

# Το Υπόδειγμα Probit

18 Μαΐου 2026

# Οικονομική θεμελίωση: απόφαση ως σύγκριση ωφελειών I

Θεωρούμε έναν οικονομικό δρώντα που επιλέγει μεταξύ δύο εναλλακτικών:

$$d \in \{0, 1\}$$

Ορίζουμε τις αντίστοιχες ωφέλειες:

$$U_i(1), \quad U_i(0)$$

**Κανόνας απόφασης:**

$$Y_{(i)} = 1 \iff U_i(1) > U_i(0)$$

Ορίζουμε τη διαφορά ωφελειών:

$$Y_{(i)}^* = U_i(1) - U_i(0)$$

## Γραμμική εξειδίκευση:

$$Y_{(i)}^* = X_{(i)}\beta_0 + \varepsilon_{(i)}$$

όπου:

- $X_{(i)}$ : παρατηρήσιμα χαρακτηριστικά (εισόδημα, εκπαίδευση κ.λπ.)
- $\beta$ : παράμετροι που μετρούν επίδραση
- $\varepsilon_{(i)}$ : μη παρατηρήσιμοι παράγοντες (προτιμήσεις, πληροφορία-πηγές ετερογένειας)

## Παρατηρήσιμη μεταβλητή:

$$Y_{(i)} = \mathbf{1}\{Y_{(i)}^* > 0\}$$

**Κεντρική ιδέα:** Παρατηρούμε μόνο την (διακριτή) επιλογή, όχι τη ωφέλεια.

Από:

$$Y_{(i)} = \mathbf{1}\{X_{(i)}\beta_0 + \varepsilon_{(i)} > 0\}$$

έχουμε:

$$\mathbb{P}(Y_{(i)} = 1 | X_n) = \mathbb{P}(\varepsilon_{(i)} > -X_{(i)}\beta)$$

Προφανώς η μορφή της παραπάνω πιθανότητας (και του αντίστοιχου στατιστικού υποδείγματος) καθορίζεται από την κατανομή του  $\varepsilon_{(i)}$ :

- $\varepsilon_{(i)} | X_n \sim N(0, 1) \Rightarrow$  Probit
- $\varepsilon_{(i)} | X_n \sim \text{Logistic} \Rightarrow$  Logit

**Κεντρική ιδέα:**

Κατανομή σφάλματος  $\Rightarrow$  μορφή πιθανοτήτων

# Ταυτοποίηση στο Probit: το πρόβλημα

Θεωρούμε το μη παρατηρήσιμο υπόδειγμα:

$$Y_{(i)}^* = X_{(i)}\beta + \varepsilon_{(i)}, \quad Y_{(i)} = \mathbf{1}\{Y_{(i)}^* > 0\}, \quad \beta \in \Theta$$

Παρατηρούμε μόνο:

$$Y_{(i)} = \mathbf{1}\{X_{(i)}\beta + \varepsilon_{(i)} > 0\}$$

**Κρίσιμο σημείο:** η απόφαση εξαρτάται μόνο από το πρόσημο του  $Y_{(i)}^*$ .

Για κάθε  $c > 0$ :

$$\mathbf{1}\{X_{(i)}\beta + \varepsilon_{(i)} > 0\} = \mathbf{1}\{cX_{(i)}\beta + c\varepsilon_{(i)} > 0\}$$

**Κεντρική ιδέα:** Το υπόδειγμα είναι **αναλλοίωτο στην κλίμακα (scale invariance)**.

Από την προηγούμενη ιδιότητα η διακύμανση της δεσμευμένης κατανομής του  $\varepsilon_{(i)}$  δεν είναι ταυτοποιήσιμη.

## Διαισθητικά:

- μόνο το σχετικό μέγεθος  $X_{(i)}\beta$  ως προς το  $\varepsilon_{(i)}$  έχει σημασία
- η απόλυτη κλίμακα δεν παρατηρείται

## Κανονικοποίηση:

$$\text{Var}(\varepsilon_{(i)}|n) = 1$$

και περαιτέρω (υποθέτουμε και δεσμευμένη ανεξαρτησία και ομοιογένεια-θα μπορούσαμε να το γενικεύσουμε):

$$\varepsilon_n|X_n \sim N(\mathbf{0}_n, I_{n \times n})$$

# Εξαγωγή της πιθανοφάνειας I

Από τα παραπάνω έχουμε

$$\mathbb{P}(Y_{(i)} = 1 \mid X_n) = \Phi(X_{(i)}\beta), \quad \mathbb{P}(Y_{(i)} = 0 \mid X_n) = 1 - \Phi(X_{(i)}\beta),$$

$$\text{με } \Phi(X_{(i)}\beta) := \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{X_{(i)}\beta} \exp(-\frac{1}{2}z^2) dz.$$

Επειδή  $Y_{(i)} \in \{0, 1\}$ , η υπό συνθήκη πιθανότητα της παρατήρησης  $Y_{(i)}$  γράφεται ενιαία ως

$$\mathbb{P}(Y_{(i)} \mid X_n; \beta) = \Phi(X_{(i)}\beta)^{Y_{(i)}} [1 - \Phi(X_{(i)}\beta)]^{1-Y_{(i)}}.$$

Αρα, υπό την υπό συνθήκη ανεξαρτησία η από κοινού κατανομή του δείγματος  $Y_n$  δεδομένων των  $X_n$  αν η πραγματική τιμή της παραμέτρου ήταν το  $\beta$  είναι η,

$$L_n(\beta) = \prod_{i=1}^n \Phi(X_{(i)}\beta)^{Y_{(i)}} [1 - \Phi(X_{(i)}\beta)]^{1-Y_{(i)}}.$$

Λαμβάνοντας λογαρίθμους και ολοκληρώνοντας ως προς την εμπειρική κατανομή:

$$\ell_n(\beta) = \frac{1}{n} \sum_{i=1}^n [Y_{(i)} \log \Phi(X_{(i)}\beta) + (1 - Y_{(i)}) \log(1 - \Phi(X_{(i)}\beta))] .$$

Ο εκτιμητής μέγιστης πιθανοφάνειας ορίζεται ως

$$\hat{\beta} \in \arg \max_{\beta \in \Theta} \ell_n(\beta).$$

**Άρα:**

- το κριτήριο προκύπτει από την πιθανοθεωρητική δομή του μοντέλου,
- το πρόβλημα είναι μη γραμμικό και η λύση δεν έχει κλειστή μορφή.

Θέλουμε:

$$\hat{\beta} \in \arg \max_{\beta \in \Theta} \ell_n(\beta)$$

$$\ell_n(\beta) = \frac{1}{n} \sum_{i=1}^n [Y_{(i)} \log \Phi(X_{(i)}\beta) + (1 - Y_{(i)}) \log(1 - \Phi(X_{(i)}\beta))]$$

**Παράγωγος:** (χρήσιμο π.χ. όταν  $\Theta = \mathbb{R}^p$ )

$$\nabla \ell_n(\beta) = \frac{1}{n} \sum_{i=1}^n \frac{(Y_{(i)} - \Phi(X_{(i)}\beta))\phi(X_{(i)}\beta)}{\Phi(X_{(i)}\beta)(1 - \Phi(X_{(i)}\beta))} X'_{(i)}$$

## Εσσιανή μήτρα:

- περιλαμβάνει μεταξύ άλλων παρονομαστές της μορφής

$$\Phi(X_{(i)}\beta)^2, (1 - \Phi(X_{(i)}\beta))^2$$

οι οποίοι μπορεί να γίνουν αριθμητικά πολύ μικροί για μεγάλες θετικές ή αρνητικές τιμές του  $X'_{(i)}\beta$  οπότε είναι δυνατόν να εμφανίζονται προβλήματα αριθμητικής ευστάθειας

## Newton-Raphson:

$$\beta_{k+1} = \beta_k - [\nabla^2 \ell_n(\beta_k)]^{-1} \nabla \ell_n(\beta_k)$$

με προβολή στο  $\Theta$  αν δεν είναι πλήρης.

- χρησιμοποιεί την πλήρη Εσσιανή
- τοπική τετραγωνική προσέγγιση του κριτηρίου
- πολύ γρήγορη σύγκλιση κοντά στο βέλτιστο
- ευαίσθητος στην επιλογή αρχικής τιμής

## Fisher Scoring:

- αντικαθιστά την Εσσιανή με την εμπειρική μήτρα πληροφοριών

$$\frac{1}{n} \sum_{i=1}^n \frac{\phi^2(\mathbf{X}_{(i)}\beta)}{\Phi(\mathbf{X}_{(i)}\beta)(1 - \Phi(\mathbf{X}_{(i)}\beta))} \cdot \mathbf{X}'_{(i)}\mathbf{X}_{(i)}$$

# Quasi-Newton (BFGS) και σύγκριση

## BFGS:

- γενικότερα προσεγγίζει την Εσσιανή χωρίς τον υπολογισμό δεύτερων παραγώγων

## Πλεονεκτήματα:

- υψηλή σταθερότητα
- καλή απόδοση σε μεσαία/μεγάλα δείγματα

	Μέθοδος	Ταχύτητα	Σταθερότητα	Κόστος
<b>Σύγκριση:</b>	Newton	πολύ υψηλή	μέτρια	υψηλό
	Fisher	υψηλή	υψηλή	μέτριο
	BFGS	καλή	πολύ υψηλή	χαμηλό

**Trade-off:** ταχύτητα σύγκλισης vs υπολογιστική σταθερότητα

# Υπολογιστική δομή του Probit MLE I

Σε κάθε επανάληψη ενός αλγορίθμου (π.χ. BFGS / Newton) υπολογίζουμε:

## 1. Τιμές γραμμικού δείκτη:

$$z_i = X_{(i)}\beta \Rightarrow \mathcal{O}(np)$$

## 2. Πιθανότητες και πυκνότητες:

$$\Phi(z_i), \phi(z_i) \Rightarrow \mathcal{O}(n)$$

## 3. Gradient:

$$\nabla \ell_n(\beta) = \sum_{i=1}^n X_{(i)} \cdot w_i \Rightarrow \mathcal{O}(np)$$

(Newton μόνο) Υπολογισμός Εσσιανής:

$$\nabla^2 \ell_n(\beta) \Rightarrow \mathcal{O}(np^2)$$

**Συνολικό κόστος ανά iteration:**

$$\mathcal{O}(np) \quad (\text{BFGS}) \quad \mathcal{O}(np^2) \quad (\text{Newton})$$

**Αριθμός επαναλήψεων:**

20 – 50 (τυπικά)

**Συνολικό αριθμητικό κόστος:**

$$\mathcal{O}(np^* \times \# \text{ επαναλήψεις}), \quad p^* = p \text{ (BFGS)}, \quad p^* = p^2 \text{ (Newton)}$$

Οι υπολογισμοί μπορεί να επιβαρύνονται από την ύπαρξη περιορισμών όταν  $\Theta \subset \mathbb{R}^p$ .

# Python snippet: Probit MLE (BFGS)

```
import numpy as np
from scipy.stats import norm
from scipy.optimize import minimize

def probit_loglik(beta, X, y):
    z = X @ beta
    p = norm.cdf(z)

    # numerical stability
    eps = 1e-8
    p = np.clip(p, eps, 1 - eps)

    ll = y * np.log(p) + (1 - y) * np.log(1 - p)
    return -np.sum(ll) # negative log-likelihood

def estimate_probit(X, y):
    p = X.shape[1]
    beta0 = np.zeros(p)

    res = minimize(probit_loglik, beta0,
                  args=(X, y),
                  method="BFGS")

    return res.x

# usage:
# beta_hat = estimate_probit(X, y)
```

$$Y_n^* = X_n \beta_0 + \varepsilon_n, \quad \varepsilon \sim N(0, 1)$$

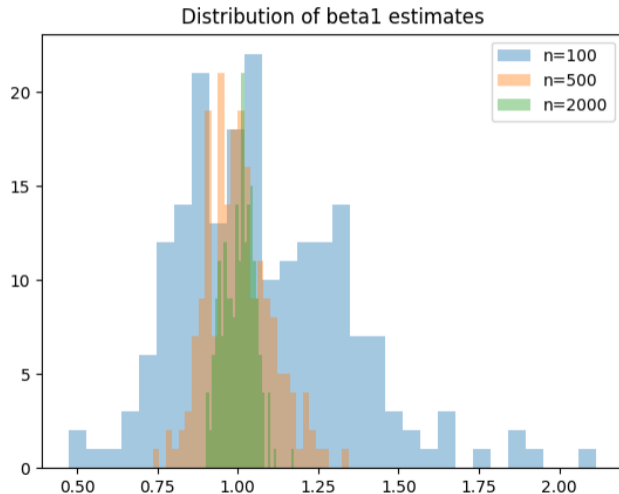
$$\beta_0 = (1, 1)$$

- $\Theta = \mathbb{R}^2$
- $X = (\mathbf{1}, N(\mathbf{0}_n, I_{n \times n}))$  ανεξάρτητα του  $\varepsilon$
- $n = 100, 500, 2000$
- 200 MC επαναλήψεις
- βελτιστοποίηση με BFGS

$n$	$\bar{\beta}_0$	$\bar{\beta}_1$	$\sigma_0$	$\sigma_1$
100	1.071	1.081	0.230	0.268
500	1.007	1.002	0.087	0.101
2000	1.004	1.004	0.041	0.048

**Διακρίνεται:** σύγκλιση προς  $\beta_0$

# Monte Carlo I: εμπειρική κατανομή εκτιμητή



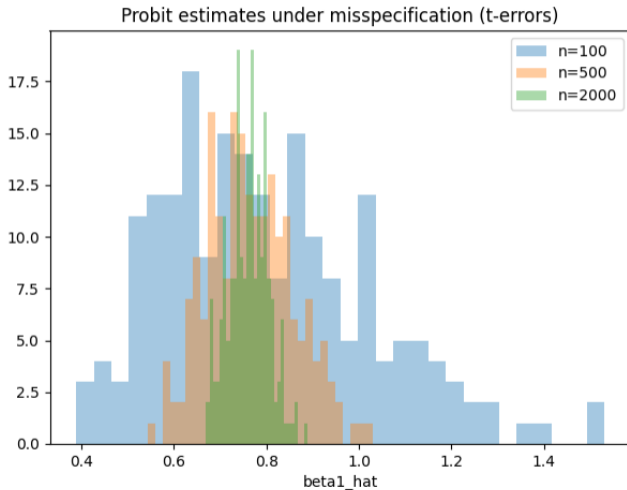
$$\varepsilon \sim t(3)$$

εκτίμηση: Probit

**Κεντρική ιδέα:** το υπόδειγμα κακώς εξειδικευμένο

$n$	$\bar{\beta}_0$	$\bar{\beta}_1$	$\sigma_0$	$\sigma_1$
100	0.800	0.801	0.189	0.224
500	0.784	0.766	0.074	0.092
2000	0.787	0.761	0.040	0.043

# Monte Carlo II: εμπειρική κατανομή εκτιμητή



# Ψευδο-αληθής (pseudo-true) τιμή της παραμέτρου

$$\hat{\beta} \rightarrow \beta^* \neq \beta_0$$

$$\beta^* = \arg \max \mathbb{E}[\log f(Y|X, \beta)]$$

**Κεντρική ιδέα:** KL-τύπου προβολή στην εγγύτερη κατανομή στο στατιστικό υπόδειγμα.

- 200 βελτιστοποιήσεις
- κάθε βελτιστοποίηση  $\approx 0.01 - 0.03 \text{ sec}$

Συνολικός χρόνος:

2 – 6 δευτερόλεπτα

## Hardware:

- σε τυπικό laptop (i5 / M1)