

УДК 519.2

## ОЦЕНИВАНИЕ ПАРАМЕТРОВ РАСПРЕДЕЛЕНИЯ ВЕЙБУЛЛА ПО СЛУЧАЙНО ЦЕНЗУРИРОВАННЫМ ВЫБОРКАМ

© 2010 г.

М.С. Тихов, В.В. Агеев, Т.С. Бородина

Нижегородский госуниверситет им. Н.И. Лобачевского

tikhovm@mail.ru

Поступила в редакцию 23.09.2009

Распределение Вейбулла является важным распределением, особенно для анализа надежности и ремонтпригодности. В статье представлены некоторые методы оценивания параметров распределения Вейбулла, именно параметра формы  $\alpha$  и масштабного параметра  $\sigma$ . Доказана состоятельность и асимптотическая нормальность полученных оценок.

*Ключевые слова:* распределение Вейбулла, случайно цензурированная выборка, параметрическое оценивание, метод наименьших квадратов.

### Введение

Распределение Вейбулла является одним из важнейших в теории надежности. Оно имеет функцию распределения

$$F(x) = 1 - \exp\left(-\left(\frac{x-\mu}{\sigma}\right)^\alpha\right), \quad (1)$$

$x > \mu, \sigma > 0, \alpha > 0.$

Это распределение является также одним из трех предельных распределений нормированных разностей минимума (максимума) независимых и одинаково распределенных случайных величин. Статистическому анализу распределения Вейбулла и его параметров посвящены две большие недавно вышедшие монографии (см. [1, 2]), список цитируемых статей которых насчитывает свыше тысячи источников. Основной метод оценивания параметров этого распределения – метод максимального правдоподобия. Однако ввиду аналитической сложности получаемых при этом уравнений для нахождения значений параметров распределения Вейбулла он используется в совокупности с численными методами, что вносит дополнительную погрешность в определение значений оценок. Другим способом оценивания является довольно простой и аналитически удобный метод спрямления, который сводится к следующему нелинейному функциональному преобразованию уравнения (1) (полагая  $\mu = 0$ ):

$$z = \alpha y - \lambda, \quad (2)$$

где  $z = \ln(-\ln(1 - F(x)))$ ,  $y = \ln x$ ,  $\lambda = \alpha \ln \sigma$ .

Таким образом, в системе координат  $yOz$  уравнение (2) есть уравнение прямой и оценку

параметров  $\alpha$  и  $\lambda$ , а значит, и  $\sigma$  можно производить по методу наименьших квадратов. Для полных, цензурированных по типу I и типу II, прогрессивно цензурированных выборок такие оценки предложены в работах [1–5] и были исследованы в основном численными методами. Однако в литературе совсем не представлены подходы к построению и не исследовано поведение оценок по случайно цензурированным выборкам, что важно для практических приложений. В данной работе мы рассматриваем задачу построения оценок параметров распределения Вейбулла по случайно цензурированным выборкам. В преобразовании (2) мы используем, в основном, множительные оценки Каплана–Мейера [6] и оценки Нельсона–Аалена [7–9], а также метод наименьших квадратов. Мы показываем, что полученные оценки являются состоятельными и асимптотически нормальными. Рассмотрены и другие, важные в теории надежности и эконометрике, распределения, для которых применим предложенный подход.

### 1. Построение оценок

Мы рассматриваем случайно цензурированную выборку, когда вместо величин  $X_i, 1 \leq i \leq n$ , наблюдаются только пары  $(Z_1, \delta_1), (Z_2, \delta_2), \dots, (Z_n, \delta_n)$ ,  $Z_i = \min(X_i, T_i)$ ,  $\delta_i = I(X_i \leq T_i)$ ,  $i = 1, 2, \dots$ , где  $\{T_i, 1 \leq i \leq n\}$  есть цензурирующие величины,  $I(A)$  обозначает индикатор события  $A$ . Оценки параметров распределения Вейбулла будем строить по случайно цензурированным данным  $\{(Z_i, \delta_i), 1 \leq i \leq N\}$ .

Имея в виду практическое применение модели случайного цензурирования, будем считать, что  $X_i, 1 \leq i \leq n$ , и  $T_j, 1 \leq j \leq n$ , являются неотрицательными и независимыми случайными величинами, кроме того, каждая из случайных величин  $T_j$  не зависит от каждой из величин  $X_i$ , где  $X_i$  имеет функцию распределения  $F(x) = 1 - \exp(-(x/\sigma)^\alpha)$ . Цензурирующие величины  $T_1, T_2, \dots$  предполагаются независимыми, одинаково распределенными случайными величинами с известной или неизвестной функцией распределения  $G(x)$ . В таком случае функция распределения величины  $Z_i$  равна

$$H(x) = \mathbf{P}(Z_i \leq x) = 1 - (1 - F(x))G(x) = 1 - S(x)\bar{G}(x),$$

где  $S(x) = 1 - F(x)$ ,  $\bar{G}(x) = \mathbf{P}(T_i > x)$ .

Хорошо известно, что наилучшей в определенном смысле оценкой функции распределения  $F(x)$  по выборке  $(Z_i, \delta_i), 1 \leq i \leq n$ , является оценка Каплана–Мейера (КМ) [6], определенная следующим образом:

$$\hat{S}_n(x) = 1 - \hat{F}_n(x) = \prod_{i=1}^n \left( 1 - \frac{\delta_{[i:n]}}{n - i + 1} \right)^{I(Z_{i:n} \leq x)} = \prod_{u \leq x} \left( 1 - \frac{d\bar{N}(u)}{\bar{Y}(u)} \right), \quad (3)$$

где  $Z_{i:n}$  есть  $i$ -я порядковая статистика, построенная по выборке  $Z_1, Z_2, \dots, Z_n$ , а  $\delta_{[i:n]}$  —  $i$ -я сопутствующая порядковая статистика: если  $Z_{i:n} = Z_j$ , то  $\delta_{[i:n]} = \delta_j$ ;  $\bar{N}(t) = \sum_{j=1}^n N_j(t)$ ,  $N_j(t) = I(X_j \leq t, \delta_j = 1)$ ,  $\bar{Y}(t) = \sum_{j=1}^n Y_j(t)$ ,  $Y_j(t) = I(X_j > t)$ .

Известно (см. [10]), что для оценки (3) имеет место соотношение:

$$\mathbf{P} \left( \sup_{-\infty < x < +\infty} |\hat{F}_n(x) - F(x)| = O \left( \sqrt{\frac{\ln n}{n}} \right) \right) = 1,$$

т.е. почти наверное  $\hat{F}_n(x)$  равномерно сходится к истинной функции распределения  $F(x)$ .

Известно также, что эти оценки асимптотически нормальны с ожиданием  $F(x)$  и асимптотической дисперсией

$$\frac{S^2(x)}{n} \int_0^x \frac{dF(y)}{S^2(y)\bar{G}(y)}.$$

Оценки параметров распределения Вейбулла будем находить из условия минимума по  $\alpha$  и  $\lambda$  выражения

$$Q \equiv Q(\alpha, \lambda) = \int_0^\infty (\ln(-\ln(1 - \hat{F}_n(x))) - \alpha \ln x + \lambda)^2 d\hat{F}_n(x).$$

Исходя из необходимого условия экстремума (для квадратичной функции оно является и достаточным), получаем систему уравнений:

$$\begin{cases} \int_0^\infty \ln x \cdot \ln(-\ln(1 - \hat{F}_n(x))) d\hat{F}_n(x) = \\ \quad = \alpha \int_0^\infty \ln^2 x d\hat{F}_n(x) - \lambda \int_0^\infty \ln x d\hat{F}_n(x), \\ \int_0^\infty \ln(-\ln(1 - \hat{F}_n(x))) d\hat{F}_n(x) = \\ \quad = \alpha \int_0^\infty \ln x d\hat{F}_n(x) - \lambda. \end{cases} \quad (4)$$

Положим:

$$\begin{aligned} \hat{v}_1 &= \int_0^\infty \ln(-\ln(1 - \hat{F}_n(x))) d\hat{F}_n(x), \\ \hat{v}_2 &= \int_0^\infty \ln x \cdot \ln(-\ln(1 - \hat{F}_n(x))) d\hat{F}_n(x), \\ \hat{\tau}_1 &= \int_0^\infty \ln x d\hat{F}_n(x), \quad \hat{\tau}_2 = \int_0^\infty \ln^2 x d\hat{F}_n(x). \end{aligned}$$

Тогда система (4) примет вид:

$$\begin{cases} \hat{v}_2 = \hat{\tau}_2 \alpha - \hat{\tau}_1 \lambda, \\ \hat{v}_1 = \hat{\tau}_1 \alpha - \lambda, \end{cases}$$

решением ее будет

$$\hat{\alpha} = \frac{\hat{v}_1 \hat{\tau}_1 - \hat{v}_2}{\hat{\tau}_1^2 - \hat{\tau}_2}, \quad \hat{\lambda} = \frac{\hat{v}_1 \hat{\tau}_2 - \hat{v}_2 \hat{\tau}_1}{\hat{\tau}_1^2 - \hat{\tau}_2}.$$

## 2. Состоятельность оценок

Имеет место следующий результат.

**Теорема 1.** *Предположим, что  $S(x) = \exp(-(x/\sigma)^\alpha)$ , а  $G(x)$  — непрерывная функция. Тогда  $\hat{\alpha} \xrightarrow[n \rightarrow \infty]{p} \alpha$ ,  $\hat{\lambda} \xrightarrow[n \rightarrow \infty]{p} \lambda$ .*

**Доказательство.** Учитывая представление

$$\begin{aligned} \hat{v}_1 &= \int_0^\infty \ln(-\ln(1 - \hat{F}_n(x))) d\hat{F}_n(x) = \\ &= \int_0^\infty \ln(-\ln(1 - F(x))) d\hat{F}_n(x) + \\ &+ \int_0^\infty \ln(-\ln(1 - \hat{F}_n(x)) - \ln(-\ln(1 - F(x)))) d\hat{F}_n(x) \end{aligned}$$

и что при  $n \rightarrow \infty$

$$\begin{aligned} & \sup_{x \leq x_0} |\ln(-\ln(1 - \hat{F}_n(x))) - \ln(-\ln(1 - F(x)))| \leq \\ & \leq C_1 \sup_{x \leq x_0} |\ln(1 - \hat{F}_n(x)) - \ln(1 - F(x))| \leq \\ & \leq C_2 \sup_{x \leq x_0} |\hat{F}_n(x) - F(x)|, \end{aligned} \quad (6)$$

используя результаты работ [11, 12], получа-

ем:  $\hat{v}_1 - v_1 \xrightarrow[n \rightarrow \infty]{p} 0$ , где

$$\begin{aligned} v_1 &= \int_0^{\infty} \ln(-\ln(1 - F(x))) dF(x) = \\ &= \int_0^{\infty} (\alpha \ln x + \lambda) dF(x). \end{aligned}$$

Аналогично,

$$\hat{v}_2 = \int_0^{\infty} \ln x \cdot \ln(-\ln(1 - \hat{F}_n(x))) d\hat{F}_n(x) \xrightarrow[n \rightarrow \infty]{p} v_2,$$

где

$$\begin{aligned} v_2 &= \int_0^{\infty} \ln x \ln(-\ln(1 - F(x))) dF(x) = \\ &= \int_0^{\infty} \ln x (\alpha \ln x + \lambda) dF(x), \end{aligned}$$

$$\hat{\tau}_1 = \int_0^{\infty} \ln x d\hat{F}_n(x) \xrightarrow[n \rightarrow \infty]{p} \tau_1 = \int_0^{\infty} \ln x dF(x),$$

$$\hat{\tau}_2 = \int_0^{\infty} \ln^2 x d\hat{F}_n(x) \xrightarrow[n \rightarrow \infty]{p} \tau_2 = \int_0^{\infty} \ln^2 x dF(x).$$

Из этих соотношений следует, что

$$\hat{\alpha} \xrightarrow[n \rightarrow \infty]{p} \frac{v_1 \tau_1 - v_2}{\tau_1^2 - \tau_2} = \alpha \quad \text{и} \quad \hat{\lambda} \xrightarrow[n \rightarrow \infty]{p} \lambda.$$

### 3. Асимптотическая нормальность

Поскольку  $H(x)$  есть функция распределения величины  $Z_i = \min(X_i, T_i)$ , то положим  $\bar{H} = 1 - H$  и определим  $\tau_H = \inf\{x \geq 0 : H(x) = 1\}$ .

**Теорема 2.** При условиях теоремы 1  $\sqrt{n}(\hat{\alpha} - \alpha)$  и  $\sqrt{n}(\hat{\lambda} - \lambda)$  асимптотически (при  $n \rightarrow \infty$ ) нормальны.

**Доказательство.** Для установления сходимости нормированных разностей оценок  $\sqrt{n}(\hat{\alpha} - \alpha)$  и  $\sqrt{n}(\hat{\lambda} - \lambda)$  к нормальным случайным величинам воспользуемся результатами работ [11–13], в которых показано, что

$$\sqrt{n} \left( \int \varphi d\hat{F}_n - \int_0^{\tau_H} \varphi dF \right) \xrightarrow[n \rightarrow \infty]{d} \mathcal{N}(0, \sigma_1^2),$$

$$\begin{aligned} \sigma_1^2 &= \int_0^{\tau_H} \frac{\varphi^2(x)}{G(x)} dF(x) - \left( \int_0^{\tau_H} \varphi(x) dF(x) \right)^2 - \\ &- \int_0^{\tau_H} \frac{S(x)}{1-H(x)} \left\{ \int_x^{\tau_H} \varphi(y) dF(y) \right\} dG(x), \end{aligned}$$

где измеримая функция  $\varphi: R \rightarrow R$  такова, что  $\int \varphi^2 dF < \infty$ .

Из этого результата следует, например, что  $\sqrt{n}(\hat{v}_1 - v_1)$  и  $\sqrt{n}(\hat{\tau}_1 - \tau_1)$  асимптотически нормальны  $\mathcal{N}(0, \sigma_2^2)$  и  $\mathcal{N}(0, \sigma_3^2)$ , если в качестве функции  $\varphi(x)$  взять  $\varphi_2(x) = \ln(-\ln(1 - F(x)))$  и  $\varphi_3(x) = \ln x$  соответственно.

Из разложения

$$\hat{v}_1 \hat{\tau}_1 - v_1 \tau_1 = \hat{v}_1 (\hat{\tau}_1 - \tau_1) + \tau_1 (\hat{v}_1 - v_1)$$

выводим, что последовательность  $\sqrt{n}(\hat{v}_1 \hat{\tau}_1 - v_1 \tau_1)$  при  $n \rightarrow \infty$  будет асимптотически нормальной  $\mathcal{N}(0, \sigma_4^2)$ , где  $\sigma_4^2 = \sigma_2^2 + \sigma_3^2 + 2\sigma_{23}$ ,  $\sigma_{23} = \lim_{N \rightarrow \infty} \sqrt{n} \mathbf{E}((\hat{v}_1 - v_1)(\hat{\tau}_1 - \tau_1))$ .

Аналогично,  $\sqrt{n}(\hat{v}_1 \hat{\tau}_2 - v_1 \tau_2)$ ,  $\sqrt{n}(\hat{v}_2 \hat{\tau}_1 - v_2 \tau_1)$  и  $\sqrt{n}(\hat{\tau}_1^2 - \tau_1^2)$  будут асимптотически нормальны  $\mathcal{N}(0, \sigma_5^2)$ ,  $\mathcal{N}(0, \sigma_6^2)$  и  $\mathcal{N}(0, \sigma_7^2)$ .

Далее, пусть  $\sqrt{n}(\hat{T}_{1n} - T_1)$  и  $\sqrt{n}(\hat{T}_{2n} - T_2)$  асимптотически нормальны  $\mathcal{N}(0, \sigma_8^2)$ ,  $\mathcal{N}(0, \sigma_9^2)$ . Имеем представление (см. [14]):

$$\begin{aligned} \frac{\hat{T}_{2n}}{\hat{T}_{1n}} - \frac{T_2}{T_1} &= \frac{\hat{T}_{2n} - T_2}{T_1} - \frac{T_2(\hat{T}_{1n} - T_1)}{T_1^2} + \\ &+ O\left(\frac{(\hat{T}_{2n} - T_2)(\hat{T}_{1n} - T_1)}{T_1^2}\right) + \\ &+ O\left(\frac{T_2(\hat{T}_{1n} - T_1)^2}{T_1^3}\right), \end{aligned}$$

из которого следует асимптотическая нормальность последовательностей  $\sqrt{n}(\hat{\alpha} - \alpha)$  и  $\sqrt{n}(\hat{\lambda} - \lambda)$ . Теорема доказана.

В представленных рассуждениях вместо  $\ln(1 - \hat{F}_n(x))$  можно взять другие оценки функции распределения (например, оценки Нельсона–Аалена  $A_n(x)$  [7–9]) и мы получим те же предельные распределения оценок параметров

$\alpha$  и  $\lambda$ , когда используются статистики  $A_n(x)$ , поскольку  $\hat{F}_n$  и  $\exp(-A_n)$  имеют одни и те же предельные распределения. Однако оценка  $S_n^* = \exp(-A_n)$ , являясь асимптотически несмещенной, при конечных  $n$  имеет смещение, и в некоторых случаях ее значения могут сильно отличаться от оценки  $\hat{S}_n(x)$ , поэтому для уменьшения этого смещения предлагается воспользоваться аппроксимациями Паде (см. [15]) для функции  $\ln(1-x)$ . Эти аппроксимации можно найти, воспользовавшись пакетом символьной математики Maple 12. Именно, находим, что

$$Pade[1, 1] = -2x/(2-x),$$

$$Pade[2, 2] = (3x^2 - x)/(6 - 6x + x^2).$$

Для демонстрации точности аппроксимации рассмотрим следующий пример.

Дана выборка объема  $N = 80$  на интервале  $[0, 4]$ , в которой

$z_j$	$d_j$	$c_j$
1	38	1
2	16	2
3	10	2
4	8	3

где  $d_j$  – число отказов в момент  $z_j$  (наблюдалась величина  $X_j$  и  $\delta_j = 1$ ),  $c_j$  – число пристановок в момент  $z_j$  (наблюдалась величина  $T_j$  и  $\delta_j = 0$ ).

Результаты расчетов приведены в таблице.

Таблица

(1)	(2)	(3)	(4)	(5)
1	0.5250	0.6219	0.5364	0.5253
2	0.3200	0.4210	0.3303	0.3204
3	0.1809	0.2725	0.1895	0.1811
4	0.0494	0.1317	0.0604	0.0502

Здесь в первом столбце приведены значения переменной  $x$ , во втором – значения оценки Каплана–Мейера  $\hat{S}(x)$ , в 3-м – значения функции  $\exp(-A_n(x))$ , в 4-м – значения функции  $\exp(-Pade[1, 1])$ , в 5-м – значения функции  $\exp(-Pade[2, 2])$ . Таким образом, представленный пример говорит о том, что уже аппроксимация [2/2] достаточно хорошо приближает оценку КМ.

#### 4. Другие распределения и оценивание их параметров

Подход, аналогичный представленному, можно использовать и для других распределений: распределения, которые являются пре-

дельными для нормированных разностей экстремальных порядковых статистик (см. пп. 4.1 и 4.2), а также для распределений 4.3 и 4.4.

**4.1.** Распределение Фреше (обратное распределение Вейбулла (см. [2], 3.3.3, с. 129):

$$F_1(x) = \exp\left(-\left(\frac{x}{\sigma}\right)^{-\alpha}\right), x > 0, \sigma > 0, \alpha > 0. \text{ Здесь}$$

необходимое преобразование есть  $\ln(-\ln F_1(x)) = -\alpha(\ln x - \ln \sigma)$ .

**4.2.** Распределение Гнеденко–Гумбеля (лог-распределение Вейбулла) (см. [2], 3.3.4, с. 131)

$$F_2(x) = 1 - \exp(-\exp(\alpha(x - \ln \sigma))).$$

Преобразование:

$$\ln(-\ln(1 - F_2(x))) = -\alpha(\ln x - \ln \sigma).$$

**4.3.** Распределение Парето – при больших значениях переменной  $x$  является аппроксимацией распределения Фреше:

$$F_3(x) = 1 - \left(\frac{x}{\sigma}\right)^{-\alpha}, x > \sigma, \sigma > 0, \alpha > 0.$$

Преобразование:

$$\ln(1 - F_3(x)) = -\alpha(\ln x - \ln \sigma).$$

**4.4.** Логистическое распределение. Является сверткой двух распределений 4.2:

$$F_4(x) = \frac{1}{1 + \exp\left(\left(\frac{|x|}{\sigma}\right)^\alpha \cdot \text{sign } x\right)},$$

$$-\infty < x < \infty, \sigma > 0, \alpha > 0.$$

Преобразование:

$$\ln\left(\text{sign } x \cdot \ln \frac{1}{F_4(x)} - 1\right) = \alpha(\ln|x| - \sigma).$$

#### Список литературы

1. Dobson B. The Weibull analysis handbook. ASQ Quality Press, 2006. 167 p.
2. Rinne H. The Weibull distribution. A Handbook. CRC Press, 2009. 762 p.
3. Cohen A.C. Maximum likelihood estimation in the Weibull distribution based on complete and on censored samples // Technometrics. 1965. V. 7, No. 4. P. 579–588.
4. Al-Fawzan M.A. Methods for estimating the parameters of the Weibull distribution. URL: <http://interstat.statjournals.net/YEAR/2000/articles/001001.pdf>.
5. Romeu J.L. Empirical assessment of Weibull distribution // RAC START. V. 10, No. 3. URL: <http://src.alionscience.com/pdf/WEIBULL>.
6. Kaplan E.L., Meier P. Nonparametric estimation from incomplete observations // J. Amer. Statist. Assoc. 1958. V. 53. P. 457–481.

7. Nelson W. Hasard plotting for incomplete failure data // *J. Qual. Tech.* 1969. V. 1. P. 27–52.
8. Aalen O. Nonparametric inference in connection with multiple decrement models // *Scandinavian J. Statist.* 1976. P. 15–27.
9. Aalen O. Nonparametric inference for a family of counting process // *Ann. Statist.* 1978. V. 6, No. 4. P. 701–726.
10. Foldes A., Rejto L. Strong uniform consistency for nonparametric survival curve estimators from randomly censored data // *Ann. Statist.*, 1981. V. 9, No. 1. P. 122–129.
11. Stute W. The statistical Analysis of Kaplan–Meier integrals // *Lecture Notes.* 1995. V. 27. P. 231–254.
12. Stute W. The central limit theorem under random censorship // *Ann. Statist.* 1995. V. 23, No. 2. P. 422–439.
13. Suzukawa A. Asymptotic properties of Aalen–Johansen integrals for competing risk data // *J. Japan Statist. Soc.* 2002. V. 32, No. 1. P. 77–93.
14. Tikhov M.S. Statistical estimation on the basis of interval-censored data // *Journal of Math. Sciences.* 2004. V. 119, No. 3. P. 321–335.
15. Бейкер Дж., Грейс-Моррис П. Аппроксимации Паде. М.: Мир, 1986. 502 с.
16. Breslow N.E. Discussion of professor Cox’s paper // *Journal of the Royal Statistical Society, Series B.* 1972. V. 34. V. 216–217.
17. Тихов М.С. Линейные функции индуцированных порядковых статистик и непараметрическое оценивание распределений в зависимости доза–эффект // *Обозрение прикл. и промышл. мат.* 1999. Т. 6, № 1. С. 244.

### RANDOMLY CENSORED SAMPLE ESTIMATION OF WEIBULL DISTRIBUTION PARAMETERS

*M.S. Tikhov, V.V. Ageev, T.S. Borodina*

The Weibull distribution is an important distribution for reliability and maintainability analysis. Some methods for estimating Weibull parameters, namely, shape parameter  $\alpha$  and scale parameter  $\sigma$  are presented. Consistency and asymptotic normality of the estimations obtained have been proved.

*Keywords:* Weibull distribution, randomly censored sample, parametric estimation, least-square method.