



NATIONAL RESEARCH  
UNIVERSITY

# Лекция по эконометрике № 5, 3 модуль

## Модели бинарного выбора

Демидова

Ольга Анатольевна

[https://www.hse.ru/staff/demidova\\_olga](https://www.hse.ru/staff/demidova_olga)

E-mail: [demidova@hse.ru](mailto:demidova@hse.ru)

11.02.2022

- 1) Модели с бинарной зависимой переменной**
- 2) Модель линейной вероятности, ее недостатки**
- 3) Логит и Пробит модели, их оценивание**
- 4) Интерпретация результатов оценивания моделей с бинарными зависимыми переменными**
- 5) Показатели качества оценки моделей бинарного выбора**

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i, i = 1, \dots, n,$$
$$Y_i = 1 \text{ или } 0$$

**Примеры бинарных переменных:**

**После школы пойти учиться или работать?**

**Купить квартиру или арендовать?**

**Участвовать в выборах или нет?**

**И т.д. и т.п.**

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i, i = 1, \dots, n,$$

$$Y_i = E(Y_i) + \varepsilon_i$$

**Найдем математическое ожидание  $Y_i$ .**

$$p_i = p(Y_i = 1), p(Y_i = 0) = 1 - p_i,$$

$$E(Y_i) = 1 \times p_i + 0 \times (1 - p_i) = p_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki},$$

$$p_i = p(Y_i = 1) = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}$$

$$p_i = p(Y_i = 1) = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}$$

**Если мы будем оценивать модель с качественной зависимой переменной, как и ранее, с помощью МНК, мы получим указанную выше модель, называемую моделью линейной вероятности.**

**Однако линейная вероятностная модель имеет ряд серьезных недостатков:**

- **Одним из главных недостатков линейной вероятностной модели является следующий : оцененные значения вероятности могут оказаться больше 1 или меньше 0.**

$$p_i = p(Y_i = 1) = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}$$

**Однако линейная вероятностная модель имеет ряд серьезных недостатков:**


- **Распределение случайного члена не является нормальным,**
- **Можно показать, что дисперсия случайного члена зависит от  $X$ , таким образом, имеет место проблема гетероскедастичности.**

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i, i = 1, \dots, n,$$

$$p(Y_i = 1) = P(\varepsilon_i = 1 - \beta_0 - \beta_1 X_{1i} - \dots - \beta_k X_{ki}) = p_i,$$

$$p(Y_i = 0) = P(\varepsilon_i = 0 - \beta_0 - \beta_1 X_{1i} - \dots - \beta_k X_{ki}) = 1 - p_i$$

# Модели бинарного выбора



Главным недостатком модели линейной вероятности являлась возможность для оцененных значений зависимой переменной принимать значение вне интервала (0, 1).

Обычным способом решения этой проблемы является предположение о том, что вероятность является S – образной функцией от переменной  $Z$ ,  $F(Z)$  принимает значения на интервале (0, 1), где  $Z$  является линейной функцией от объясняющих переменных.

# Модели бинарного выбора

**Другой способ получения модели:**

$$P(Y_i = 1) = F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}), i=1, \dots, n, (*)$$

**Предположим, что существует латентная переменная  $Y_i^*$ , связанная с переменной  $X$  обычным регрессионным уравнением:**

$$Y_i^* = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i, i=1, \dots, n,$$

**где возмущения  $\varepsilon_i, i=1, \dots, n$ , независимы и одинаково распределены,**

**$E(\varepsilon_i) = 0, \text{var}(\varepsilon_i) = \sigma^2$ , и  $F$  – функция распределения нормированных возмущений с симметричной функцией плотности.**

$$Y_i = 1, \text{ если } Y_i^* \geq 0, i=1, \dots, n,$$

$$Y_i = 0, \text{ если } Y_i^* < 0, i=1, \dots, n$$

# Модели бинарного выбора

$$P(Y_i = 1) = F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}) (*),$$

$$Y_i^* = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i, i=1, \dots, n,$$

$$Y_i = 1, \text{ если } Y_i^* \geq 0, i=1, \dots, n,$$

$$Y_i = 0, \text{ если } Y_i^* < 0, i=1, \dots, n$$

$$\begin{aligned} \text{Тогда } P(Y_i = 1) &= P(Y_i^* \geq 0) = P(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon_i \geq 0) = \\ &= P(\varepsilon_i \geq -\beta_0 - \beta_1 X_{1i} - \dots - \beta_k X_{ki}) = P(\varepsilon_i \leq \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}) = \\ &= P(\varepsilon_i / \sigma \leq (\beta_0 / \sigma) + (\beta_1 / \sigma) X_{1i} + \dots + (\beta_k / \sigma) X_{ki}) = \\ &= F((\beta_0 / \sigma) + (\beta_1 / \sigma) X_{1i} + \dots + (\beta_k / \sigma) X_{ki}) \end{aligned}$$

**что с точностью до нормировки совпадает с (\*).**


# Оценка параметров модели бинарного выбора

$$\begin{aligned}
 L(\beta) &= \prod_{Y_i=1} P(Y_i = 1) \prod_{Y_i=0} P(Y_i = 0) = \\
 &= \prod_{Y_i=1} F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}) \prod_{Y_i=0} (1 - F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})) = \\
 &= \prod_{i=1}^n [F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})]^{Y_i} [1 - F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})]^{1-Y_i} = \\
 l(\beta) &= \ln L(\beta) = \sum_{i=1}^n [Y_i \ln F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}) + \\
 &+ (1 - Y_i) \ln(1 - F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}))]
 \end{aligned}$$

Необходимые условия экстремума первого порядка

$$\frac{\partial l(\beta)}{\partial \beta_j} = \sum_{i=1}^n X_{ji} \left[ \begin{array}{l} \frac{f(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})}{F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})} Y_i + \\ + (1 - Y_i) \frac{(-f(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}))}{1 - F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})} \end{array} \right] = 0,$$

$j = 0, \dots, k$



$$P(Y=1) = F(Z) = \Lambda(Z) = \frac{1}{1+e^{-Z}}$$

**Если функция  $F$  является логистической (формула для этой функции приведена выше), то соответствующая модель называется логит - моделью.**

$$f(z) = F'(Z) = \frac{e^{-Z}}{(1+e^{-Z})^2} - \text{функция плотности для логит-модели.}$$

## Оценка параметров логит-модели

$$l(\beta) = \ln L(\beta) = \sum_{i=1}^n [Y_i \ln F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}) + (1 - Y_i) \ln(1 - F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}))]$$

Для логит-модели необходимые условия экстремума первого порядка

$$\frac{\partial l(\beta)}{\partial \beta_j} = \sum_{i=1}^n X_{ji} \left[ \begin{array}{l} \frac{f(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})}{F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})} Y_i + \\ + (1 - Y_i) \frac{(-f(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}))}{1 - F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})} \end{array} \right] = 0$$

могут быть сведены к виду:  $\sum_{i=1}^n [Y_i - \Lambda(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})] X_{ji} = 0$ ,

Матрица Гессе для логит-модели является отрицательно определенной (детали см.

Green, издание 7, с.691-692), поэтому найденное решение является максимумом.

Если функция плотности является функцией плотности стандартного нормального распределения

$$f(z) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{1}{2}z^2\right\},$$

$$F(Z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z \exp\left\{-\frac{1}{2}x^2\right\} dx,$$

То  $P(Y=1) = F(Z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z \exp\left\{-\frac{1}{2}x^2\right\} dx$  называется пробит-моделью.

Матрица Гессе для пробит-модели является отрицательно определенной (детали см. Green, издание 7), поэтому найденное решение

$$\frac{\partial l(\beta)}{\partial \beta_j} = \sum_{i=1}^n X_{ji} \left[ \begin{array}{l} \frac{f(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})}{F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})} Y_i + \\ + (1 - Y_i) \frac{(-f(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki}))}{1 - F(\beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki})} \end{array} \right] = 0$$

является максимумом.

# Пример использования ЛОГИТ-МОДЕЛИ

Пример использования логит – модели для оценки вероятности окончания средней школы. В качестве объясняющей выбрана переменная *ASVABC* (обобщенные результаты тестов).

**GRAD = 1**, если респондент закончил школу и **0** иначе.

```
. logit GRAD ASVABC
```

```
Iteration 0:   log likelihood = -118.67769
Iteration 1:   log likelihood = -104.45292
Iteration 2:   log likelihood = -97.135677
Iteration 3:   log likelihood = -96.887294
Iteration 4:   log likelihood = -96.886017
```

Logit estimates

```
Number of obs   =          540
LR chi2(1)      =          43.58
Prob > chi2     =          0.0000
Pseudo R2      =          0.1836
```

Log likelihood = -96.886017

GRAD	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ASVABC	.1313626	.022428	5.86	0.000	.0874045	.1753206
_cons	-3.240218	.9444844	-3.43	0.001	-5.091373	-1.389063

# Пример использования ЛОГИТ-МОДЕЛИ

```
. logit GRAD ASVABC
```

```
Iteration 0:   log likelihood = -118.67769
Iteration 1:   log likelihood = -104.45292
Iteration 2:   log likelihood = -97.135677
Iteration 3:   log likelihood = -96.887294
Iteration 4:   log likelihood = -96.886017
```

Logit estimates

```
Number of obs   =           540
LR chi2(1)      =           43.58
Prob > chi2     =           0.0000
Pseudo R2      =           0.1836
```

Log likelihood = -96.886017

GRAD	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ASVABC	.1313626	.022428	5.86	0.000	.0874045	.1753206
_cons	-3.240218	.9444844	-3.43	0.001	-5.091373	-1.389063

Для проверки значимости коэффициентов используется z – статистика, поскольку оценки МП имеют (асимптотически) нормальное распределение.

LR статистика используется для проверки совместной значимости коэффициентов при выбранных факторах (всех, кроме константы).

# Пример использования пробит-модели

```
. probit GRAD ASVABC SM SF MALE
```

```
Iteration 0: log likelihood = -118.67769
Iteration 1: log likelihood = -98.195303
Iteration 2: log likelihood = -96.666096
Iteration 3: log likelihood = -96.624979
Iteration 4: log likelihood = -96.624926
```

Probit estimates

```
Number of obs = 540
LR chi2(4) = 44.11
Prob > chi2 = 0.0000
Pseudo R2 = 0.1858
```

Log likelihood = -96.624926

GRAD	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ASVABC	.0648442	.0120378	5.39	0.000	.0412505	.0884379
SM	-.0081163	.0440399	-0.18	0.854	-.094433	.0782004
SF	.0056041	.0359557	0.16	0.876	-.0648677	.0760759
MALE	.0630588	.1988279	0.32	0.751	-.3266368	.4527544
_cons	-1.450787	.5470608	-2.65	0.008	-2.523006	-.3785673

# Интерпретация результатов оценки моделей бинарного выбора

$$P(Y = 1) = F(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k),$$

$\frac{\partial p}{\partial X_j} = \frac{dp}{dZ} \frac{\partial Z}{\partial X_j} = f(Z)\beta_j$  - предельный эффект непрерывной объясняющей переменной  $X_j$ , зависит от точки, в которой этот эффект рассчитывается.

$$\frac{\partial p}{\partial X_j} = \frac{dp}{dZ} \frac{\partial Z}{\partial X_j} = f(Z)\beta_j = \frac{e^{-Z}}{(1+e^{-Z})^2} \beta_j - \text{для логит-модели}$$

$$\frac{\partial p}{\partial X_j} = \frac{dp}{dZ} \frac{\partial Z}{\partial X_j} = f(Z)\beta_j = \left( \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}Z^2} \right) \beta_j - \text{для пробит-модели}$$

$\frac{\partial p}{\partial X_j} = p(X_1, X_2, \dots, X_j = 1, \dots, X_k) - p(X_1, X_2, \dots, X_j = 0, \dots, X_k)$  - предельный эффект, если  $X_j$  – думми переменная).

# Пример вычисления предельного эффекта

```
. sum GRAD ASVABC
```

Variable	Obs	Mean	Std. Dev.	Min	Max
GRAD	540	.9425926	.2328351	0	1
ASVABC	540	<b>51.36271</b>	9.567646	25.45931	66.07963

В рассмотренном примере **средний результат ASVABC равен 51.36.**

Logit estimates

Number of obs = 540

LR chi2(1) = 43.58

Prob > chi2 = 0.0000

Pseudo R2 = 0.1836

Log likelihood = -96.886017

GRAD	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
ASVABC	.1313626	.022428	5.86	0.000	.0874045	.1753206
_cons	-3.240218	.9444844	-3.43	0.001	-5.091373	-1.389063

# Пример вычисления предельного эффекта

```
. sum GRAD ASVABC
```

Variable	Obs	Mean	Std. Dev.	Min	Max
GRAD	540	.9425926	.2328351	0	1
ASVABC	540	51.36271	9.567646	25.45931	66.07963

Logit estimates

Number of obs = 540  
 LR chi2(1) = 43.58  
 Prob > chi2 = 0.0000  
 Pseudo R2 = 0.1836

Log likelihood = -96.886017

GRAD	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
ASVABC	.1313626	.022428	5.86	0.000	.0874045 .1753206
_cons	-3.240218	.9444844	-3.43	0.001	-5.091373 -1.389063

$$Z = -3.240 + 0.131 \times 51.36 = 3.507$$

В этой точке  $Z$  равно 3.507

# Пример вычисления предельного эффекта

```
. sum GRAD ASVABC
```

Variable	Obs	Mean	Std. Dev.	Min	Max
GRAD	540	.9425926	.2328351	0	1
ASVABC	540	51.36271	9.567646	25.45931	66.07963

GRAD	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
ASVABC	.1313626	.022428	5.86	0.000	.0874045 .1753206
_cons	-3.240218	.9444844	-3.43	0.001	-5.091373 -1.389063


$$Z = -3.240 + 0.131 \times 51.36 = 3.507$$

$$e^{-Z} = e^{-3.507} = 0.030$$

$$f(Z) = \frac{dp}{dZ} = \frac{e^{-Z}}{(1 + e^{-Z})^2} = \frac{0.030}{(1 + 0.030)^2} = 0.028$$

$$\frac{\partial p}{\partial X_i} = \frac{dp}{dZ} \frac{\partial Z}{\partial X_i} = f(Z) \beta_i = 0.028 \times 0.131 = 0.004$$

**Предельный эффект для имеющего средний результат тестирования равен 0.004. Это означает, что при увеличении результата тестирования *ASVABC* на 1 балл вероятность закончить школу возрастает на 0.4 процента.**



**Предельный эффект при среднем результате очень мал. Это связано с тем, что вероятность закончить школу при средних результатах и так очень велика.**

# Интерпретация результатов оценки моделей бинарного выбора

- 1) С помощью предельных эффектов (чаще всего в точке средних значений (не очень хорошо для дамми-переменных) или средний эффект по всем наблюдениям)
- 2) С помощью отношения шансов (только для логит-модели)
- 3)  $P(Y_i = 1) = \frac{1}{1+e^{-z}}$ ,  $P(Y_i = 0) = \frac{e^{-z}}{1+e^{-z}}$ ,

Отношение шансов (odd ratio)  $OR = \frac{P(Y_i = 1)}{P(Y_i = 0)} = e^z = \exp\{\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k\}$  ,

$$\ln(OR) = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k$$

Если  $X_j$  изменится на 1 единицу, то OR изменится в  $\exp\{\beta_j\}$  раз.

# Использование моделей бинарного выбора для прогноза

$\hat{p} = \hat{P}(Y_i = 1) = F(\hat{\beta}_0 + \hat{\beta}_1 X_1 + \dots + \hat{\beta}_k X_k)$  – оценка вероятности, что  $Y = 1$ .


$$\hat{Y}_i = \begin{cases} 1, & \text{если } \hat{p} \geq c \text{ (cutoff),} \\ 0, & \text{если } \hat{p} < c \end{cases}$$

Обычно  $c = 0.5$

Чувствительность (Sensitivity) – доля правильно идентифицированных 1,

Специфичность (Specificity) – доля правильно идентифицированных 0.

Пример:




# Показатели качества оценки моделей бинарного выбора

Classified	True		Total
	D	~D	
+	793	397	1190
-	943	1789	2732
Total	1736	2186	3922

Classified + if predicted  $\Pr(D) \geq .5$   
 True D defined as male  $\neq 0$

Sensitivity	$\Pr(+   D)$	45.68%
Specificity	$\Pr(-   \sim D)$	81.84%
Positive predictive value	$\Pr(D   +)$	66.64%
Negative predictive value	$\Pr(\sim D   -)$	65.48%
False + rate for true ~D	$\Pr(+   \sim D)$	18.16%
False - rate for true D	$\Pr(-   D)$	54.32%
False + rate for classified +	$\Pr(\sim D   +)$	33.36%
False - rate for classified -	$\Pr(D   -)$	34.52%
Correctly classified		65.83%

ROC – кривая (ROC – received operating characteristics)



$AUC = 0.5$  – модель не лучше случайного гадания,

$AUC < 0.5$  – модель хуже случайного гадания

Чувствительность (Sensitivity) – доля правильно идентифицированных 1,

Специфичность (Specificity) – доля правильно идентифицированных 0.

$R_{MF}^2$  –  $R^2$  МакФаддена (McFadden) определяется формулой:

$R_{MF}^2 = 1 - \frac{\hat{l}}{l_0}$ , где  $\hat{l}$  - максимум логарифмической функции правдоподобия для рассматриваемой модели,  $l_0$  - максимум логарифмической функции правдоподобия для модели, в которую включена только константа.

Псевдо  $R^2$  (Amemiya, 1981):

$$Pseudo R^2 = 1 - \frac{1}{1 + \frac{2}{n}(\hat{l} - l_0)}$$

# Показатели качества оценки моделей бинарного выбора

Доля неверных прогнозов вычисляется по формуле:¶

$$wr_1 = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 . ¶$$

Эта доля неверных прогнозов интересна в сравнении с долей неверных прогнозов самой простой бинарной модели, в которую включена только константа. Для этой простой модели прогнозы строятся совсем просто:¶

$$\begin{aligned} \hat{Y}_i &= 1, \text{ если } \hat{p} > 0.5, \text{ где } \hat{p} \text{ — доля единиц в выборке, } ¶ \\ \hat{Y}_i &= 0, \text{ если } \hat{p} \leq 0.5. \end{aligned}$$

Доля неверных прогнозов для простой модели вычисляется так:¶

$$\begin{cases} wr_0 = 1 - \hat{p}, & \text{если } \hat{p} > 0.5, \\ wr_0 = \hat{p}, & \text{если } \hat{p} \leq 0.5. \end{cases} ¶$$

Отметим, что пороговое значение 0.5 иногда изменяют, чтобы достичь более высокой точности предсказания.¶

Показатель качества подгонки модели рассчитывается по формуле:¶

$$R_p^2 = 1 - \frac{wr_1}{wr_0} . ¶$$



NATIONAL RESEARCH  
UNIVERSITY

# Thank you for your attention!

20, Myasnitskaya str., Moscow, Russia, 101000  
Tel.: +7 (495) 628-8829, Fax: +7 (495) 628-7931  
[www.hse.ru](http://www.hse.ru)