} = C + X'X$
$\bar{n} = T - k$	$\bar{n} = n_0 + T$
$\bar{s} = S(\hat{\beta}) = (y - X\hat{\beta})'(y - X\hat{\beta})$	$\bar{s} = s_0 + y'y + a'Ca - \bar{a}'\bar{C}\bar{a}$

Predykcja w BMNRL 4

➤ Charakterystyki łącznego rozkładu predyktywnego (w przypadkach [RJn] i [GNz]):

$$p(y^f | y) = f_{St}^h(y^f | \bar{a}^f, \bar{P}^f, \bar{n})$$

$$\bar{a}^f = X^f \bar{a}, \quad \bar{P}^f = \frac{\bar{n}}{\bar{s}} \bar{G}, \quad \bar{G} = [I_h + X^f \bar{C}^{-1} X^{f'}]^{-1},$$

- $E(y^f | y) = \bar{a}^f$, dla $\bar{n} > 1$
- $Mo(y^f | y) = \bar{a}^f$ (\bar{n} – dowolne)
- mediana w przypadku rozkładów wielowymiarowych – za trudne...
- $V(y^f | y) = \frac{\bar{n}}{\bar{n}-2} \bar{P}^f = \frac{\bar{s}}{\bar{n}-2} \bar{G}^{-1}$, dla $\bar{n} > 2$ → $Var(y_i^f | y) = [V(y^f | y)]_{ii}$

Predykcja w BMNRL 5

➤ Brzegowe rozkłady predyktywne (tj. dla pojedynczych y_i^f , $i = 1, 2, \dots, h$):

$$p(y_i^f | y) = \int_{\mathbb{R}^{h-1}} p(y^f | y) dy_{\setminus i}^f = f_{St}^1(y_i^f | \bar{a}_i^f, \bar{P}_i^f, \bar{n})$$

gdzie $y_{\setminus i}^f$ oznacza wektor powstały z y^f poprzez pominięcie i -tej jego współrzędnej, \bar{a}_i^f jest i -tą współrzędną wektora \bar{a}^f , natomiast

$$\bar{P}_i^f = Prec(y_i^f | y) = \frac{\bar{n}}{\bar{n} - 2} (Var(y_i^f | y))^{-1} = \frac{\bar{n}}{\bar{s}} ([\bar{G}^{-1}]_{ii})^{-1}$$

Uwaga: $\bar{P}_i^f \neq [\bar{P}^f]_{ii}$

- Predyktywna wartość oczekiwana: $E(y_i^f | y) = \bar{a}_i^f$ dla $\bar{n} > 1$
- Modalna i mediana predyktywna: $Mo(y_i^f | y) = Me(y_i^f | y) = \bar{a}_i^f$ (\bar{n} – dowolne)
- Wariancja predyktywna: $Var(y_i^f | y) = [V(y^f | y)]_{ii}$ dla $\bar{n} > 2$
- Predyktywne odchylenie standardowe: $D(y_i^f | y) = \sqrt{Var(y_i^f | y)}$

Predykcja w BMNRL 6

➤ Brzegowe rozkłady predyktywne (tj. dla pojedynczych y_i^f , $i = 1, 2, \dots, h$):

- $H\text{Pred}D_{1-\alpha}(y_i^f) = \left(\bar{a}_i^f - t_{\frac{\alpha}{2}} \sqrt{\bar{P}_i^{f-1}}, \bar{a}_i^f + t_{\frac{\alpha}{2}} \sqrt{\bar{P}_i^{f-1}} \right)$,

gdzie $t_{\frac{\alpha}{2}}$ – dwustronna wartość kryt. w $St(0, 1, \bar{n})$:

- $\Pr(|x| \geq t_{\frac{\alpha}{2}}) = 1 - \alpha$, gdzie $x \sim St(0, 1, \bar{n})$;

- $t_{\frac{\alpha}{2}}$ w Excelu: → =ROZKŁAD.T.ODW(*prawdopodobieństwo* = α ; *stopnie_swobody* = \bar{n}) (starsza wersja)
→ =ROZKŁ.T.ODWR.DS(*prawdopodobieństwo* = α ; *stopnie_swobody* = \bar{n}) (nowsza wersja)