

О.М. Дюсуше

К ВОПРОСУ О ПРОБЛЕМЕ БЕРЕНСА-ФИШЕРА: ПРИМЕНЕНИЕ ПОДХОДА НЕЙМАНА-ПИРСОНА

В отличие от тестирования на значимость гипотезы равенства двух средних приближенными методами и построения доверительных границ (подход Беренса-Фишера-Уэлча) применяется метод тестирования простых альтернативных гипотез (подход Неймана-Пирсона) на основе построения и предварительного анализа точных распределений статистик. Примеры рассчитаны с использованием данных Леманна.

О. Dusouchet

Applying of Neyman-Pearson approach to the problem of Behrens-Fisher

In contrast to test of significance of hypothesis of equality two means for constructing confidence interval by approximate methods (Behrens-Fisher-Welch approach) here is used method of testing simple alternative hypotheses (Neyman-Pearson approach), based on selecting the appropriate statistics and constructing exact distributions. Lehmann's data are used to calculate some examples.

Введение

Беренс (1929) рассматривал задачу о равенстве генеральных средних по малым выборкам из двух независимых нормальных совокупностей $N\{\mu_1, \sigma_1\}$, $N\{\mu_2, \sigma_2\}$. Вопрос построения доверительных границ оказался более сложным, чем в случае Госсета (Стьюдента), что привлекло внимание Фишера и многих других ведущих статистиков к решению этой достаточно актуальной задачи. Введение в проблематику можно найти в Википедии - общедоступных мультязычных универсальных интернет-энциклопедиях, например, на русском, немецком, английском языках. Обзор и обсуждение основных исследований задачи «о двух средних» периода до середины 60-х есть в втором томе монографии Кендалла и Стьюарта (1973, гл. 21). Критерий сравнения средних с соответствующими таблицами можно найти в таблицах Большева и Смирнова (1983). Ким и Кохен (1998) в обзоре более 80-ти публикаций (включая анализ 10-таблиц) по проблеме Беренса-Фишера отмечали, что она стала одной из фокальных точек противоречия трех теоретических подходов: частотного (Нейман-Пирсон (1928, 1933) против фидуциального (Фишер (1935, 1939) и байесовского (Джеффри (1940)), заключив, что не существует никаких конечных решений в рамках рассмотренных работ. Основанием подобного заключения стала серия работ Линника (1963, 1964 и др., англ. 1968/1966) и других авторов, в которых было показано, в том числе, на примере теста Вальда (1955), что однородный наиболее мощный критерий не существует в контексте задачи Беренса-Фишера.

Фишер (1935), будучи сторонником (и создателем) *теста на значимость*, отмечал, что в статистических задачах нулевая гипотеза никогда не может быть доказана или установлена, но может быть опровергнута¹. Также Фишер (1934) утверждал, что, если существует такая достаточная статистика, что функция максимального правдоподобия выборки включает только эту статистику, и ее распределение выражается в терминах функции правдоподобия, то только эти случаи позволяют получать тесты на значимость типа равномерно наиболее мощных тестов Неймана-Пирсона относительно класса альтернатив. Если такой статистики не существует, Фишер рекомендовал искать подходящую статистику, обеспечивающую использование всей необходимой информации, содержащейся в выборке.

Настоящий анализ здесь мотивируется целью построения и сравнения *точных распределений* известных статистик Беренса-Фишера-Уэлча и Вальда в конечном виде, и применения подхода Неймана-Пирсона (1933) для *тестирования простых альтернативных гипотез*. Рей и Питмен [9] получили точное (центральное) распределение статистики Беренса-Фишера для нечетных объемов двумерной выборки в виде взвешенной суммы

¹ Цитируется по “Earliest Uses of Symbols in Probability and Statistics” со ссылкой на работу Фишера “The Design of Experiments” (1935, с. 19). Используемые термины и символы - там же, <http://jeff560.tripod.com/h.html> см. раздел Н – “Hypothesis testing”, “Test of significance” и др.

распределений Стьюдента. Здесь распределения в конечном виде были построены методами Вентцель и Овчарова (1969, гл. 8) путем эквивалентных преобразований монотонных функций от одной или двух независимых случайных величин – к функциям от случайных величин с известными распределениями. Это позволило определить зависимость функции мощности от параметров распределений, в том числе от, так называемого, «мешающего» параметра λ и показать неоднородность ошибки второго рода по паре параметров U и λ . Три рассматриваемые статистики преобразованы одним способом, поэтому вывод функции плотности дан только для первой статистики.

1. Распределение статистики u Уэлча

Распределения статистики u , рассмотренной в статье Уэлча (1938, с.350), и составляющих компонент V и S после ее преобразования проводятся ниже:

$$u = (\bar{x}_1 - \bar{x}_2) / \sqrt{s_1^2 / n_1 + s_2^2 / n_2}, \quad (1)$$

где $\bar{x}_1 = \frac{\sum_{i=1}^{n_1} x_1^i}{n_1}$; $\bar{x}_2 = \frac{\sum_{i=1}^{n_2} x_2^i}{n_2}$; $s_1^2 = \frac{\sum_{i=1}^{n_1} (x_1^i - \bar{x}_1)^2}{n_1 - 1}$; $s_2^2 = \frac{\sum_{i=1}^{n_2} (x_2^i - \bar{x}_2)^2}{n_2 - 1}$ - оценки, состоятельные

и несмещенные, неизвестных параметров μ_1, μ_2, D_1, D_2 двух нормальных распределений.

Распределение числителя $V = (z + U)\sqrt{D_V}$:

$$u = \left(\frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{D_1/n_1 + D_2/n_2}} + \frac{(\mu_1 - \mu_2)}{\sqrt{D_1/n_1 + D_2/n_2}} \right) \frac{\sqrt{D_V}}{\sqrt{\lambda c w_1 + w_2}} = \frac{(z + U)\sqrt{D_V}}{\sqrt{\lambda c w_1 + w_2}} = \frac{V}{Z},$$

$$\lambda = \frac{D_1}{D_2}, \quad c = \frac{n_2(n_2 - 1)}{n_1(n_1 - 1)}, \quad D_V(\lambda) = \frac{D_1/n_1 + D_2/n_2}{D_2 / ((n_2 - 1)n_2)} = \lambda c(n_1 - 1) + (n_2 - 1),$$

$$z \in N(0,1), \quad U = const, \quad V \in N(U\sqrt{D_V}, D_V), \quad f_V(V) = \frac{\exp\left(-\frac{1}{2}(V - U\sqrt{D_V})^2\right)}{\sqrt{2pD_V}}. \quad (2)$$

Плотности распределений выражения $Z=S^2$ и знаменателя $Z=S$ для квантили u

$$w_i = \frac{s_i^2(n_i - 1)}{D_i} \in \chi_{v_i}^2, \quad f_{w_i}(w_i) = \frac{w_i^{v_i/2 - 1} \exp(-w_i/2)}{2^{v_i/2} \Gamma(v_i/2)}, \quad v_i = n_i - 1, \quad i = 1, 2, \quad f_{\lambda c w_1}(y) = \frac{\chi_{v_1}^2(y/\lambda c)}{\lambda c}, \quad \text{где}$$

$w > 0$, $\Gamma(\cdot)$ – гамма-функция; Плотность распределения функции $y = \varphi(x)$ с распределением случайной величины x : $f(x)$, равна: $f_y(y) = f(\psi(y)) |\psi'(y)|$, где $\psi(y)$ – функция обратная к функции $y(x)$; $|\psi'(y)|$ – модуль производной от функции $\psi(y)$. Плотности распределения случайных, независимых величин под корнем S^2 в (1) и величины $Z = \sqrt{S^2}$ равны:

$$f_{S^2}(S^2) = \int_0^{S^2} f_{\lambda c w_1}(y) f_{w_2}(S^2 - y) dy = \int_0^{S^2} \frac{(y/\lambda c)^{\frac{n_1-3}{2}} \exp\left(-\frac{y}{2\lambda c}\right) (S^2 - y)^{\frac{n_2-3}{2}} \exp\left(-\frac{S^2 - y}{2}\right)}{\lambda c \cdot 2^{\frac{n_1-1}{2}} \Gamma\left(\frac{n_1-1}{2}\right) 2^{\frac{n_2-3}{2}} \Gamma\left(\frac{n_2-1}{2}\right)} dy$$

$$f_Z(Z) = Z' f_Z(Z) = 2Z f_{S^2}(Z^2) = 2Z \frac{\int_0^{Z^2} y^{\frac{n_1-3}{2}} (Z^2 - y)^{\frac{n_2-3}{2}} \exp\left(-\frac{y}{2\lambda c} - \frac{Z^2 - y}{2}\right) dy}{(\lambda c)^{\frac{n_1-1}{2}} 2^{\frac{n_1+n_2-2}{2}} \Gamma\left(\frac{n_1-1}{2}\right) \Gamma\left(\frac{n_2-1}{2}\right)} \quad (3)$$

Плотность распределения статистики u (1): $f_u(u) = \int_0^{+\infty} Z \cdot f_V(uZ) f_Z(Z) dZ =$

$$\int_0^{\infty} \int_0^{Z^2} Z^2 y^{\frac{n_1-3}{2}} (Z^2 - y)^{\frac{n_2-3}{2}} \exp \left(-\frac{1}{2} \left(\frac{u \cdot Z}{\sqrt{\lambda c(n_1-1) + n_2 - 1}} - U \right)^2 - \frac{y}{2\lambda c} - \frac{Z^2 - y}{2} \right) dy dZ$$

$$= \frac{\int_0^{\infty} \int_0^{S^2} K(\lambda) S x^{\frac{n_1-3}{2}} (S^2 - x)^{\frac{n_2-3}{2}} \exp \left(-\frac{1}{2} \left(u \frac{S}{\sqrt{D_V(\lambda)}} - U(\delta, \lambda, \sigma_2) \right)^2 - \frac{x}{2\lambda c} - \frac{(S^2 - x)}{2} \right) dx dS}{\sqrt{\pi(\lambda c(n_1-1) + n_2 - 1)} (\lambda c)^{\frac{n_1-1}{2}} 2^{\frac{n_1+n_2-3}{2}} \Gamma\left(\frac{n_1-1}{2}\right) \Gamma\left(\frac{n_2-1}{2}\right)} \quad (4)$$

УТВЕРЖДЕНИЕ: Плотность распределения статистики (1) имеет особенность в окрестности $\delta = \mu_1 - \mu_2 = 0$, или $U = 0$, где плотность распределения определена как функция от одного параметра – отношения дисперсий $\lambda : f_u(u, \lambda \mid n_1, n_2)$; а при $\delta \neq 0$ плотность распределения статистики (1) может быть определена как параметрическая функция от генеральной квантили для выборочных средних U и отношения дисперсий $\lambda : f_u(u, U, \lambda \mid n_1, n_2)$, и в общем случае имеет вид:

$$f_u(u) = \frac{\int_0^{\infty} \int_0^{S^2} K(\lambda) S x^{\frac{n_1-3}{2}} (S^2 - x)^{\frac{n_2-3}{2}} \exp \left(-\frac{1}{2} \left(u \frac{S}{\sqrt{D_V(\lambda)}} - U(\delta, \lambda, \sigma_2) \right)^2 - \frac{x}{2\lambda c} - \frac{(S^2 - x)}{2} \right) dx dS}{\sqrt{\pi(\lambda c(n_1-1) + n_2 - 1)} (\lambda c)^{\frac{n_1-1}{2}} 2^{\frac{n_1+n_2-3}{2}} \Gamma\left(\frac{n_1-1}{2}\right) \Gamma\left(\frac{n_2-1}{2}\right)} \quad (5)$$

Параметрическое представление функции плотности позволяет анализировать альтернативы $U = 0$ и $U \neq 0$, которые определяют $\delta = 0$ и $\delta \neq 0$.




Рис. 1. Зависимость плотности $u(\lambda)$ в точке $u=U1$ ($\mu_1 - \mu_2, D_1, D_2$). Расчеты Mathcad-14 ($\lambda=y$)

2. Распределение статистики v Беренса-Фишера

Статистика v Беренса-Фишера, рассмотренная в таблицах [4, с. 204] имеет вид:

$$v = \frac{(\bar{x}_1 - \bar{x}_2) - (\mu_1 - \mu_2)}{\sqrt{s_1^2/n_1 + s_2^2/n_2}} \quad (6)$$

Эквивалентными преобразованиями статистика v (6) приводится к виду, зависящему только от параметра отношения дисперсий λ :

$$v = \frac{z \sqrt{D_V}}{\sqrt{\lambda c w_1 + w_2}}, \quad z \in N(0,1), \quad w_i \in \chi_{n_i-1}^2, \quad i = 1, 2,$$

Аналогично порядку, показанному в п.1 получена плотность распределения $f(v)$, которая имеет вид:

$$f_v(v, \lambda \mid n_1, n_2) = \int_0^{\infty} \int_0^{S^2} K(\lambda) S x^{\frac{n_1-3}{2}} (S^2 - x)^{\frac{n_2-3}{2}} \exp \left(-\frac{1}{2} \left(u \frac{S}{\sqrt{D_V(\lambda)}} \right)^2 - \frac{x}{2\lambda c} - \frac{(S^2 - x)}{2} \right) dx dS \quad (7)$$

Сравнение распределения статистик u и v : (5) и (7) показывает, что в выражении (7) параметр $U=0$, $\delta=0$, и плотность распределения зависит только от отношения дисперсий, но не их размера.

3. Тест Вальда

Вальд [11] исследовал проблему равенства средних и критический регион для статистики, удовлетворяющей требованиям достаточности и инвариантности, в виде неравенства:

$$(\bar{x}_1 - \bar{x}_2) / \sqrt{s_1^2 + s_2^2} \geq \varphi(s_2^2 / s_1^2) \quad (8)$$

Эквивалентные преобразования статистики W (8) и распределения ее компонент показывают, что $D_v > D_w$, $c = c_w n_2 / n_1$. Соотношение рассеивания статистик (1) и (8) зависит от соотношения объемов выборки. В примере Леманна рассеивание статистики (8) меньше чем у (1), т.е. статистика (8) более эффективна.

$$u_w = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s_1^2 + s_2^2}} = \left(\frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{D_1/n_1 + D_2/n_2}} + \frac{(\mu_1 - \mu_2)}{\sqrt{D_1/n_1 + D_2/n_2}} \right) \cdot \frac{\sqrt{D_1/n_1 + D_2/n_2}}{\sqrt{D_2/(n_2-1)} \sqrt{C_w w_{v1} + w_{v2}}} = \frac{(z+U)\sqrt{D_w}}{\sqrt{c_w w_1 + w_2}}$$

$$\lambda = \frac{D_1}{D_2}, \quad u = \frac{(z+U)\sqrt{D_w}}{\sqrt{c_w w_1 + w_2}} = \frac{W}{S}, \quad c_w(\lambda) = \lambda \frac{(n_2-1)}{(n_1-1)} = \lambda c_w, \quad D_w(\lambda) = \lambda c_w \frac{(n_1-1)}{n_1} + \frac{(n_2-1)}{n_2},$$

Аналогичные выкладки позволяют получить плотность распределения статистики Вальда (9)

$$f_w(W, U, \lambda) = \frac{\int_0^{\infty} \int_0^{S^2} S^2 y^{\frac{n_1-3}{2}} (S^2 - y)^{\frac{n_2-3}{2}} \exp \left[-\frac{1}{2} \left(\frac{uS}{\sqrt{\lambda c_w \frac{n_1-1}{n_1} + \frac{n_2-1}{n_2}}} - U \right)^2 - \frac{y}{2\lambda c_w} - \frac{S^2 - y}{2} \right] dy dS}{\sqrt{\pi \left(\lambda c_w \frac{n_1-1}{n_1} + \frac{n_2-1}{n_2} \right)} (\lambda c_w)^{\frac{n_1-1}{2}} 2^{\frac{n_1+n_2-3}{2}} \Gamma\left(\frac{n_1-1}{2}\right) \Gamma\left(\frac{n_2-1}{2}\right)}$$

Распределение статистики φ в правой части неравенства (8) зависит только от величины, имеющей распределение Фишера и от параметра отношения дисперсий λ , то есть, принадлежит к однопараметрическому семейству. Статистика Вальда в левой части критерия (8) аналогично статистике Уэлча может рассматриваться в двухмерном $\{U, \lambda\}$ параметрическом пространстве. Фактически, в неопубликованной задаче Вальд должен был прийти к ограничению функции мощности, определенной в двухмерном пространстве, посредством критерия, определенного в одномерном пространстве. В исследованиях Линника и Шалаевских было показано, что в задаче Беренса-Фишера критериев подобных по размеру критерия и параметрам (σ_1, σ_2) не существует, что соответствует заключению Линника о невозможности существования теста Вальда подобного относительно счетного ограниченного множества значений $\lambda = \sigma_1^2 / \sigma_2^2$.

Функция плотности статистики Вальда позволяет определить математическое ожидание и дисперсию. Графически можно показать, что при прочих равных распределение f_w более компактно, и поэтому статистика Вальда предпочтительнее статистики Уэлча. На рис. 2. приведены распределения плотности Вальда и Уэлча, соответствующие гипотезам: $H_0: U_0 = 0, \lambda = 30.644$, и $H_1: U_1 = 2.143, \lambda = 30.644$.

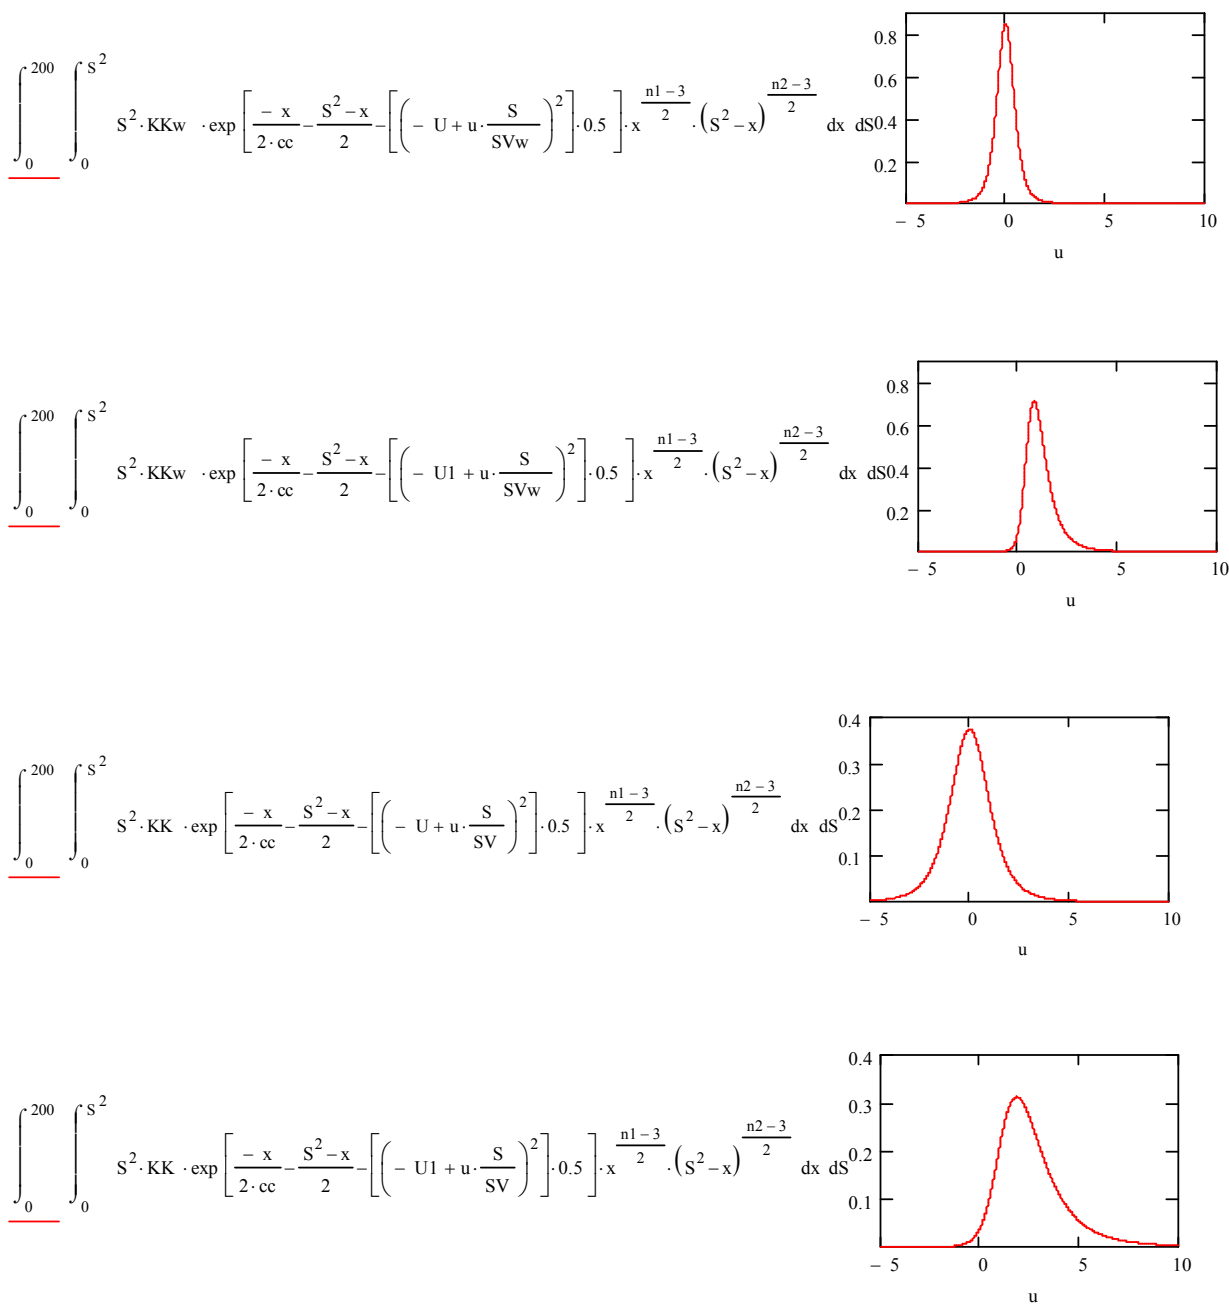


Рис. 2 Распределения плотности статистик (1) и (8) при $U=0$, и $U1=(d/S)=2.143$ в примере Леманна

4. Проверка простых альтернативных гипотез в задаче Беренса-Фишера на основе подхода Неймана-Пирсона

Простой гипотезой относительно распределения случайных величин согласно Крамеру [6, с.574] называется *точка* в пространстве параметров распределения этих величин. Простые альтернативные гипотезы как точки в 2-х мерном пространстве параметров, позволяют определить гипотезы и *критерий тестирования* двух распределений с параметрами, соответствующими гипотезам H_0 и H_1 . Константа k ограничивает область интегрирования по u , и определяет уровень ошибок первого и второго рода. Если выборочная квантиль u не попадает в область вокруг нуля, это означает, что альтернативная гипотеза более вероятна, чем нулевая. Достаточно малые ошибки должны обеспечиваться соответствием объемов выборки и параметров адекватной и приемлемой альтернативы^(*):

$$\begin{cases} H_0 : \delta = 0, \lambda = \lambda_0 \Rightarrow \text{если } |u| < k, \text{ принимают } H_0; \\ H_1 : \delta = \delta_1, \lambda = \lambda_1, \sigma_2 = \sigma_{21} \Rightarrow \text{если } |u| \geq k, \text{ принимают } H_1. \end{cases}$$

Система уравнений рисков при *размере* (α) и *мощности* ($1 - \beta$) критерия имеет вид:

$$\begin{cases} \int_{-k}^k f_W(u, n_1, n_2, \lambda \setminus H_0) du = 1 - \alpha \\ \int_{-k}^k f_W(u, n_1, n_2, \lambda, \sigma_2 \setminus H_1) du = \beta \end{cases}$$

Решение уравнения при выполнении условия (*) в общем случае целесообразно объединить с целочисленным решением задачи планирования оптимальных объемов испытаний, т.к. задание уровня ошибок первого и второго рода, обоснование альтернативной гипотезы и выбор объемов испытаний взаимосвязаны.

Интервал $[-k, k]$ определяет дополнение к критической области. Нейман и Пирсон [11] при заданном объеме испытаний советуют задать ошибку первого рода, и проверять приемлемость ошибки второго рода. В этой задаче мы вынуждены поступить наоборот – определить $k=2.87$ из условия $\beta=0.05$ (при $H_1 : U1=2,5$):

$$\int_{-k}^k \int_0^{200} \int_0^{S^2} S^2 \cdot KKw \cdot \exp\left[\frac{-x}{2 \cdot cc} - \frac{S^2 - x}{2} - \left[(-U1 + u \cdot \frac{S}{SVw})^2\right] \cdot 0.5\right] \cdot x^{\frac{n1-3}{2}} \cdot (S^2 - x)^{\frac{n2-3}{2}} dx dS du = 0.9505976$$

$$\int_{-k}^k \int_0^{200} \int_0^{S^2} S^2 \cdot KKw \cdot \exp\left[\frac{-x}{2 \cdot cc} - \frac{S^2 - x}{2} - \left[u \cdot \frac{S}{SVw}\right]^2 \cdot 0.5\right] \cdot x^{\frac{n1-3}{2}} \cdot (S^2 - x)^{\frac{n2-3}{2}} dx dS du = 0.9976267$$

В этом случае $k=2.87$ и $\text{Вер}(u > k / H_1) = 1 - \beta = 0.95$ и $\text{Вер}(u > k / H_0) = \alpha = 0.002$. Принимается нулевая гипотеза если выборочная квантиль ограничена значением k .

Почему не существует однородного наиболее мощного критерия для проверки абсолютной разности средних? Во-первых, из функции правдоподобия двумерной выборки при четырех неизвестных параметрах не удастся выделить зависимость от разности средних, $\delta = \mu_1 - \mu_2$. Согласно рекомендациям Фишера рассматриваются критерии, основанные не на функции правдоподобия, а на функции от достаточных статистик выборки. В качестве «хорошей» статистики выбрана статистика Вальда (1955)².




Рис.3. Функции мощности критерия в зависимости от квантили U по для 4-х значений λ .

Во вторых, если из некоторых прагматических соображений исследователь выбирает альтернативную гипотезу H_1 , то не для всех параметров λ равномерно обеспечивается

² Статистика Уэлча описывает вероятность непревышения средних значений $\text{Вер}(\bar{x}_2 < \bar{x}_1)$, а статистика Вальда вероятность непревышения единичных реализаций $\text{Вер}(x_2 < x_1)$. Оба распределения зависят от параметра разности генеральных средних $\mu_1 - \mu_2$.

размер критерия α . Невозможно построить равномерно мощный критерий для какой-либо области λ (например, по горизонтали уровня 0,05).

Библиографический список

1. Большев Л.Н., Смирнов Н.В. Таблицы математической статистики. – М.: Наука, 1983.
2. Вентцель Е.С., Овчаров Л.А. Теория вероятностей. Гл.8. – М.: Наука, 1969.
3. Кендалл М. Дж., Стьюарт А. Статистические выводы и связи. – М.: Наука, 1973.
4. Крамер Г. Математические методы статистики. – М.: Мир, 1975.
5. Линник Ю.В., Шалаевский О.В. К аналитической теории тестов для проблемы Беренса-Фишера Доклады Академии наук СССР, 1963, Том 150, №.1.
6. Линник Ю.В. О тесте А. Вальда для сравнения двух нормальных выборок Теория вероятностей и ее применение. – 1964. – № 9. – С. 16-30.
7. Behrens, W.V. Ein Beitrag zur Fehlerberechnung bei wenigen Beobachtungen// *Landwirtsch. Jahrbücher* 68, 1929. – pp. 807–837.
8. Fisher R. Two new properties of mathematical likelihood// *Proceedings of the Royal Society*, 1934. – A, 144: 285-307.
9. Fisher R. Fiducial argument in statistical inference// *Annals of Eugenics*, 1935, 6: 391-398.
<http://digital.library.adelaide.edu.au/dspace/handle/2440/15222>
10. Kim S-H, Cohen A.S. On the Behrens-Fisher Problem: A Review // *Journal of Educational and Behavioral Statistics*, Winter. – 1998. – Vol. 23. – No. 4. – pp. 356-377.
11. Neyman J., E.S. Pearson. On the Problem of the Most Efficient Test of Statistical Hypotheses// *Philosophical Transactions of the Royal Society, Series A.* (1934) 1933. – Vol. 231, pp. 289-337.
12. Ray, W. D. and Pitman, E. N. T. An Exact Distribution of the Fisher-Behrens-Welch Statistic// *Journal of the Royal Statistical Society*, 23 (1961).
13. Wald A. Testing the difference between the means of two normal populations with unknown standard deviations// *Selected papers in statistics and probability by Abraham Wald.* – pp. 669–695. McGraw-Hill Book, Co., Inc. New York-Toronto-London, 1955. Цит. по *Mathematical Reviews on the Web* (MathSciNet, MR0070918).
14. Welch, B.L. The Significance of the Difference Between Two Means when the Population Variances are Unequal// *Biometrika*, 1938. – Vol. 29. – No. – Feb. – pp. 350-362.