

**В.Ф.Писаренко**

Стохастическое моделирование,  
бутстреп

# Генерирование случайных чисел с заданным распределением.

Функция распределения  $F(x)$  случайной величины  $\xi$  :

$$F(x) = Pr\{\xi \leq x\}.$$

Если  $F(x)$  непрерывна, то случайная величина  $F(\xi)$  имеет равномерное на отрезке  $[0, 1]$  распределение.

$R_n = (r_1, \dots, r_n)$  – вектор  $[0, 1]$ -случайных величин. Пусть существует такой случайный вектор  $Z_n$ , что выполняется

$$F(Z_n) = R_n. \quad (*)$$

Применим к уравнению (\*) функцию  $F_{inv}(\cdot)$  обратную по отношению к функции  $F(x)$ :  $Z_n = F_{inv}(R_n)$ . Тогда все компоненты вектора  $Z_n$  имеют функцию распределения  $F(x)$ .

Пример:  $F(x) = 1 - \exp(-b \cdot x); x \geq 0.$        $Z_n = -(1/b) \cdot \log(1 - R_n).$

Обратную функцию  $F_{inv}$  в явном виде можно найти не для всех функций распределения.

Что делать в таких случаях? Ищем **приближенную** обратную функцию (с очень высокой степенью приближения). Определим интервал заведомо включающий весь возможный для реальных наблюдений диапазон  $[m, M]$ . Задаем на отрезке  $[m, M]$  очень мелкую, равномерную решетку

$$MN = m : 1/N : M,$$

где  $N$  – очень большое число (оно ограничено только возможностями компьютера). Вектор  $MN$  состоит из  $N$  компонент:  $MN = (m_1, \dots, m_N)$ . Вычисляем прямую функцию распределения от аргументов  $(m_1, \dots, m_N)$ :

$$z_j = F(m_j) ; j = 1, \dots, N; \quad Z_N = (z_1, \dots, z_N).$$

Пусть задано множество  $n$  случайных точек  $R_n$  из  $[0, 1]$ :  $R_n = (r_1, \dots, r_n)$ .

На множестве  $R_n$  получаем значения магнитуд  $M_n$  с помощью интерполяции с решетки  $(M_N, Z_N)$ .

В пакете MATLAB эти операции можно компактно выполнить с помощью стандартной операции линейной интерполяции *interp1*:

$$M_n = \text{interp1}(Z_N, M_N, R_n, 'linear').$$

Если шаг решетки  $1/N$  достаточен для детального описания функции  $F(x)$ , то можно считать, что компоненты вектора  $M_n$  имеют функцию распределения  $F(x)$  с приемлемой точностью.

# Многомерные гауссовские случайные векторы с заданной ковариационной матрицей.

Плотность многомерного гауссовского вектора  $(\xi_1, \dots, \xi_n)$  имеет вид:

$$f(x_1, \dots, x_n / A, B) = \frac{1}{(2\pi)^{n/2} \sqrt{\det(B)}} \cdot \exp\left\{-\frac{1}{2} \sum \beta_{kj} (x_k - a_k)(x_j - a_j)\right\}; \quad (1)$$

$$E(\xi_k) = a_k; \quad A = (a_1, \dots, a_n); \quad B = \{ E(\xi_k - a_k)(\xi_j - a_j) \}; \quad \{\beta_{kj}\} = B^{-1};$$

$E$  – символ математического ожидания; вектор  $A$  – вектор средних значений; матрица  $B$  – матрица ковариаций. Они заданы.

Требуется генерировать вектор случайных гауссовских величин со средними значениями  $A$  и матрицей ковариаций  $B$ . Обозначим через  $G$  корень из матрицы  $B$ :  $G = B^{1/2} = \{ \gamma_{kj} \}$ .

Берем вектор стандартных независимых гауссовских значений  $(\eta_1, \dots, \eta_n)$ ; (их генерирует компьютер стандартной командой **randn**) и получаем из него нужные нам гауссовские величины  $(\xi_1, \dots, \xi_n)$  с помощью линейных комбинаций:

$$\xi_k = a_k + \sum_{j=1}^n \gamma_{kj} (\eta_j - a_j); \quad k = 1, \dots, n.$$

Вектор  $(\xi_1, \dots, \xi_n)$  имеет плотность вероятности (1).

## Статистическое тестирование критериев значимости, основанных на эмпирической функции распределения, при наличии неизвестных параметров.

Пусть  $(x_1 < x_2 \dots < x_n)$  – упорядоченная выборка независимых наблюдений случайной величины с функцией распределения  $F(x / \alpha)$ , где  $\alpha$  - некоторый параметр (возможно, векторный). Нужно проверить гипотезу о том, что выборка соответствует функции  $F(x / \alpha)$  при каком-то неизвестном значении параметра  $\alpha$ . Оценим  $\alpha$  методом максимального правдоподобия, оценку обозначим  $\hat{\alpha}$ . Подставим эту оценку в  $F(x / \hat{\alpha})$  и рассмотрим расстояние Колмогорова  $KD$  между  $F(x / \hat{\alpha})$  и выборочной функцией распределения  $\hat{F}_n(x)$ :

$$KD = n^{1/2} \max | F(x / \hat{\alpha}) - \hat{F}_n(x) |. \quad (\text{MATLAB: } \mathbf{kstest})$$

Если бы функция распределения была известна точно (были бы точно известны параметры), то распределение расстояния  $KD$  можно было бы определить точно (оно называется распределением Колмогорова, есть таблицы). Далее нужно выбрать порог допустимых расстояний  $H$ , который будет превышать лишь с малой вероятностью  $p$  (скажем,  $p = 0.05$ ), и отвергать нашу гипотезу, если наблюдается  $KD > H$ . Для случая с подгонкой неизвестного параметра расстояние Колмогорова будет меньше, чем без подгонки, и поэтому оно не будет соответствовать распределению Колмогорова. Какой выход из этого положения?

*Предлагается смоделировать процедуру оценки параметра, повторить её  $N$  раз (скажем 10000 раз) и получить большую выборку расстояний Колмогорова  $(KD_1, \dots, KD_N)$ .*

*Затем взять **выборочный** квантиль уровня  $(1-p)$ , т.е. то значение из выборки  $(KD_1, \dots, KD_N)$ , которое превзойдут лишь  $p \cdot N$  значений этой выборки. Его-то и нужно взять в качестве порога для расстояния Колмогорова в случае подгонки параметров. Оно будет несколько больше порога  $H$ , а вероятность его превзойти с большой точностью равна  $p$ .*

## Бутстреп-метод

Понятие бутстреп (bootstrap) введено в 1977 году Брэдли Эфроном (Bradly Efron). Суть метода состоит в том, чтобы по имеющейся выборке построить эмпирическое распределение. Используя это распределение как теоретическое распределение вероятностей, можно с помощью датчика псевдослучайных чисел сгенерировать практически неограниченное количество псевдовыборок произвольного размера. С помощью этих псевдовыборок можно оценить анализируемые статистические характеристики и изучить их вероятностные распределения. Таким способом, например, можно оценить дисперсию любой статистики независимо от её сложности.

Пусть  $(x_1, \dots, x_n)$  выборка из неизвестного распределения  $F(x)$ .

Производим с помощью датчика случайных чисел  $n$ -кратную выборку (**выбор с возвращением**) из величин  $(x_1, \dots, x_n)$ ; полученный вектор обозначим  $\mathbf{y}^{(1)} = (y_1^{(1)}, \dots, y_n^{(1)})$ .

Генерируем  $N$  таких векторов:  $\mathbf{y}^{(1)} \dots \mathbf{y}^{(N)}$ .

Считая, что эти векторы достаточно представительного характеризуют распределение  $F(x)$  (что справедливо лишь с некоторым приближением, которое улучшается при  $n \rightarrow \infty$ ), можно статистически оценить любую интересующую нас характеристику распределения. При этом надо помнить, что любые такие оценки построены фактически на одной исходной выборке  $(x_1, \dots, x_n)$  и поэтому, строго говоря, являются **условными** (при условии реализации данной выборки). Они стремятся к безусловным оценкам при  $n \rightarrow \infty$ . Степень близости надо оценивать в каждом конкретном случае, имитируя реальную ситуацию, на примерах с известным ответом. По этой причине бутстреп-оценка дисперсии какой-то статистики, как правило, несколько ниже её истинной дисперсии.

# Бутстреп с непрерывной функцией распределения

Классический бутстреп предполагает использование дискретного (полиномиального) распределения с одинаковыми вероятностями  $1/n$  для каждого значения выборки  $x_k$ . Это соответствует процедуре «выборка с возвращением». Но если мы знаем, что исследуемая случайная величина непрерывная, то естественно как-то выправить это несоответствие. Для этого можно дискретное полиномиальное распределение приблизить непрерывной функцией распределения. Способы приближения могут быть различны. Например, стандартная команда вычисления выборочных квантилей (процентилей) **prctile(X, q%)** выполняет такое приближение с помощью линейной интерполяции исходного полиномиального распределения в интервале  $[\min(X); \max(X)]$ . Пусть  $R_n$  – вектор случайных величин из  $[0, 1]$ :  $R_n = (r_1, \dots, r_n)$ . Тогда вектор  $Z = \text{prctile}(X, R_n)$  имеет (приблизительно) функцию распределения исходного вектора  $X$ . Можно генерировать любое количество независимых векторов  $Z$  и использовать их как независимые наблюдения для оценивания любых интересующих исследователя статистик с необходимой точностью.

Приведем альтернативный способ приближения исходной функции распределения – кернел-метод (kernel – ядро, функция типа колокола). Этот метод дает оценку  $\hat{F}(z)$  в точке  $z$  для функции распределения:

$$\hat{F}(z) = \text{mean}(\text{normcdf}(X - z), s);$$

$s$  – параметр сглаживания; *normcdf* – (кумулятивная) Гауссовская функция распределения (можно брать и другие ядра) со средним значением  $(X - z)$  и стандартным отклонением  $s$ ; усреднение проводится по  $n$  значениям выборки; параметр  $s$  – подбирается так, чтобы сгладить выбросы от отдельных наблюдений и не «загладить» распределение (возможная рекомендация  $s \approx 0.3 \cdot \text{std}(X) / n^{1/5}$ )

Имея функцию распределения, можно генерировать сколь угодно большие выборки и статистически оценивать любые статистики со сколь угодно большой точностью (условно, поскольку все это делается в рамках бутстрепа, на основе единственной исходной выборки).

## Аппроксимация выборочной функции равномерного распределения $F(x)$ на $[0; 2]$ ,

$n = 4$ , показанного черными стрелками с помощью:

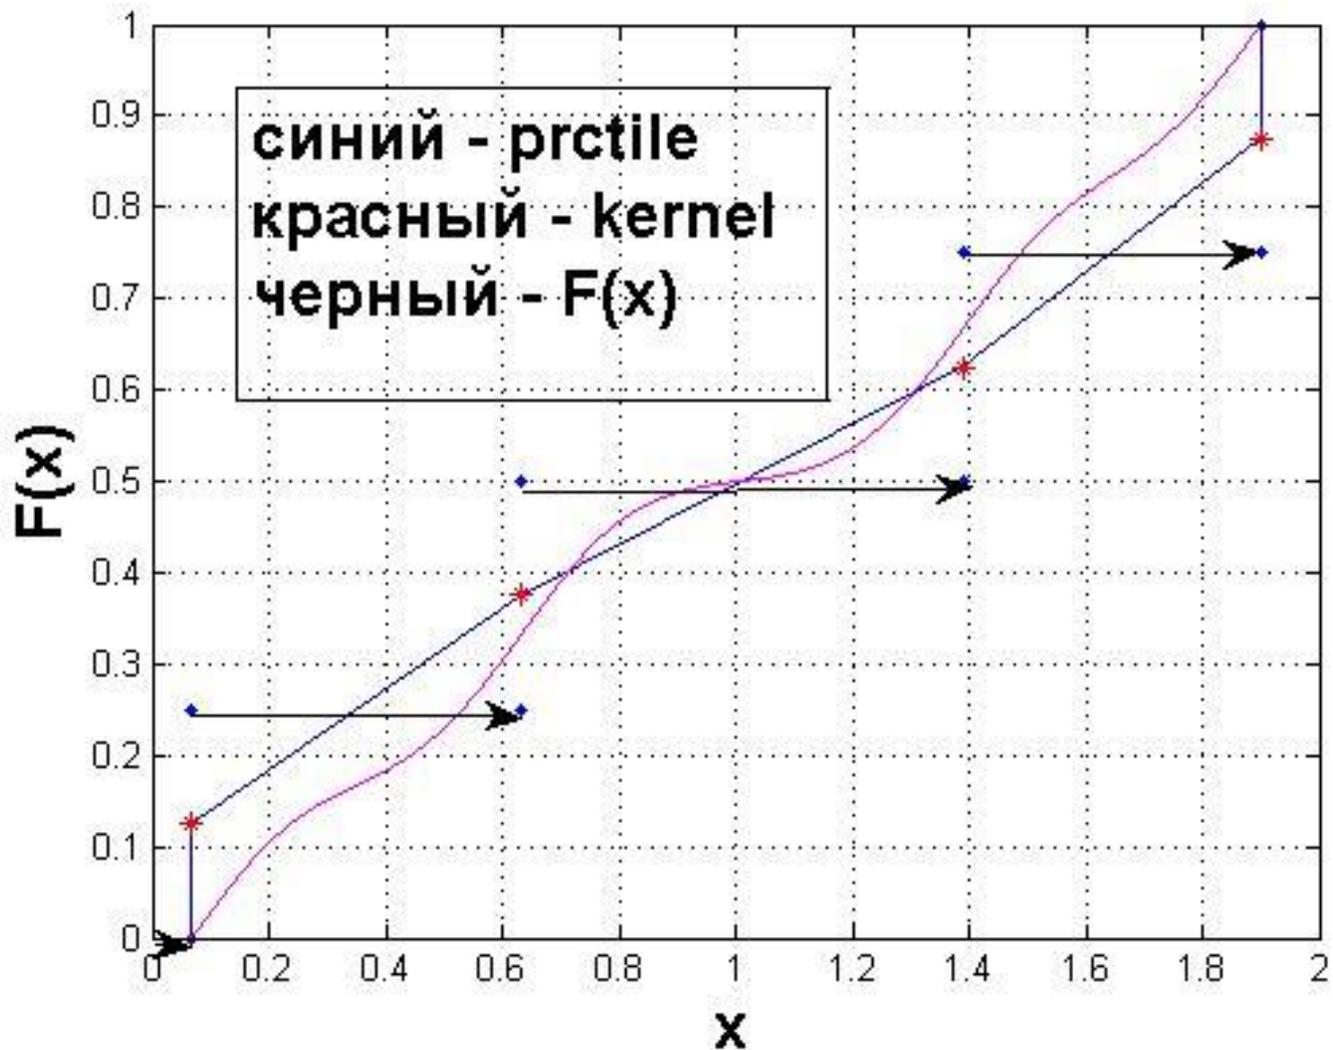
красный – кернел-метод;

синий – процентиля;

черные стрелки – выборочная  $F(x)$ .

Метод процентилей линейно аппроксимирует **середины скачков** выборочной  $F(x)$ , они отмечены звездочками.

Кернел-метод дает более плавную аппроксимацию к истинной  $F(x)$  – диагонали прямоугольника.



## Использование статистического моделирования и бутстреп-метода для оценки параметров функции распределения.

Рассмотрим предложенную недавно в работах Писаренко и Родкина новую составную модель для закона повторяемости землетрясений. Закон повторяемости землетрясений задаётся моделью, состоящей из двух ветвей. Повторяемость в диапазоне средних и слабых землетрясений описывается линейным законом Гутенберга-Рихтера (Г-Р), а в диапазоне сильных - Обобщенным распределением Парето (Generalized Pareto Distribution, GPD).

Составная модель содержит три параметра, подлежащих оценке: наклон графика повторяемости в диапазоне средних и слабых магнитуд –  $b$ , параметр  $h$ , задающий точку гладкого сочленения двух ветвей модели и параметр формы GPD-распределения  $\xi$ , характеризующий быстроту убывания плотности при приближении к крайней предельной точке.

$$C_1 \{1 - \exp[-b \cdot (m - m_0)]\}; \quad m_0 \leq m \leq h;$$

$$F(m/b, h, \xi) =$$

$$C_3 + C_2 \{1 - [1 + \frac{b\xi}{1+\xi}(m-h)]^{-1/\xi}\}; \quad h \leq m \leq M_{max} = h - \frac{1+\xi}{b\xi}, \quad -1 < \xi < 0;$$

$$C_1 = 1 / (1 + \xi \exp[-b \cdot (h - m_0)]);$$

$$C_2 = (1 + \xi) \exp[-b \cdot (h - m_0)] / (1 + \xi \exp[-b \cdot (h - m_0)]);$$

$$C_3 = \{1 - \exp[-b \cdot (h - m_0)]\} / (1 + \xi \exp[-b \cdot (h - m_0)]).$$

Здесь верхняя ветвь соответствует распределению Г-Р; нижняя ветвь – распределению GPD;  $m_0$  – нижняя граница диапазона магнитуд;  $b$  - наклон графика повторяемости ветви Г-Р;  $h$  – параметр, задающий точку гладкого сочленения двух ветвей модели;  $\xi$  - параметр формы GPD-распределения;  $C_1$ ,  $C_2$ ,  $C_3$  – нормирующие константы, зависящие от параметров и обеспечивающие непрерывность плотности распределения и её первой производной в точке сочленения  $m = h$ .

## Оценка параметров составной модели

Дана выборка магнитуд  $X = (m_1, \dots, m_n)$ . Нужно оценить  $h$ ,  $\xi$ ,  $b$ .

В качестве оценки параметра  $h$  берется выборочный квантиль  $X$  уровня  $q_h\%$ :

$$\hat{h} = \text{prctile}(X, q_h).$$

Уровень  $q_h$  подбирается с учетом выборки  $X$  таким образом, чтобы число наблюдений выше  $\hat{h}$  было не менее 20. Обычно  $q_h = 50 \div 80\%$ . Параметры  $(\xi, b)$  оцениваются методом максимального правдоподобия с помощью стандартной программы поиска максимума функции от нескольких переменных (двух в данном случае).

## Подгонка Модели-2

Каталог SMT 1976-2016

Континентальные землетрясения  
Евразии:

$27 < \lambda < 47$ ;  $10 < \varphi < 95$ ;  $h \leq 70 \text{ km}$ ;  
 $m \geq 5.5$ ;  $q_h = 80\%$ .

$n = 436$ ;  $n_1 (m < h) = 349$ ;  $n_2 (m \geq h) = 87$ .

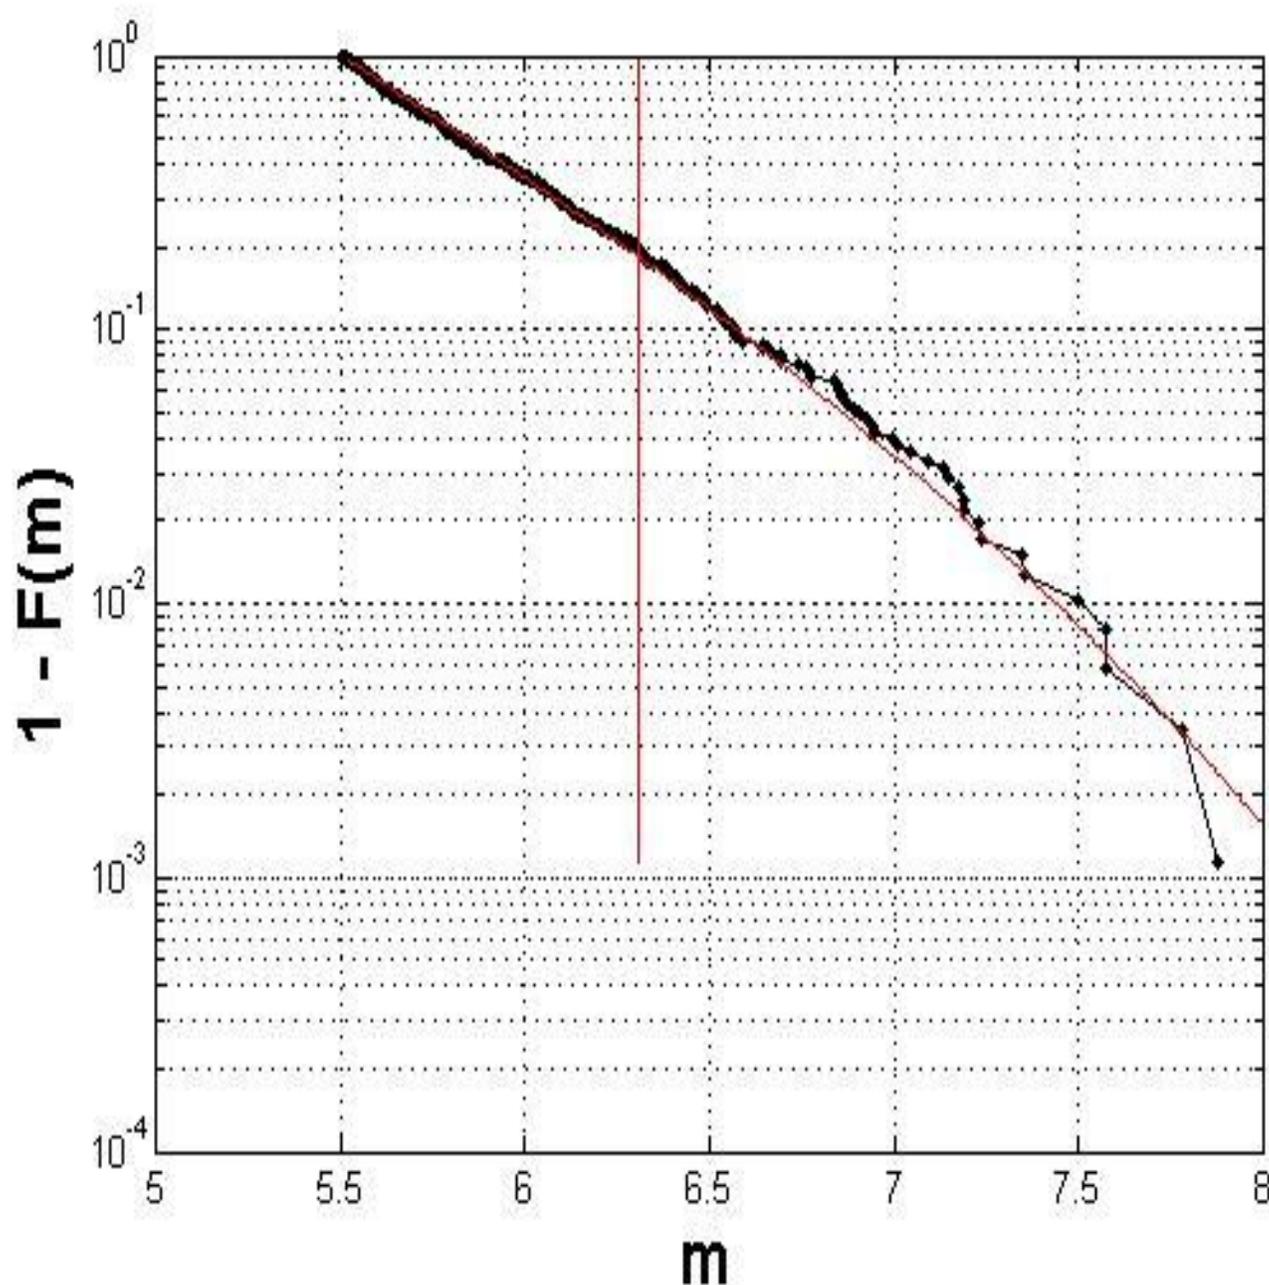
**MaxLikEstimates:  $\hat{\xi} = -0.104$ ;**  
 **$\hat{b} = 0.863$ ;**

**$\hat{h} = \text{prctile}(X, 80) = 6.31$**

**$KD = 0.803$ ;  $pvKD = 0.49$ .**

Вероятность  $pvKD = P\{KD > 0.803\}$   
оценивалась методом случайного  
моделирования, описанным выше.

Погрешность оценок  $\hat{\xi}$ ,  $\hat{b}$   
оценивалась двумя способами



## Погрешность оценок $\hat{\xi}$ , $\hat{\mathbf{b}}$

Для оценки погрешности  $\hat{\xi}$ ,  $\hat{\mathbf{b}}$  нужно иметь достаточно много (псевдо)-выборок. Классический бутстреп-метод генерирует их с помощью выборки с возвращением. Альтернативный метод состоит в том, чтобы подставить в модельную функцию распределения  $F$  выборочные оценки  $\hat{\xi}$ ,  $\hat{\mathbf{b}}$  и рассматривать  $F(m/\hat{\xi}, \hat{\mathbf{b}})$  как теоретическую функцию распределения, которая, как мы видели ранее, позволяет генерировать сколь угодно большие выборки того же объема  $n$ , что и исходная выборка. Конечно,  $F(m/\hat{\xi}, \hat{\mathbf{b}})$  отличается от истинной функции распределения (поскольку в ней стоят не истинные значения параметров, а их оценки), но это будут уже *отличия второго порядка* и ими, как правило, можно пренебречь при оценке разброса  $(\hat{\xi}, \hat{\mathbf{b}})$ . При увеличении объема исходной выборки  $n$  эти отличия исчезают.

Применяя эти два метода, мы получили следующие оценки погрешности:

$std(\hat{\xi}) = 0.0501$ ;  $std(\hat{\mathbf{b}}) = 0.134$ ; бутстреп-метод;

$std(\hat{\xi}) = 0.0542$ ;  $std(\hat{\mathbf{b}}) = 0.130$ ; метод генерирования выборок с помощью  $F(m/\hat{\xi}, \hat{\mathbf{b}})$ .

# Метод случайного моделирования

## Резюме.

Итак, метод случайного моделирования состоит из двух этапов:

1. Из исходной выборки объема  $n$  ( $x_1, \dots, x_n$ ) получаем тем или иным способом большое число  $N$  псевдо-выборок. Бутстреп делает это с помощью выборки с возвращением, а способ иммитации аппроксимирует функцию распределения и с её помощью генерирует псевдо-выборки.
2. Имея большое число псевдо-выборок можно по ним взять выборочное среднее значение любой статистики (теоретически вычислять её распределение иногда очень трудно). Псевдо-выборки зависимы, но среднее значение (даже от зависимых одинаково распределенных слагаемых) всегда равно среднему по ансамблю.

**СПАСИБО ЗА ВНИМАНИЕ!**