

# Mikroekonometria

## 6

Mikołaj Czajkowski  
Wiktor Budziński

# 'Nietypowe' zmienne objaśniane

---

- ▶ Problemy mikroekonometryczne – często zmienna objaśniana nie jest ciągła lub jej wartość nie ma bezpośredniej interpretacji ilościowej
  - ▶ Zmienną objaśnianą jest jakiś wskaźnik o ocenianych wartościach – np. decyzja o zakupie, głosowanie, wybór spośród dostępnych alternatyw, deklarowany poziom jakiejś wielkości (w podanej skali) itp.
  - ▶ Wynikiem optymalizacji może być rozwiązanie brzegowe
  - ▶ Estymatory MNK nie są zgodne -> estymacja MNW



# 'Nietypowe' zmienne objaśniane

---

- ▶ Przykłady modeli dla nieciągłych zmiennych objaśnianych
  - ▶ Wybór binarny (ang. *binary choice*)
    - ▶ Wybór jednej z dwóch możliwości
      - Np. podjęcie działania czy nie – dojazd transportem publicznym, kupno ubezpieczenia
    - ▶ 0/1 oznacza nie/tak
  - ▶ Wybór wielomianowy (ang. *multinomial choice*)
    - ▶ Wybór jednej z więcej niż dwóch możliwości
      - Tej, która dostarcza największej użyteczności
      - Pozwala modelować preferencje konsumentów
      - Np. wybór marki, produktu, sposobu dojazdu do pracy
    - ▶ 0/1 oznacza nie wybraną/wybraną alternatywę

# 'Nietypowe' zmienne objaśniane

---

- ▶ Przykłady modeli dla nieciągłych zmiennych objaśnianych
  - ▶ Wybór uporządkowany (ang. *ordered choice*)
    - ▶ Wybór jednej z wielkości na podanej skali
    - ▶ Ujawnia siłę preferencji
      - Np. ocena filmu, własnego stanu zdrowia, zadowolenia z produktu, miejsce w rankingu
    - ▶ Wartości liczbowe są na skali porządkowej, nie absolutnej
      - 4 oznacza lepiej niż 2, ale niekoniecznie 2 razy lepiej
  - ▶ Liczność zdarzeń (ang. *event counts*)
    - ▶ Obserwowane są wielkości całkowite
      - Np. liczba wizyt u lekarza, w parku narodowym, na basenie, liczba zachorowań, aresztowań, dzieci, liczba wadliwych sztuk w procesie produkcyjnym w ciągu roku

# Modele binarne

---

- ▶ Obserwujemy wynik ( $Y = 0$  lub  $Y = 1$ )
- ▶ Interesuje nas jak można go przewidywać
  - ▶ Prawdopodobieństwo  $Y = 0$  / prawdopodobieństwo  $Y = 1$
  - ▶ Funkcja zmiennych objaśniających  $\mathbf{X}$ ,  $\Pr(\mathbf{Y}) = \mathbf{X}\beta$
  - ▶ Jakie powinny być parametry ( $\beta$ )?
- ▶ Jaka jest interpretacja takiego modelu?
- ▶ Jaki jest wzór na to prawdopodobieństwo, jako funkcja  $\mathbf{X}\beta$ ?
- ▶ W jaki sposób wykorzystać dane (obserwacje) do oszacowania  $\beta$ ?



# Modele binarne – modele dla zmiennej ukrytej

---

- ▶ Modele binarne można zinterpretować jako modele funkcji wskaźnikowej
  - ▶ Wyjaśniana jest losowa, ciągła zmienna  $y^*$  ale obserwowana jest tylko zmienna binarna  $y$ , która przyjmuje wartość 0 lub 1 w zależności od tego, czy  $y^*$  przekracza wartość graniczną (np., po normalizacji, 0)
    - ▶  $y^* = \boldsymbol{\beta}'\mathbf{x} + \varepsilon$
    - ▶  $y^*$  nie jest obserwowalne, obserwujemy tylko:  $y = \begin{cases} 1 & \text{jeśli } y^* > 0 \\ 0 & \text{jeśli } y^* \leq 0 \end{cases}$
    - ▶  $\Pr[y=1|\mathbf{X}] = \Pr[y^* > 0]$ 
      - $= \Pr[\boldsymbol{\beta}'\mathbf{x} + \varepsilon > 0]$
      - $= \Pr[-\varepsilon < \boldsymbol{\beta}'\mathbf{x}]$
      - $= F(\boldsymbol{\beta}'\mathbf{x})$
    - ▶  $F$  jest dystrybuantą  $\varepsilon$ 
      - Zwykle o gęstości symetrycznej względem 0
    - ▶ Pozostaje tylko wybrać odpowiedni rozkład  $\varepsilon$

# Modele binarne – normalizacja składnika losowego

---

- ▶ Wariancja przyjętego rozkładu składnika losowego nie ma znaczenia

$$y = 1 \Leftrightarrow \boldsymbol{\beta}'\mathbf{x} + \varepsilon > 0$$

- ▶  $\varepsilon$  ma średnią = 0 (jeśli model ma stałą to to też nie ma znaczenia) i jakąś wariancję  $\sigma$  (nie wiadomo jaką)
- ▶ Model będzie ten sam jeśli policzymy

$$y = 1 \Leftrightarrow \frac{\boldsymbol{\beta}'\mathbf{x}}{\sigma} + \frac{\varepsilon}{\sigma} > 0$$

- ▶ Co jest tożsame z

$$y = 1 \Leftrightarrow \boldsymbol{\gamma}'\mathbf{x} + w > 0$$

- ▶ Gdzie  $w$  to jakiś rozkład o średniej 0 i wariancji 1
- ▶ Można przyjąć wariancję = 1, przeskalują się tylko parametry, model ten sam
- ▶ Normalizacja wariancji (lub jednego z parametrów) jest konieczna dla identyfikowalności modelu

# Logit / probit

---

- ▶ Typowo zakładane – składnik losowy ( $\varepsilon$ ) ma rozkład:

- ▶ Logistyczny

$$f(x) = \frac{\exp\left(-\frac{x-\mu}{\sigma}\right)}{\sigma \left(1 + \exp\left(-\frac{x-\mu}{\sigma}\right)\right)^2}$$

- ▶ Normalny

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

- ▶ Zakładamy rozkład standardowy ( $\mu = 0, \sigma = 1$ )

- ▶ Nie ma to znaczenia, bo najwyżej parametry  $\beta$  będą większe, żeby poziom 'losowości' był odpowiedni

- ▶ Dystrybuanta

$$\Lambda(x) = \frac{\exp(x)}{1 + \exp(x)}$$

- ▶ Dystrybuanta

$$\Phi(x) = \int_{-\infty}^x \phi(z) dz$$

- ▶ Mamy wzór na Pr, który możemy wykorzystać w estymacji!

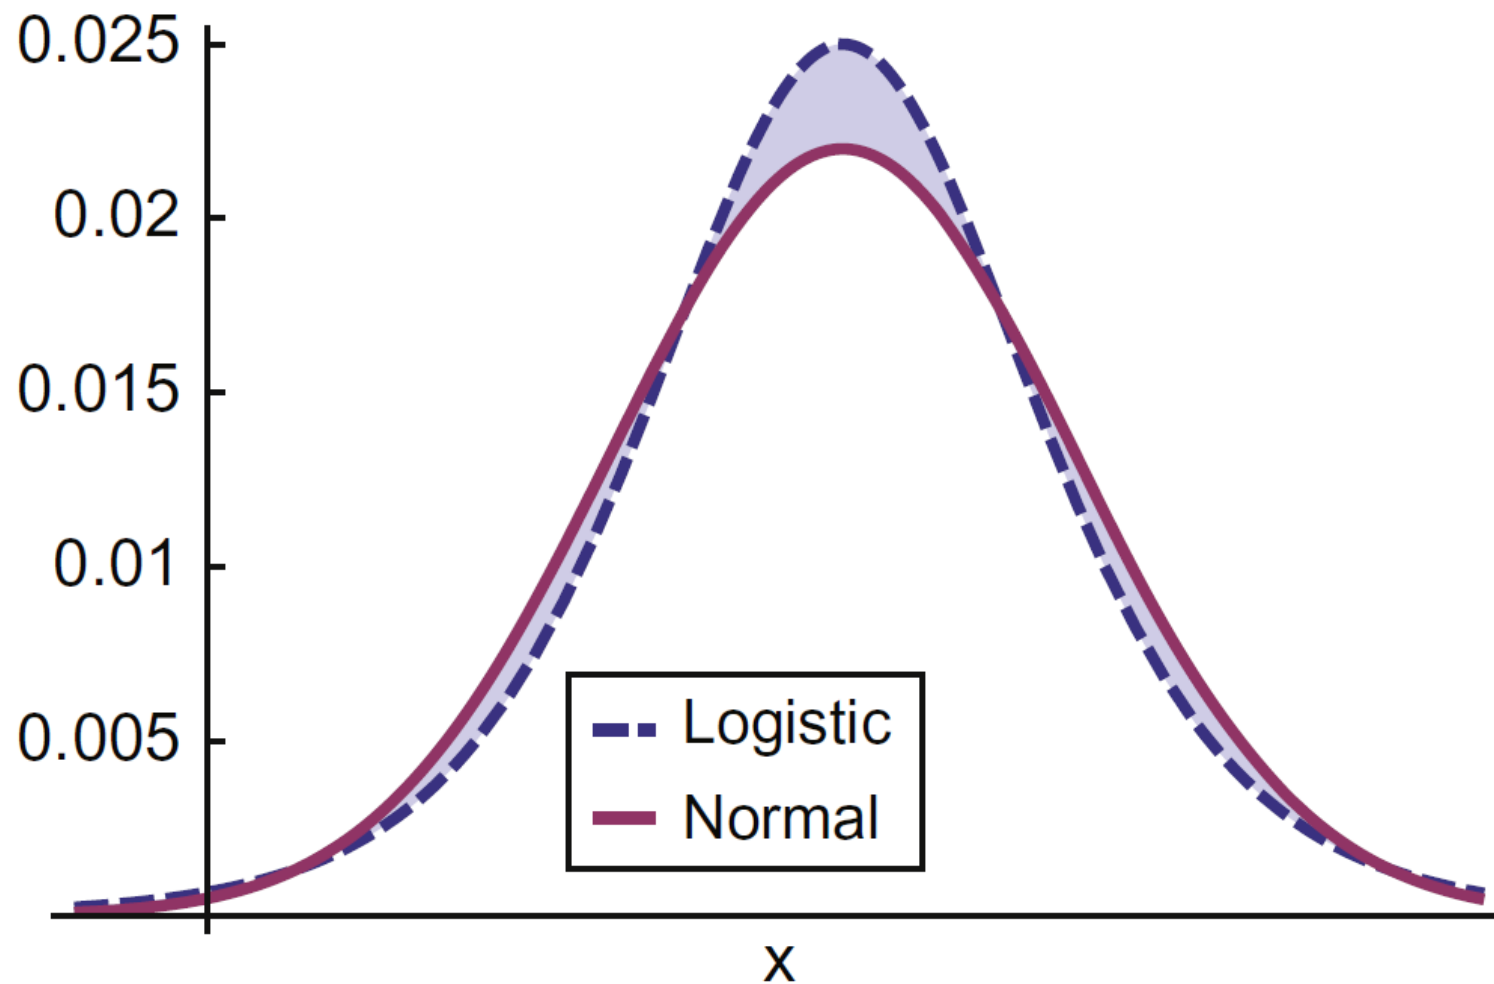
- ▶ -> Model logit

- ▶ -> Model probit




# Rozkład logistyczny vs. normalny

---



# Logit / probit / liniowy model prawdopodobieństwa



# Logit / probit – który wybrać?

---

- ▶ Rozkład logistyczny – przypomina normalny (symetryczny dzwon, trochę grubsze ogony), ale ma wzór na dystrybuantę w postaci zamkniętej
  - ▶ Upraszcza obliczenia / umożliwia rozwiązanie analityczne
  - ▶ Pozwala interpretować parametry jako stosunek log-oddsów
- ▶ Probit
  - ▶ Może być bardziej uzasadniony w przypadku normalnego rozkładu zmiennej ukrytej
- ▶ Praktycznie nie ma różnicy
  - ▶ Istnieją testy dla porównywania niezagnieżdżonych modeli, ale w tym przypadku prawie zawsze nie dają jednoznacznego wyniku
  - ▶ Ponieważ logit ma grubsze ogony, w próbach w których obserwacje są bardzo niesymetryczne (znacznie więcej 0 lub 1) lub jest bardzo duża wariancja ważnej zmiennej objaśniającej – różnice mogą być większe

# Logit / probit – parametry

---

- ▶ Ponieważ logit i probit wykorzystują różne funkcje prawdopodobieństwa, oszacowania parametrów będą różne

- ▶ Jako 'reguła kciuka':

$$\hat{\beta}_{\text{logit}} \approx 4\hat{\beta}_{\text{MNK}}$$

$$\hat{\beta}_{\text{probit}} \approx 2,5\hat{\beta}_{\text{MNK}}$$

$$\hat{\beta}_{\text{logit}} \approx 1,6\hat{\beta}_{\text{probit}}$$

- ▶ Ale to oczywiście bardziej skomplikowane
- ▶ Absolutne wartości parametrów i tak nie mają znaczenia
  - ▶ Nie tak jak w MNK!
  - ▶ Dlaczego? Bo parametry wykorzystywane w skomplikowanych funkcjach obliczających prawdopodobieństwo
  - ▶ Jeśli już, to lepiej porównywać *efekty krańcowe* (pochodne)
    - Jak zmienne objaśniające wpływają na zmianę prawdopodobieństwa danego wyboru


# Logit / probit i inne modele dla wyboru binarnego

---

- ▶ Inne rozkłady składnika losowego, które nie zakładają symetryczności:
  - ▶ Gumbel, Gompit, Gompertz ( $\varepsilon$  ma rozkład wartości ekstremalnych)  
 $CDF(x) = \exp(-\exp(-x))$
  - ▶ *Complementary log log*  
 $CDF(x) = 1 - \exp(-\exp(-x))$
  - ▶ I inne (np. arctangens, burr (scobit), ...)
  - ▶ Wyniki mogą się czasem znacznie różnić od wyników logitu i probitu
  - ▶ Przydatne, gdy jeden z wyników jest rzadki
    - ▶ Np. mały odsetek 'tak' w próbie

# Standardowy rozkład wartości ekstremalnych

---



# Estymacja – metoda największej wiarygodności

---

- ▶ Zaobserwowaliśmy  $(Y_i, \mathbf{X}_i)$ , dla  $i = 1, \dots, N$
- ▶ Zmienna zależna ( $Y_i$ ) ma rozkład Bernoulliego (binarny z 1 powtórzeniem)

- ▶ Funkcja prawdopodobieństwa masy

$$f(Y_i | \mathbf{X}_i) = p_i^{Y_i} (1 - p_i)^{1 - Y_i}$$

- ▶ Co się dzieje z tą funkcją gdy  $Y_i = 1$ ? A gdy  $Y_i = 0$ ?
  - ▶ Zawsze dostajemy  $p_i$  lub  $(1 - p_i)$
- ▶ U nas  $p_i = F(\boldsymbol{\beta}'\mathbf{X}_i)$  więc

$$f(Y_i | \mathbf{X}_i) = F(\boldsymbol{\beta}'\mathbf{X}_i)^{Y_i} (1 - F(\boldsymbol{\beta}'\mathbf{X}_i))^{1 - Y_i}$$

# Estymacja – metoda największej wiarygodności

---

- ▶ Funkcja prawdopodobieństwa masy

$$f(Y_i | \mathbf{x}_i) = F(\boldsymbol{\beta}'\mathbf{x}_i)^{Y_i} (1 - F(\boldsymbol{\beta}'\mathbf{x}_i))^{1-Y_i}$$

- ▶ Obserwacje są niezależne. Jaka jest szansa, że dostaniemy taki zbiór obserwacji, jaki mamy?

$$L(\boldsymbol{\beta} | \text{dane}) = \prod_{i=1}^N F(\boldsymbol{\beta}'\mathbf{x}_i)^{Y_i} (1 - F(\boldsymbol{\beta}'\mathbf{x}_i))^{1-Y_i}$$

- ▶ Funkcja wiarygodności (ang. *likelihood function*)
- ▶ Chcemy znaleźć takie  $\boldsymbol{\beta}$ , żeby zmaksymalizować tę funkcję
  - ▶ Czyli, żeby nasz model miał takie parametry, żeby przewidywał takie prawdopodobieństwa, które dają największą szansę takiego wyniku, jaki dostaliśmy



# Estymacja – metoda największej wiarygodności

---

- ▶ Szukamy maksimum funkcji wiarygodności:

$$L(\boldsymbol{\beta} | \text{dane}) = \prod_{i=1}^N F(\boldsymbol{\beta}'\mathbf{x}_i)^{Y_i} (1 - F(\boldsymbol{\beta}'\mathbf{x}_i))^{1-Y_i}$$

- ▶ Jest ono w tym samym punkcie, co maksimum logarytmu z funkcji wiarygodności (logarytm to funkcja monotonicznie rosnąca), a wygodniej maksymalizować coś takiego:

$$\ln L(\boldsymbol{\beta} | \text{dane}) = \sum_{i=1}^N (Y_i \ln F(\boldsymbol{\beta}'\mathbf{x}_i) + (1 - Y_i) \ln(1 - F(\boldsymbol{\beta}'\mathbf{x}_i)))$$

- ▶ W praktyce – dość prosto się liczy
  - Dla każdej obserwacji wziąć prawdopodobieństwo uzyskanego wyniku (tak lub nie)
  - Zsumować
  - Zmaksymalizować funkcję po  $\boldsymbol{\beta}$

# Estymacja – metoda największej wiarygodności


---

- ▶ Estymację robią za nas zwykle pakiety statystyczne 😊
  - ▶ Ale jak widać jest to dość proste, da się policzyć na piechotę
- ▶ Hesjan modelu logit/probit jest ujemnie określony
  - ▶ Funkcja LL jest globalnie wklęsła
  - ▶ Istnieje globalne maksimum
- ▶ Estymator MNW jest zgodny
  - ▶ Estymator MNK nie jest
- ▶ Parametry mają asymptotyczny rozkład normalny
- ▶ Asymptotyczna macierz wariancji-kowariancji (ang. *asymptotic variance covariance matrix*, AVC) może być oszacowana jako odwrotność hesjanu dla optymalnych oszacowań MNW
  - ▶ Stąd mamy błędy standardowe parametrów

# Zadanie 1. – Posiadanie kochanka

---

1. Wczytaj projekt `me.affairs.dta`
  - ▶ Dane z ankiety 6366 mężatek (magazyn *Redbook*)
2. Ile % kobiet w próbie miało kiedykolwiek romans?
3. Sprawdź, jakie zmienne mogą pomóc to przewidywać
4. Porównaj wyniki z Liniowym Modelem Prawdopodobieństwa



# Wartość funkcji LL zawsze ujemna

---

- ▶ Funkcja LL:

$$\ln L(\boldsymbol{\beta} | \text{dane}) = \sum_{i=1}^N (Y_i \ln F(\boldsymbol{\beta}'\mathbf{x}_i) + (1 - Y_i) \ln(1 - F(\boldsymbol{\beta}'\mathbf{x}_i)))$$

- ▶ Logarytm z prawdopodobieństwa (<1) zawsze ujemny
  - ▶ Funkcja LL zawsze ujemna
  - ▶ Osiąga teoretyczne maksimum w 0

## Zadanie 2. – Zakup eko-jabłek

1. Wczytaj projekt me.apples.dta
2. Oszacuj model, w którym gotowość do zakupu dodatnich ilości eko-jabłek wyjaśniana jest przez:
  - ▶ Poziom edukacji respondenta
  - ▶ Cenę zwykłych jabłek
  - ▶ Cenę eko-jabłek
  - ▶ To, czy wybór dokonywany jest w sezonie
  - ▶ To czy respondent był mężczyzną
  - ▶ Dochód rodziny
  - ▶ Liczbę członków rodziny w każdej kategorii wiekowej
3. Co dzieje się z modelem, jeśli dodatkowo uwzględnić wielkość rodziny?



# Pomiar 'dopasowania' modelu

---

- ▶ Po estymacji modelu zwykle raportowane są:
  - ▶ Wartość funkcji LL w optimum (w punkcie konwergencji)
  - ▶ Wartość funkcji LL 'w 0' (model wykorzystujący tylko stałą)
    - ▶ Odpowiada założeniu, że wszystkie parametry w modelu nieistotne
- ▶ Nie ma miary  $R^2$  z MNK
- ▶ Pewnym rozwiązaniem jest Pseudo- $R^2$  (kilka wersji)
  - ▶ Miary oparte na wartości funkcji LL (wiele wersji):
    - ▶ McFadden's pseudo- $R^2 = \frac{1 - \ln L(\boldsymbol{\beta})}{\ln L(\mathbf{Y})} = 1 - \ln L / \ln L_0 \in [0, 1)$
    - ▶ Im model lepiej dopasowany tym  $R^2$  bliższe 1
      - Ale przedział między 0 a 1 nie ma interpretacji naturalnej
        - Nie wiemy, gdzie jest zero
        - Z powodu istnienia składnika losowego model nie osiąga 1

# Pomiar 'dopasowania' modelu

---

- ▶ Kryterium informacyjne Akaike (AIC)

$$AIC = 2k - 2\ln L(\boldsymbol{\beta})$$

- ▶ AIC skorygowane (dla skończonej próby)

$$AICc = AIC + \frac{2k(k+1)}{N-k-1}$$

- ▶ Bayesowskie kryterium informacyjne (BIC, Schwarz)

$$BIC = k\ln N - 2\ln L(\boldsymbol{\beta})$$

- ▶ Znormalizowane – podzielone przez  $N$
- ▶ Jak w modelu liniowym – nie jest to kryterium 'statystycznego' porównania, ale często używane
  - ▶ Mówi, który model lepiej pasuje do danych
  - ▶ Nie mówi czy dobrze, o ile lepiej i czy istotnie lepiej
  - ▶ W porównaniu z pseudo- $R^2$  przynajmniej bierze pod uwagę liczbę zmiennych objaśniających

# Pomiar 'dopasowania' modelu

---

- ▶ Miary oparte na przewidywaniu wyników
  - ▶ Tabela poprawnych i niepoprawnych predykcji
    - ▶ Błędy I i II typu – trade-off
    - ▶ Ile % poprawnych predykcji ma naiwna reguła  $Y_i = 1$ ?
- ▶ Miary oparte na przewidywaniu prawdopodobieństw
  - ▶ BenAkiva i Lerman's pseudo- $R^2 = \frac{1}{N} \sum_{i=1}^N (Y_i \hat{F}(\mathbf{x}_i \boldsymbol{\beta}) + (1 - Y_i)(1 - \hat{F}(\mathbf{x}_i \boldsymbol{\beta})))$ 
    - ▶ Średnie prawdopodobieństwo poprawnych predykcji
    - ▶ Problem gdy obserwacje w próbie są niesymetryczne



## Zadanie 2. – Zakup eko-jabłek c.d.

---

4. Wypróbuj inne modele dla zmiennych binarnych
  - ▶ Probit
  - ▶ Scobit
  - ▶ Complementary log-log
5. Porównaj dopasowanie wykorzystując różne miary



# Praca domowa ME.6 – wydatki na lekarza w USA

---

1. Wczytaj projekt `me.usahealth.dta`
2. Sprawdź czy następujące zmienne mogą pomóc przewidzieć, czy ktoś poniósł jakieś wydatki medyczne (tzn. czy zmienna *med* jest większa niż 0)
  - ▶ Udział własny w kosztach opieki medycznej (zmienna *coins*)
  - ▶ Stan zdrowia
  - ▶ Czynniki socjodemograficzne
3. Wypróbuj różne modele dla zmiennych binarnych i wybierz najlepszy
4. Wykorzystaj wybrane przekształcenia nieliniowe, w celu poprawy dopasowania (LL) wybranego modelu
  - ▶ Do przygotowania w grupach trzyosobowych

```
set seed 10+"Nr indeksu"  
sample 90, by(coins)
```

