

Лекция 11

Функциональная предельная теорема для эмпирического процесса

Пусть η_1, η_2, \dots – независимые одинаково распределенные случайные величины с функцией распределения $F(t)$. Введем для каждого $n \in \mathbf{N}$ эмпирическую функцию распределения

$$F_n(t) = \frac{1}{n} \sum_{i=1}^n I_{\{\eta_i \leq t\}}, \quad t \in \mathbb{R},$$

где $I_A(\cdot)$ означает индикатор случайного события A . Ясно, что $F_n(t)$ – случайная величина, и по усиленному закону больших чисел почти наверное

$$\lim_{n \rightarrow \infty} F_n(t) = F(t).$$

Введем так называемый эмпирический процесс:

$$Z_n(t) = \sqrt{n}(F_n(t) - F(t)), \quad t \in \mathbb{R}.$$

Иногда рассматривается частный случай этого процесса, когда случайные величины η_1, η_2, \dots имеют равномерное распределение на интервале $(0, 1)$. В этом случае $F(t) = t$ при $t \in [0, 1]$ и, следовательно, $Z_n(t) = \sqrt{n}(F_n(t) - t)$ при $t \in [0, 1]$. Следующий результат принадлежит Донскеру.

Теорема 1. Если η_1, η_2, \dots – независимые случайные величины, имеющие равномерное распределение на интервале $(0, 1)$, то при $n \rightarrow \infty$

$$\{Z_n(t), t \in [0, 1]\} \xrightarrow{D} W_0,$$

где W_0 – броуновский мост, знак \xrightarrow{D} означает сходимость по распределению в пространстве $D[0, 1]$.

Сначала установим полезную теорему, имеющую применения и вне данного контекста. Пусть η_1, η_2, \dots – независимые случайные величины, имеющие равномерное распределение на интервале $(0, 1)$. Положим при $t \in [0, 1]$

$$Y_n(t) = \sum_{i=1}^n I_{\{\eta_i \leq t\}}, \quad \tilde{Y}_n(t) = Y_n\left(\frac{\lfloor nt \rfloor}{n}\right).$$

Рассмотрим последовательность независимых случайных величин $X_i, i \in \mathbf{N}$, имеющих распределение Пуассона с параметром $a > 0$, и положим $S_n = X_1 + \dots + X_n, n \in \mathbf{N}$.

Теорема 2. Конечномерные распределения процессов

$$\left\{ \tilde{Y}_n(t), t \in [0, 1] \right\} \text{ и } \left\{ S_{\lfloor nt \rfloor}, t \in [0, 1] \mid S_n = n \right\}$$

совпадают.

Доказательство теоремы 2. Предположим, что $m \in \mathbb{N}$ и p_1, \dots, p_m – неотрицательные числа, такие что $p_1 + \dots + p_m = 1$. Напомним, что случайный вектор $\{\xi_1, \dots, \xi_m\}$, $m \in \mathbb{N}$, имеет полиномиальное распределение с параметрами n и p_1, \dots, p_m , если для произвольных целых неотрицательных чисел k_1, \dots, k_m таких, что $\sum_{i=1}^m k_i = n$,

$$\mathbf{P}(\xi_1 = k_1, \dots, \xi_m = k_m) = \frac{n!}{k_1! \dots k_m!} p_1^{k_1} \dots p_m^{k_m}.$$

Лемма 1. Пусть $m \in \mathbb{N}$ и $0 = t_0 < t_1 < \dots < t_m < t_{m+1} = 1$. Тогда случайный вектор $\{Y_n(t_i) - Y_n(t_{i-1}), i \in I_{m+1}\}$ имеет полиномиальное распределение с параметрами n и p_1, \dots, p_{m+1} , где $p_i = t_i - t_{i-1}$, $i \in I_{m+1}$.

Доказательство. Рассмотрим случайную величину η , имеющую равномерное распределение на интервале $(0, 1)$. Будем говорить, что достигается успех i -го типа, если $t_{i-1} < \eta \leq t_i$, $i \in I_{m+1}$. Тогда $Y_n(t_i) - Y_n(t_{i-1})$ – число успехов i -го типа в n независимых испытаниях, $i \in I_{m+1}$. Хорошо известно, что случайный вектор, состоящий из таких компонент имеет полиномиальное распределение. Лемма доказана.

Следствие 1. Пусть $m \in \mathbb{N}$ и $0 = t_0 < t_1 < \dots < t_m < t_{m+1} = 1$. Тогда случайный вектор $\{\tilde{Y}_n(t_i) - \tilde{Y}_n(t_{i-1}), i \in I_{m+1}\}$ имеет полиномиальное распределение с параметрами n и $\tilde{p}_1, \dots, \tilde{p}_{m+1}$, где $\tilde{p}_i = (\lfloor nt_i \rfloor - \lfloor nt_{i-1} \rfloor) / n$, $i \in I_{m+1}$.

Лемма 2. Пусть $m, n \in \mathbb{N}$ и натуральные числа n_1, n_2, \dots, n_m возрастают. Тогда случайный вектор $\{S_{n_1}, S_{n_2} - S_{n_1}, \dots, S_{n_m} - S_{n_{m-1}} \mid S_{n_m} = n\}$ имеет полиномиальное распределение с параметрами n и p_1, \dots, p_m , где $p_i = (n_i - n_{i-1}) / n_m$, $i \in I_m$, причем $n_0 = 0$.

Доказательство. При целых неотрицательных числах k_1, \dots, k_m таких, что $\sum_{i=1}^m k_i = n$, находим, что

$$\begin{aligned} & \mathbf{P}(S_{n_i} - S_{n_{i-1}} = k_i, i \in I_m \mid S_{n_m} = n) = \\ &= \frac{1}{\mathbf{P}(S_{n_m} = n)} \prod_{i=1}^m \mathbf{P}(S_{n_i} - S_{n_{i-1}} = k_i) = \\ &= \frac{n!}{(an_m)^n e^{-an_m}} \prod_{i=1}^m \frac{(a(n_i - n_{i-1}))^{k_i} e^{-a(n_i - n_{i-1})}}{k_i!} = \\ &= \frac{n!}{k_1! \dots k_m!} \prod_{i=1}^m \left(\frac{n_i - n_{i-1}}{n_m} \right)^{k_i} = \frac{n!}{k_1! \dots k_{m+1}!} \prod_{i=1}^m p_i^{k_i}. \end{aligned}$$

Лемма доказана.

Следствие 2. Пусть $m \in \mathbb{N}$ и $0 = t_0 < t_1 < \dots < t_m < t_{m+1} = 1$. Тогда случайный вектор $\{S_{\lfloor nt_1 \rfloor}, S_{\lfloor nt_2 \rfloor} - S_{\lfloor nt_1 \rfloor}, \dots, S_{\lfloor nt_{m+1} \rfloor} - S_{\lfloor nt_m \rfloor} \mid S_n = n\}$ имеет полиномиальное распределение с параметрами n и $\tilde{p}_1, \dots, \tilde{p}_{m+1}$, где $\tilde{p}_i = (\lfloor nt_i \rfloor - \lfloor nt_{i-1} \rfloor) / n$, $i \in I_{m+1}$.

Из следствий 1 и 2 следует утверждение теоремы 2.

Доказательство теоремы 1. Напомним, что при $t \in [0, 1]$

$$Z_n(t) = \sqrt{n}(F_n(t) - t).$$

Поскольку $F_n(t) = Y_n(t)/n$, то

$$Z_n(t) = \frac{Y_n(t) - nt}{\sqrt{n}}. \quad (1)$$

Положим

$$\tilde{Z}_n(t) = Z_n\left(\frac{\lfloor nt \rfloor}{n}\right).$$

Из (1) вытекает, что

$$\tilde{Z}_n(t) = \frac{\tilde{Y}_n(t) - \lfloor nt \rfloor}{\sqrt{n}}. \quad (2)$$

Наша задача показать, что при $n \rightarrow \infty$

$$Z_n \xrightarrow{D} W_0. \quad (3)$$

Докажем сначала, что при $n \rightarrow \infty$

$$\tilde{Z}_n \xrightarrow{D} W_0. \quad (4)$$

Ввиду теоремы 2 совпадают конечномерные распределения процессов

$$\{\tilde{Y}_n(t), t \in [0, 1]\} \text{ и } \{S_{\lfloor nt \rfloor}, t \in [0, 1] \mid S_n = n\}.$$

В дальнейшем будем рассматривать частный случай второго из этих процессов, когда $a = 1$. Положим $X_i^* = X_i - 1$ при $i \in \mathbb{N}$ и

$$S_n^* = X_1^* + \dots + X_n^*, \quad n \in \mathbb{N}.$$

Поскольку $S_n^* = S_n - n$ при $n \in \mathbb{N}$, то

$$\{S_{\lfloor nt \rfloor}, t \in [0, 1] \mid S_n = n\} = \{S_{\lfloor nt \rfloor}^* + \lfloor nt \rfloor, t \in [0, 1] \mid S_n^* = 0\}.$$

Таким образом, совпадают конечномерные распределения процессов

$$\{\tilde{Y}_n(t), t \in [0, 1]\} \text{ и } \{S_{\lfloor nt \rfloor}^* + \lfloor nt \rfloor, t \in [0, 1] \mid S_n^* = 0\}$$

и, значит (см. (2)), совпадают конечномерные распределения процессов

$$\{\tilde{Z}_n(t), t \in [0, 1]\} \text{ и } \{S_{\lfloor nt \rfloor}^*/\sqrt{n}, t \in [0, 1] \mid S_n^* = 0\}.$$

Заметим, что $\mathbf{E}X_1^* = 0$, $\mathbf{E}(X_1^*)^2 = 1$ и, следовательно, по функциональной предельной теореме Лигетта при $n \rightarrow \infty$

$$\{S_{\lfloor nt \rfloor}^*/\sqrt{n}, t \in [0, 1] \mid S_n^* = 0\} \xrightarrow{D} W_0.$$

Таким образом, справедливо соотношение (4).

Лемма 3. При $n \rightarrow \infty$

$$\rho_{\text{ск}}(Z_n, \tilde{Z}_n) \xrightarrow{P} 0.$$

Доказательство. При фиксированном $\delta > 0$ рассмотрим функционал $x \rightarrow w_x(\delta)$, где $x \in D[0, 1]$. Он равномерно непрерывен относительно равномерной метрики при всех $x \in D[0, 1]$ и, следовательно (см. лемму 1 лекции 8.1), он непрерывен относительно метрики Скорохода при всех $x \in C[0, 1]$. Поскольку траектории броуновского моста почти наверное непрерывны, то при каждом $\delta > 0$ (см. теорему 1' лекции 4) при $n \rightarrow \infty$

$$w_{\tilde{Z}_n}(\delta) \xrightarrow{D} w_{W_0}(\delta)$$

(по распределению в $D[0, 1]$). Поэтому для всех $\varepsilon > 0$ (за исключением не более чем счетного множества)

$$\limsup_{n \rightarrow \infty} \mathbf{P}(w_{\tilde{Z}_n}(\delta) \geq \varepsilon) = \mathbf{P}(w_{W_0}(\delta) \geq \varepsilon)$$

и, значит, для каждого $\varepsilon > 0$

$$\lim_{\delta \rightarrow 0} \limsup_{n \rightarrow \infty} \mathbf{P}(w_{\tilde{Z}_n}(\delta) \geq \varepsilon) = \lim_{\delta \rightarrow 0} \mathbf{P}(w_{W_0}(\delta) \geq \varepsilon) = 0. \quad (5)$$

Из (5) следует, что для каждого $\varepsilon > 0$

$$\limsup_{n \rightarrow \infty} \mathbf{P}(w_{\tilde{Z}_n}(3/n) \geq \varepsilon) = 0. \quad (6)$$

Из определения \tilde{Z}_n вытекает, что

$$w_{Z_n}(2/n) \leq w_{\tilde{Z}_n}(3/n). \quad (7)$$

Из (6) и (7) находим, что при $n \rightarrow \infty$

$$\limsup_{n \rightarrow \infty} \mathbf{P}(w_{Z_n}(2/n) \geq \varepsilon) = 0. \quad (8)$$

Процесс \tilde{Z}_n является ступенчатым $(1/n)$ -приближением процесса Z_n , поэтому (см. леммы 2 и 3 лекции 6)

$$\rho_{\text{ск}}(Z_n, \tilde{Z}_n) \leq w_{Z_n}(2/n) + 1/n. \quad (9)$$

Из соотношений (8) и (9) следует, что

$$\limsup_{n \rightarrow \infty} \mathbf{P}(\rho_{\text{ск}}(Z_n, \tilde{Z}_n) \geq \varepsilon) = 0.$$

Лемма доказана.

Из соотношения (4) и леммы 3 следует (3). Теорема 1 доказана.

В математической статистике известна следующая теорема Гливенко-Кантелли: почти наверное

$$\lim_{n \rightarrow \infty} \sup_{t \in \mathbb{R}} |F_n(t) - F(t)| = 0.$$

Важно понять, с какой скоростью величина $\sup_{t \in \mathbb{R}} |F_n(t) - F(t)|$, получившая название *статистики Колмогорова*, стремится к нулю. Следующий результат, установленный А.Н. Колмогоровым, является одной из *фундаментальных теорем математической статистики*.

Теорема 3. Пусть η_1, η_2, \dots – независимые одинаково распределенные случайные величины с непрерывной функцией распределения $F(t)$, $t \in \mathbb{R}$. Тогда для произвольного $x \geq 0$

$$\lim_{n \rightarrow \infty} \mathbf{P} \left(\sqrt{n} \sup_{t \in \mathbb{R}} |F_n(t) - F(t)| \leq x \right) = K(x),$$

где $K(\cdot)$ – функция распределения Колмогорова, т.е.

$$K(0) = 0, \quad K(x) = 1 + 2 \sum_{k=1}^{\infty} (-1)^k \exp(-2k^2 x^2), \quad x > 0.$$

Доказательство. Сначала установим следующий полезный результат.

Лемма 4. Если $F(t)$ – непрерывная функция распределения, то случайная величина $\sup_{t \in \mathbb{R}} |F_n(t) - F(t)|$ имеет такое же распределение, как $\sup_{t \in [0,1]} \left| \tilde{F}_n(t) - t \right|$, где $\tilde{F}_n(t)$ – эмпирическая функция распределения, построенная по $\tilde{\eta}_1, \tilde{\eta}_2, \dots$ – независимым одинаково распределенным случайным величинам, имеющим равномерное распределение на интервале $(0, 1)$.

Доказательство. Для простоты изложения будем считать, что функция распределения $F(t)$, $t \in \mathbb{R}$, строго возрастает, тогда существует обратная функция $F^{-1}(y)$, $y \in (0, 1)$. Случайные величины $\tilde{\eta}_i = F(\eta_i)$, $i \in \mathbb{N}$, имеют равномерное распределение на интервале $(0, 1)$. Действительно, при $y \in (0, 1)$

$$\mathbf{P}(\tilde{\eta}_i \leq y) = \mathbf{P}(F(\eta_i) \leq y) = \mathbf{P}(\eta_i \leq F^{-1}(y)) = F(F^{-1}(y)) = y.$$

Далее,

$$\begin{aligned} \sup_{t \in \mathbb{R}} |F_n(t) - F(t)| &= \sup_{t \in \mathbb{R}} \left| \frac{1}{n} \sum_{i=1}^n I_{\{\eta_i \leq t\}} - F(t) \right| = \\ &= \sup_{t \in \mathbb{R}} \left| \frac{1}{n} \sum_{i=1}^n I_{\{F(\eta_i) \leq F(t)\}} - F(t) \right| = \sup_{u \in [0,1]} \left| \frac{1}{n} \sum_{i=1}^n I_{\{\tilde{\eta}_i \leq u\}} - u \right|. \end{aligned}$$

Лемма доказана.

Продолжим доказательство теоремы 3. Покажем, что при $n \rightarrow \infty$

$$\sqrt{n} \sup_{t \in \mathbb{R}} |F_n(t) - F(t)| \xrightarrow{D} \sup_{t \in [0,1]} |W_0(t)|. \quad (10)$$

Рассмотрим отображение $f : x \rightarrow \sup_{t \in [0,1]} |x(t)|$, где $x \in D[0, 1]$. Ранее было показано (см. доказательство теоремы 1 лекции 8.1), что это отображение равномерно непрерывно в равномерной метрике при всех $x \in D[0, 1]$. Следовательно, по лемме 4 лекции 6 оно непрерывно относительно метрики Скорохода при всех $x \in C[0, 1]$. Поскольку траектории броуновского моста почти наверное непрерывны, то из теоремы 1 следует (см. теорему 1' лекции 4), что если η_1, η_2, \dots – независимые случайные величины, имеющие равномерное распределение на интервале $(0, 1)$, то при $n \rightarrow \infty$

$$\sqrt{n} \sup_{t \in [0,1]} |F_n(t) - t| = \sup_{t \in [0,1]} |Z_n(t)| \xrightarrow{D} \sup_{t \in [0,1]} |W_0(t)|. \quad (11)$$

По лемме 3 левая часть соотношения (10) имеет такое же распределение, как и левая часть соотношения (11), поэтому из (11) следует (10).

Осталось вспомнить, что распределение правой части соотношения (10) является распределением Колмогорова (см теорему 3 лекции 9). Теорема 3 доказана.