

Mikroekonometria

7

Mikołaj Czajkowski

Wiktor Budziński

Testowanie hipotez

▶ 3 podstawowe testy

▶ Przedział ufności

- ▶ Parametry mają asymptotyczny rozkład normalny
- ▶ Znamy błąd standardowy
- ▶ Czy parametr jest statystycznie różny od k (np. od 0)?

▶ Test LR – iloraz wartości funkcji największej wiarygodności

- ▶ Czy restrykcja prowadzi do istotnego pogorszenia LL?

▶ Test Walda


- ▶ Czy estymator z restrykcjami nadal jest statystycznie istotny?



Hipotezy proste, a hipotezy złożone

- ▶ Hipotezą prostą nazywamy hipotezę w postaci np.: $H_0^1 : \beta_1 = 0$
- ▶ Hipotezą złożoną natomiast: $H_0^1 : \beta_1 = 0, H_0^2 : \beta_2 = 0, \dots, H_0^K : \beta_K = 0$
- ▶ Testowanie osobno kilku hipotez prostych nie jest równoważne testowaniu jednej hipotezy złożonej
- ▶ Rozważmy prosty przypadek, kiedy statystyki testowe dla hipotez prostych są od siebie niezależne. Jeśli poziom istotności (p-stwo popełnienia błędu I rodzaju) jest równe α dla każdej z hipotez prostych to dla hipotezy złożonej wynosi ono: $\alpha^* = 1 - (1 - \alpha)^K \rightarrow 1$
- ▶ Różnicę $\alpha^* - \alpha$ nazywa się obciążeniem Lovella
- ▶ Dlatego lepiej opierać wybór modelu o hipotezy złożone

Testowanie hipotez



Istotność parametrów

▶ Istotność parametrów

$$z = \frac{|\hat{\beta} - \beta_0|}{\hat{\sigma}_{\hat{\beta}}}$$

- ▶ Błędy standardowe z AVC
- ▶ Wartość krytyczna z rozkładu standardowego normalnego
 - ▶ A nie t-studenta jak w regresji liniowej i MNK
- ▶ H_0 : Parametr = β_0
 - ▶ Duże wartości absolutne statystyki z (małe p-value) => parametr jest istotnie różny od β_0 (np. od 0) na zadanym poziomie istotności
- ▶ W STATA – wyniki podawane automatycznie po estymacji dla każdego parametru

Test LR

▶ LR test

- ▶ LR – *likelihood ratio*
- ▶ Iloraz wartości funkcji największej wiarygodności

$$LR = -2(\ln \hat{L}_R - \ln \hat{L}_U)$$

- ▶ Nakładamy jakieś restrykcje na parametry
 - ▶ *R* i *U* – *restricted, unrestricted* (test tylko dla modeli zagnieżdżonych)
 - ▶ Model z restrykcjami zawsze jest nie lepszy niż model bez restrykcji, a więc $LR > 0$
- ▶ Wartość krytyczna z rozkładu chi-kwadrat z liczbą stopni swobody równą liczbie restrykcji (w formie równań)
- ▶ H_0 : Restrykcje nie pogarszają istotnie modelu
 - ▶ Duże wartości statystyki LR (małe p-value) – odrzucamy restrykcje (bo istotnie pogarszają model)
- ▶ Wymaga estymacji modelu bez i z ograniczeniami

Zadanie 1. Eko-jabłka

1. Czy każdy parametr jest istotny na poziomie 5%? 1%?
2. Czy wszystkie parametry łącznie są istotne?
3. Porównaj twój wynik z tym raportowanym przez STATA po estymacji
 - ▶ Można zastosować do dowolnych zagnieżdżonych modeli
 - ▶ Podobny do testu F z regresji liniowej

Test Walda

▶ Test Walda

- ▶ Idea: jeśli $\mathbf{X} \sim MVN_J(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ to $(\mathbf{X} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{X} - \boldsymbol{\mu}) \sim \chi_J^2$
 - ▶ Jeśli $E(\mathbf{X}) = \boldsymbol{\mu}$ to wyrażenie ma rozkład chi-kwadrat z J stopniami swobody
 - ▶ Jeśli $E(\mathbf{X}) \neq \boldsymbol{\mu}$ to wyrażenie ma niecentralny rozkład chi-kwadrat
 - Leży na prawo => daje większe wartości statystyki
- ▶ Dla zbioru restrykcji $H_0: \mathbf{c}(\boldsymbol{\theta}) = \mathbf{q}$
 - ▶ Jeśli są prawdziwe, to $\hat{\boldsymbol{\theta}}$ powinien je spełniać
 - ▶ Jeśli nie, to $\mathbf{c}(\hat{\boldsymbol{\theta}}) - \mathbf{q}$ będzie dalej od $\mathbf{0}$
- ▶ Statystyka testu Walda

$$W = (\mathbf{c}(\hat{\boldsymbol{\theta}}) - \mathbf{q})' \left(AVC(\mathbf{c}(\hat{\boldsymbol{\theta}}) - \mathbf{q}) \right)^{-1} (\mathbf{c}(\hat{\boldsymbol{\theta}}) - \mathbf{q}) \sim \chi_J^2$$

Test Walda

- ▶ Intuicyjnie – czy estymator z restrykcjami nadal jest statystycznie istotny?
- ▶ H_0 : Restrykcje nie pogarszają istotnie modelu
 - ▶ Duże wartości statystyki W (małe p-value) – odrzucamy restrykcje (bo istotnie pogarszają model)
- ▶ Nie wymaga estymacji modelu z ograniczeniami
 - ▶ Choć trzeba wyznaczyć AVC dla estymatora z restrykcjami

$$A\hat{V}C(\mathbf{c}(\hat{\boldsymbol{\theta}}) - \mathbf{q}) = \frac{\partial \mathbf{c}(\hat{\boldsymbol{\theta}})}{\partial \hat{\boldsymbol{\theta}}'} A\hat{V}C(\hat{\boldsymbol{\theta}}) \left(\frac{\partial \mathbf{c}(\hat{\boldsymbol{\theta}})}{\partial \hat{\boldsymbol{\theta}}'} \right)'$$

- ▶ Działa dla nieliniowych restrykcji
 - ▶ Dla liniowych $\mathbf{R}'\boldsymbol{\theta} = \mathbf{q}$ prościej

$$W = (\mathbf{R}'\hat{\boldsymbol{\theta}} - \mathbf{q})' (\mathbf{R}'A\hat{V}C[\hat{\boldsymbol{\theta}}]\mathbf{R})^{-1} (\mathbf{R}'\hat{\boldsymbol{\theta}} - \mathbf{q})$$

Test Walda

- ▶ Jeśli $c(\hat{\theta})=q$ jest pojedynczą restrykcją – test Walda działa tak samo jak statystyka z i test przedziału ufności

$$H_0 : \theta = \theta_0$$

$$H_1 : \theta \neq \theta_0$$

$$W = \left((\hat{\theta} - \theta_0) - 0 \right) AVC \left((\hat{\theta} - \theta_0) - 0 \right)^{-1} \left((\hat{\theta} - \theta_0) - 0 \right) = \frac{(\hat{\theta} - \theta_0)^2}{AVC(\hat{\theta})} = z^2 \quad z = \frac{|\hat{\theta} - \theta_0|}{\hat{\sigma}_{\hat{\theta}}}$$

- ▶ Statystyka W ma rozkład chi-kwadrat z 1 stopniem swobody, czyli rozkład kwadratu statystyki standardowej normalnej
- ▶ Wada: test nie jest niewrażliwy na sformułowanie restrykcji
 - ▶ Np. dla przetestowania, czy $\beta/(1-\gamma)=q$ jest równe q można testować $\beta/(1-\gamma)-q=0$ lub $\beta-q(1-\gamma)=0$ – mają różne AVC
- ▶ Zaleta: nie wymaga dodatkowych założeń o rozkładach (jak statystyki LR i LM)

Zadanie 1. Eko-jabłka c.d.

4. Czy ceny zwykłych jabłek i eko-jabłek mają tę samą siłę oddziaływania (choć w przeciwną stronę)?
5. Czy cena eko-jabłek ma inny wpływ na mężczyzn niż na kobiety?
 - ▶ Zbadaj wykorzystując test LR
 - ▶ Zbadaj wykorzystując test Walda
 - ▶ Wymaga wymuszenia równości lub określonej wartości parametrów w STATA

Testowanie hipotez – zastosowania

Homogeniczność prób

▶ Testowanie homogeniczności prób

$$\chi^2 = 2 \left(\sum_{n=1}^{\text{liczba grup}} LL_n - LL_{\text{cała próba}} \right)$$

- ▶ Statystyka testu ma rozkład chi-kwadrat z liczbą stopni swobody równą (liczbie parametrów) * (liczbie grup – 1)
 - ▶ To samo można uzyskać dodając do modelu interakcje parametrów ze zmiennymi binarnymi dla grup i testując ich łączną istotność (np. wykorzystując test LR lub Walda)
6. Sprawdź, czy mężczyźni mają inne preferencje niż kobiety, jeśli chodzi o decyzje dotyczące zakupu ekoproduktów

Niepoprawność założeń modelu binarnego – skutki

- ▶ **W modelach regresji liniowej:** $y = \beta'X + \gamma'Z + \varepsilon$
 - ▶ Pominięte zmienne (**Z**) – o ile **X** i **Z** nie są ortogonalne, lub $\gamma = 0$ – estymator β jest obciążony
 - ▶ Heteroskedastyczność – o ile ε nie jest homoskedastyczny (wariancja składnika losowego nie jest równa dla różnych obserwacji) – estymator OLS jest nadal nieobciążony i zgodny, ale jest nieefektywny
- ▶ **W modelach binarnych**
 - ▶ Pominięte zmienne – nawet jeśli pominięte zmienne są nieskorelowane z tymi uwzględnionymi w modelu – estymator ML nie jest zgodny
 - ▶ Heteroskedastyczność – estymator ML nie jest zgodny
 - ▶ A to duży problem, bo dane mikro często są heteroskedastyczne

Niepoprawność założeń modelu binarnego

- ▶ Analogicznie jak w regresji liniowej można testować poprawność formy funkcyjnej
 - ▶ Test zamiast RESET nazywa się LINKTEST
 - ▶ Estymujemy model: $y^* = \mathbf{X}\boldsymbol{\beta} + \varepsilon$
 - ▶ Liczymy wartości dopasowane: $\hat{y} = \mathbf{X}\hat{\boldsymbol{\beta}}$
 - ▶ Liczymy regresję pomocniczą: $y^* = \alpha_0 + \alpha_1\hat{y} + \alpha_2\hat{y}^2 + \alpha_3\hat{y}^3 + \dots + \varepsilon$
 - ▶ Testujemy łączną istotność $\alpha_2, \alpha_3, \dots$
- 7. Sprawdź poprawność formy funkcyjnej analizowanego modelu logistycznego
 1. Wykorzystaj polecenie wbudowane w STATA
 2. Policz 'na piechotę'

Niepoprawność założeń modelu binarnego

- ▶ Heteroskedastyczność można analizować analogicznie jak w przypadku modelu regresji liniowej
 - ▶ Wcześniej używaliśmy modelu ARCH
 - ▶ Tutaj możemy wykorzystać probit z heteroskedastycznością
 - ▶ Liczymy model: $y_i^* = \mathbf{X}_i \boldsymbol{\beta} + \sigma_i \varepsilon$
 - ▶ Wcześniej zakładaliśmy, że $\forall_i \sigma_i = 1$
 - ▶ Teraz $\sigma_i = \exp(\mathbf{Z}_i \boldsymbol{\alpha})$
- 8. Sprawdź czy w analizowanym modelu występuje dająca się wyjaśnić heteroskedastyczność

Praca domowa ME.7

1. Wykorzystaj zbiór danych *me.usahealth.dta* i zbuduj model binarny, w którym zmienną objaśnianą będzie to czy respondent poniósł jakiegokolwiek wydatki medyczne ($med > 0$).
2. Przetestuj wybrane przez siebie hipotezy stosując następujące testy :
 - ▶ Test przedziału ufności
 - ▶ LR test (proszę nie testować tutaj łącznej istotności zmiennych w modelu)
 - ▶ Test Walda
 - ▶ Przetestuj homogeniczność podprób
 - ▶ Linktest
 - ▶ Testowanie heteroskedastyczności
3. Zinterpretuj uzyskane wyniki
 - ▶ Testy nie powinny dotyczyć „losowych” hipotez
 - ▶ Do przygotowania w grupach dwuosobowych

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

