

ЛЕКЦИЯ 20

МОДЕЛИ БИНАРНОГО ВЫБОРА

Часть I

1. Когда целесообразно применять модели бинарного выбора? Несколько примеров
2. Линейная модель вероятности. Проблемы, связанные с ее использованием
3. Logit-модель
4. Probit-модель

Когда целесообразно применять модели бинарного выбора? Несколько примеров

Ранее в качестве зависимой переменной Y мы предполагали некий количественный признак, который может принимать непрерывное множество значений.

Кроме того, в классической регрессионной модели предполагалось, что ошибки имеют стандартное нормальное распределение.

В то же время часто бывает, что зависимая переменная является дискретной.

Примеры:

- Покупать ли автомобиль;
- Идти ли на выборы;

- Способ попадания из дома на работу (пешком, на метро, наземным общественным транспортом или на личном автомобиле);
- Выбрать ли для отдыха авиа – или автобусный тур;
- Переехать ли на постоянное место жительства в другой регион и т.п.

Если есть только два возможных значения зависимой переменной, то такие модели будут называться моделями бинарного выбора.

Для таких моделей зависимая переменная, которая может иметь нечисловую переменную, принимает значения 0 или 1.

Формально применение МНК для таких моделей возможно, но есть несколько «подводных камней».

Рассмотрим линейную вероятностную модель и те проблемы, которые возникают при ее интерпретации.

Линейная вероятностная модель

Linear probability model

В рамках этой модели:

$$Y_t = \begin{cases} 1, & \text{если событие произошло;} \\ 0, & \text{если не произошло.} \end{cases}$$

$$Y_i = \beta_1 + \beta_2 X_i + u_i, \quad E(u_i) = 0$$

$$Y_i = E(Y_i|X_i) + u_i$$

Таким образом, мы представляем Y как сумму детерминированной части и случайного возмущения. Пока формально все как и прежде.

Но: Y может принимать только два значения 0 и 1.


Найдем математическое ожидание Y :

$$\begin{aligned} E(Y_i) &= 0 \cdot P(Y_i = 0) + 1 \cdot P(Y_i = 1) = \\ &= 0 \cdot (1 - p_i) + 1 \cdot p_i = p_i \end{aligned}$$

Откуда, $p_i = \beta_1 + \beta_2 X_i$

Значит, выражение $\beta_1 + \beta_2 X_i$ имеет смысл вероятности, и, следовательно, значения выражения должны лежать в пределах $[0; 1]$

Графическое представление:



Основные недостатки линейной вероятностной модели:

- Остатки распределены не нормально: их распределение и вовсе является дискретным

Если $Y_i = 1$, то $u_i = 1 - \beta_1 - \beta_2 X_i$

Если же $Y_i = 0$, то $u_i = -\beta_1 - \beta_2 X_i$

- Дисперсия остатков зависит от значений регрессора:

$$Var(u_i) = (\beta_1 + \beta_2 X_i)(1 - \beta_1 - \beta_2 X_i)$$

!!!! Выведите формулу для дисперсии в качестве упражнения самостоятельно, составив предварительно

закон распределения для u_i

Это обозначает, что у нас есть проблема гетероскедастичности, следовательно, оценки параметров, полученные обычным МНК, больше не будут эффективными, и желательно тогда пользоваться ОМНК.

- Коэффициент β_1 практически всегда является неинтерпретируемым.
- Поскольку $\beta_1 + \beta_2 X_i$ имеет смысл вероятности, то мы не должны выходить за пределы $[0; 1]$, а напрямую в эту модель не заложены никакие ограничения. Следовательно, необходимо наложить либо ограничения

на регрессор, либо на параметры, чтобы остаться в рамках $[0; 1]$

В силу перечисленных недостатков, линейная вероятностная модель редко находит применение на практике.

Основные предположения, лежащие в основе logit- и probit-моделей

Обойти проблемы линейной модели можно, сделав несколько предположений:

Предположим, что

$$P(Y_i = 1) = F(\beta_1 + \beta_2 X_i),$$

где F есть некоторая функция, у которой область значений лежит в пределах $[0; 1]$

Естественно предположить, что в качестве такой функции может быть использована функция распределения некоторой случайной величины.

Зададим эту функцию путем введения латентной (ненаблюдаемой) переменной

$$Y_i^* = \beta_1 + \beta_2 X_i + \varepsilon_i, \quad \varepsilon_i \sim iid(0; \sigma^2), \quad i = 1, \dots, n \quad (*)$$

Причем:

$Y_i = 1$, если $Y_i^* \geq 0$, $i = 1, \dots, n$;

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

В модели (*) мы ввели, что ошибки независимы и одинаково распределены.

Определим в дальнейшем, что F будет функцией распределения нормированной случайной ошибки, причем функция плотности является симметричной.

Тогда

$$\begin{aligned}
P(Y_i = 1) &= P(Y_i^* \geq 0) = P(\beta_1 + \beta_2 X_i + \varepsilon_i \geq 0) = \\
&= P(\varepsilon_i \geq -\beta_1 - \beta_2 X_i) = P\left(\frac{\varepsilon_i}{\sigma} \leq \frac{(\beta_1 + \beta_2 X_i)}{\sigma}\right) = \\
&= F\left(\frac{(\beta_1 + \beta_2 X_i)}{\sigma}\right)
\end{aligned}$$

В описанной модели параметры $\beta_{1,2}$ и σ участвуют только в отношении, так что по отдельности не могут быть идентифицированы. Поэтому без ограничения общности можно считать, что $\sigma=1$.

В зависимости от того, какую именно функцию F мы выберем, получим логит- или пробит-модели.

Logit-модель

В качестве функции F выбирается функция логистического распределения (S-образная кривая):

$$p = F(Z) = \frac{1}{1 + e^{-Z}}, \quad Z = \beta_1 + \beta_2 X$$




График логистической функции

Производная функции F является функцией плотности:

$$f(Z) = F'(Z) = \frac{e^{-Z}}{(1 + e^{-Z})^2}$$

и характеризует предельный эффект объясняющего фактора.




График функции плотности логистического распределения

Для больших по модулю значений Z воздействие на вероятность мало. Это воздействие возрастает для небольших значений Z .

Функция F нелинейно зависит от параметров β_1, β_2
Для оценки этих параметров, как правило, используется метод максимального правдоподобия (ММП).

Об этом мы поговорим позже. Пока остановимся на интерпретации параметров модели.

Здесь, в отличие от классической регрессионной модели, смысл оценок коэффициентов иной.

Для моделей бинарного выбора говорят о предельных эффектах объясняющих факторов.

Рассмотрим в общем случае модель, в которой Y определяется множеством факторов X .

$$p = F(Z) = \frac{1}{1 + e^{-Z}},$$

$$Z = \beta_1 + \beta_2 X_2 + \dots + \beta_k X_k$$

Предельным эффектом фактора X_i называется частная производная функции F по этому фактору:

$$\frac{\partial p}{\partial X_i} = \frac{\partial p}{\partial Z} \cdot \frac{\partial Z}{\partial X_i} = f(Z) \cdot \beta_i = \frac{e^{-Z}}{(1 + e^{-Z})^2} \cdot \beta_i$$

Предельный эффект не является константой, а зависит от других факторов.

Предельный эффект при среднем значении фактора очень мал. Это связано с тем, что вероятность события $Y=1$ при средних результатах и так достаточно велика.

Probit-модель

Для этой модели в качестве функции F выбирается функция стандартного нормального распределения:

$$p = F(Z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^Z e^{-\frac{u^2}{2}} du,$$

$$Z = \beta_1 + \beta_2 X_2 + \dots + \beta_k X_k$$


Функция плотности стандартного нормального

распределения: $f(Z) = F'(Z) = \frac{1}{\sqrt{2\pi}} e^{-\frac{Z^2}{2}}$

Предельный эффект i -го фактора для пробит-модели:

$$\frac{\partial p}{\partial X_i} = \frac{\partial p}{\partial Z} \cdot \frac{\partial Z}{\partial X_i} = f(Z) \cdot \beta_i = \frac{1}{\sqrt{2\pi}} e^{-\frac{Z^2}{2}} \cdot \beta_i$$

Кумулятивный и предельный эффекты для пробит-модели представлены на рисунке.



Проблемы, связанные с оцениванием ММП, а также статистические тесты и вопросы, связанные с качеством оценивания мы рассмотрим в следующей лекции.

Пока рассмотрим пример.

Имеется выборка из 540 респондентов.

Изучаем зависимость окончания школы для индивидов в зависимости от ряда факторов.

Определим бинарную зависимую переменную

$GRAD=1$, если индивид закончил школу;

$GRAD=0$, в противном случае.

Для этих респондентов фиксировались также:

- совокупные результаты тестирования познавательных способностей: ASVABC (по 100-балльной шкале);
- число лет обучения матери респондента SF;
- число лет обучения отца SM;
- пол респондента MALE (фиктивная переменная, 1 – для мужчин, 0 – для женщин).

В таблице приведены результаты оценивания ЛОГИТ-модели. Использовался ММП, несколько итераций.

Также в нижней части таблицы рассчитаны предельные эффекты.

. logit GRAD ASVABC SM SF MALE
 Logit estimates Number of obs = 540
 LR chi2(4) = 43.75
 Prob > chi2 = 0.0000
 Log likelihood = -96.804844 Pseudo R2 = 0.1843

GRAD	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
ASVABC	.1329127	.0245718	5.41	0.000	.0847528 .1810726
SM	-.023178	.0868122	-0.27	0.789	-.1933267 .1469708
SF	.0122663	.0718876	0.17	0.865	-.1286307 .1531634
MALE	.1279654	.3989345	0.32	0.748	-.6539318 .9098627
_cons	-3.252373	1.065524	-3.05	0.002	-5.340761 -1.163985

Таблица 10.4. Логит-оценивание: зависимая переменная: *GRAD*

Переменная	Среднее	<i>b</i>	Среднее × <i>b</i>	<i>f</i> (<i>Z</i>)	<i>bf</i> (<i>Z</i>)
<i>ASVABC</i>	51,36	0,1329	6,8257	0,0281	0,0037
<i>SM</i>	11,58	-0,0231	-0,2687	0,0281	-0,0007
<i>SF</i>	11,84	0,0123	0,1456	0,0281	0,0003
<i>MALE</i>	0,50	0,1280	0,0640	0,0281	0,0036
Постоянный член	1,000	-3,2524	-3,2524		
Итого			3,5143		

Некоторые пояснения к построенной модели:

$$Z = \beta_1 + \beta_2 ASVABC + \beta_3 SM + \beta_4 SF + \beta_5 MALE.$$

Средние значения по каждой переменной приведены в нижней части таблицы.

С их помощью рассчитывается среднее значение Z по приведенной выше формуле и имеющимся оценкам параметров, оцененных ММП.

Затем считается

$$f(\bar{Z}) = \frac{e^{-\bar{Z}}}{(1 + e^{-\bar{Z}})^2} = \frac{e^{-3,5143}}{(1 + e^{-3,5143})} = 0,0281$$

Теперь считаем предельные эффекты.

Для примера рассчитаем предельный эффект для $ASVABC$:

$$\frac{\partial p}{\partial ASVABC} = f(\bar{Z}) \cdot \beta_{ASVABC} = 0,0281 \cdot 0,1329 = 0,0037$$

Полученное значение говорит о том, что при увеличении результата теста индивида на 1 балл, вероятность окончить школу возрастет на 0,37% пункта.

Из таблицы также видно, что от уровня образования родителей эффект незначителен.

И еще пара формул в качестве комментария к таблице результатов. Эти статистики мы детально рассмотрим в следующей лекции:

Псевдо- R^2 :

$$\text{псевдо-}R^2 = 1 - \frac{\log L}{\log L_0}.$$

Отношение правдоподобия (LR-статистика):

$$2 \log \frac{L}{L_0} = 2(\log L - \log L_0),$$

имеющее хи-квадрат распределение с числом степеней свободы $(k-1)$.