

Ekonometria II E

Jerzy Mycielski

16 kwietnia 2024

Normalizacja modeli dla zmiennych binarnych

- Model wyjściowy $Var(\varepsilon_i) = \sigma^2$:

$$y_i = \begin{cases} y_i = 0 & \text{dla } x_i\beta + \varepsilon_i < 0 \\ y_i = 1 & \text{dla } x_i\beta + \varepsilon_i \geq 0 \end{cases}$$

- Normalizacja modelu:

$$y_i = \begin{cases} y_i = 0 & \text{dla } x_i\frac{\beta}{\sigma} + \frac{\varepsilon_i}{\sigma} < 0 \\ y_i = 1 & \text{dla } x_i\frac{\beta}{\sigma} + \frac{\varepsilon_i}{\sigma} \geq 0 \end{cases}$$

- Te dwa modele są równoważne obserwacyjnie! Parametr σ jest nieidentyfikowalny.
- Oszacować można tylko model dla znormalizowanego $\sigma = 1$:

$$y_i = \begin{cases} y_i = 0 & \text{dla } x_i\beta^* + \varepsilon_i^* < 0 \\ y_i = 1 & \text{dla } x_i\beta^* + \varepsilon_i^* \geq 0 \end{cases}$$

Tablica klasyfikacyjna

- Liczby obserwacji, dla których przewidywany sukces ($\hat{p}_i \geq p^*$) bądź porażka ($\hat{p}_i < p^*$)
- p^* prawdopodobieństwo progowe

Prognozowane	Zaobserwowano		Razem
	0	1	
0	n_{00}	n_{01}	$n_{00} + n_{01}$
1	n_{10}	n_{11}	$n_{10} + n_{01}$
Razem	$n_{00} + n_{10}$	$n_{01} + n_{11}$	n

- Pseudo R^2 liczebnościowe:

$$R^2_{liczebnościowe} = \frac{n_{00} + n_{11}}{n},$$

- Dla modelu jedynie ze stałą zarówno probit jak i logit osiągają najwyższą wartość funkcji wiarygodności, gdy prawdopodobieństwo liczniejszej kategorii było równe 1.
- Zatem dla modelu tylko ze stałą $R^2_{liczebnościowe} = \frac{n_{\max}}{n} > 0.5$, gdzie n_{\max} jest liczebnością liczniejszej kategorii.
- Skorygowane $\bar{R}^2_{liczebnościowe}$ koryguje ten problem.

$$\bar{R}^2_{liczebnościowe} = \frac{n_{00} + n_{11} - n_{\max}}{n - n_{\max}}.$$

Wrażliwość, Specyficzność, Wartość predykcyjna

- Wrażliwość (czułość) to proporcja sukcesów prawidłowo przewidzianych do ogółu obserwacji

$$\text{czułość} = Pr(\hat{p}_i \geq p^* | y_i = 1) \approx \frac{n_{11}}{n_{01} + n_{11}}$$

- Specyficzność (swoistość)

$$\text{swoistość} = Pr(\hat{p}_i \leq p^* | y_i = 0) \approx \frac{n_{00}}{n_{00} + n_{10}}$$

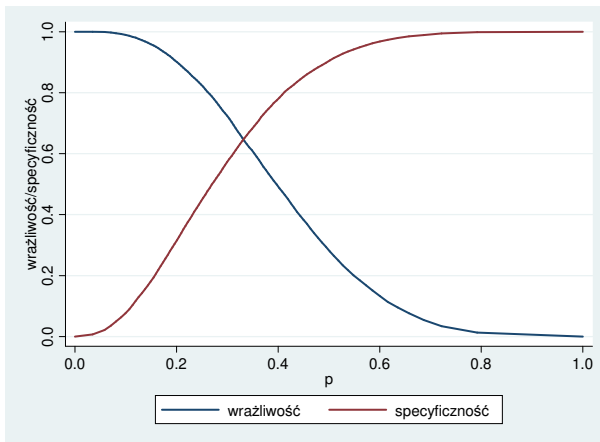
- Wartość predykcyjna

$$\text{Wartość predykcyjna dodatnia} = \frac{n_{11}}{n_{10} + n_{11}}$$


- Wartość predykcyjna ujemna

$$\text{Wartość predykcyjna ujemna} = \frac{n_{00}}{n_{00} + n_{01}}$$

Wrażliwość specyficzność



Krzywa ROC



- Standardowy wzór dla R^2 dla MNK można zapisać następująco

$$R^2 = \frac{ESS}{TSS} = \frac{ESS}{ESS + RSS} = \frac{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2 + \tilde{\sigma}^2},$$

- Analogicznie dla zmiennej ukrytej: możemy zdefiniować:

$$R^2_{McKelvey, Zavoina} = \frac{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i^* - \bar{\hat{y}}^*)^2}{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i^* - \bar{\hat{y}}^*)^2 + \tilde{\sigma}^2},$$

gdzie $\hat{y}_i^* = x_i \tilde{\beta}$.

- Probit

$$R^2_{McKelvey, Zavoina} = \frac{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i^* - \bar{\hat{y}}^*)^2}{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i^* - \bar{\hat{y}}^*)^2 + 1}$$

- Logit

$$R^2_{McKelvey, Zavoina} = \frac{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i^* - \bar{\hat{y}}^*)^2}{\frac{1}{N} \sum_{i=1}^n (\hat{y}_i^* - \bar{\hat{y}}^*)^2 + \frac{\pi^2}{3}}$$