

УДК 519.21

С. А. МАТВЕЙЧУК, мл. науч. сотр.,
Ю. И. ПЕТУНИН, д-р физ.-мат. наук (Киев. ун-т)

Обобщение схемы Бернулли, возникающее в вариационной статистике. II

Изучается частота появления событий в модифицированной схеме Бернулли при предположении $F_x(u) \equiv F_y(u)$. Предлагается критерий однородности двух выборок, основанный на свойствах этой частоты и исследуются его свойства.

Вивчається частота появи подій у модифікованій схемі Бернуллі з припущенням, що $F_x(u) \equiv F_y(u)$. Пропонується критерій однорідності двох виборок, який ґрунтується на властивостях цієї частоти і досліджуються його властивості.

Введение. Пусть $\bar{x} = (x_1, \dots, x_n)$ и $\bar{y} = (y_1, \dots, y_m)$ — независимые выборки, полученные путем простого случайного выбора из генеральных совокупностей G_x и G_y с непрерывными строго возрастающими функциями распределения $F_x(u)$ и $F_y(u)$ соответственно. Построим по выборке \bar{x} вариационный ряд $x^{(0)} < x^{(1)} \leq \dots \leq x^{(n)} < x^{(n+1)}$ ($x^{(0)} = -\infty$, $x^{(n+1)} = \infty$) и рассмотрим случайный интервал $\mathcal{I}_{i,q} = (x^{(i)}, x^{(i+q)}]$, где i, q — фиксированные числа ($1 \leq q \leq n$, $0 \leq i \leq n - q + 1$). Предположим, что $F_x(u) \equiv F_y(u)$. Схему испытаний, в которой на k -м шаге событие $A_k = \{y_k \in$

© С. А. МАТВЕЙЧУК, Ю. И. ПЕТУНИН, 1991

$\in \mathcal{J}_{i,q}$ (y_k — элемент выборки \bar{y}) происходит или не происходит, назовем модифицированной схемой Бернулли, построенной по выборкам \bar{x} и \bar{y} . Пусть $\kappa_{i,q}$ — число событий A_k , реализовавшихся в серии из m испытаний (m — объем выборки \bar{y}). Случайная величина $\kappa_{i,q}$ изучалась в работе [1], где найдено ее распределение и исследованы ее асимптотические свойства при различных способах стремления n и m , объемов выборок \bar{x} и \bar{y} к бесконечности. Там же введено понятие обобщенной схемы Бернулли как модифицированной схемы Бернулли, в которой $F_x(u) \equiv F_y(u)$. Настоящая статья является продолжением [1]. Она посвящена изучению свойств статистики $\kappa_{i,q}$ в обобщенной схеме Бернулли (п. 2), а так же построению критерия однородности выборок \bar{x} и \bar{y} , основанного на этой статистике (п. 3).

Понятия и обозначения работы — такие же, как и в статье [1].

2. *Обобщенная схема Бернулли.* В этой схеме $F_x(u) \equiv F_y(u)$, поэтому идентификатор генеральных совокупностей [1] $\tilde{G}(v) = F_y[F_x^{-1}(v)]$, $v \in [0, 1]$, будет тождественно равен v : $G(v) \equiv v$, $v \in [0, 1]$. Учтывая этот факт, сформулируем такое определение обобщенной схемы Бернулли.

Определение 1. Обобщенной схемой Бернулли называется такая модифицированная схема Бернулли, для которой идентификатор генеральных совокупностей есть единичное отображение отрезка $[0, 1]$ в себя.

На основании этого определения все утверждения, справедливые для модифицированной схемы Бернулли, непосредственно переносятся на обобщенную схему Бернулли.

Условимся в дальнейшем для случайной величины $\kappa_{i,q}$ в обобщенной схеме Бернулли использовать обозначение $\chi_{i,q}$.

Из теоремы 1, § 1, [1] путем замены $G(v)$ на v и вычисления полученных интегралов можно получить следующее утверждение.

Утверждение 1. В обобщенной схеме испытаний Бернулли случайная величина $\chi_{i,q}$ имеет следующее распределение вероятностей:

$$P(\chi_{i,q} = l) = \frac{q}{q+l} \frac{C_m^l C_n^q}{C_{m+n}^{l+q}}, \quad l = 0, 1, \dots, m, \quad (1)$$

где n, m — объемы выборок, \bar{x}, \bar{y} соответственно; i, q — фиксированные числа ($1 \leq q \leq n$, $0 \leq i \leq n - q + 1$), определяющие интервал $\mathcal{J}_{i,q}$; C_m^n — число сочетаний из m по n .

Распределение (1) впервые получено Эпштейном для интервала $\mathcal{J}_{0,q} = (-\infty, x^{(q)})$ [2].

Из (1) следует, что математическое ожидание $E(\chi_{i,q})$ и дисперсия $D(\chi_{i,q})$ случайной величины $\chi_{i,q}$ равны:

$$E(\chi_{i,q}) = mp_q, \quad (2)$$

$$D(\chi_{i,q}) = \frac{m(m+n+1)}{n+2} p_q(1-p_q), \quad (3)$$

где

$$p_q = \frac{q}{n+1}. \quad (4)$$

Будем изучать асимптотические свойства $\chi_{i,q}$. Пусть сначала n — объем выборки \bar{x} — является фиксированной величиной, а m — объем выборки \bar{y} — неограниченно возрастает. Вместо случайной величины $\chi_{i,q}$ будем рассматривать частоту $h_{i,q} = \chi_{i,q}/m$; тогда из теоремы 4, § 1, [1] вытекает такое утверждение.

Утверждение 2. В обобщенной схеме испытаний Бернулли при фиксированном n и $m \rightarrow \infty$ частота $h_{i,q}$ сходится по распределению к непрерывной случайной величине h_n , имеющей следующую функцию распределения:

$$P(h_n \leq x) = I_x(q, n - q + 1), \quad x \in [0, 1], \quad (5)$$

где

$$I_x(q, n - q + 1) = B^{-1}(q, n - q + 1) \int_0^x t^{q-1} (1-t)^{n-q} dt \quad (6)$$

— функция бета-распределения [3], $B(q, n - q + 1) = \int_0^1 t^{q-1} (1-t)^{n-q} dt$ — бета-функция Эйлера [3].

Пусть теперь m фиксировано, а n неограниченно возрастает. Из теоремы 7, § 1, [1] путем замены $G(v)$ на v вытекает следующее утверждение.

Утверждение 3. Если в обобщенной схеме Бернулли интервал $\mathcal{E}_{i,q}$ выбран таким образом, что при $n \rightarrow \infty$ $i/(n+1) \rightarrow p^*$, $q/(n+1) \rightarrow p_0$ ($p^*, p_0 \in (0, 1)$), то при фиксированном m и $n \rightarrow \infty$ случайная величина $\chi_{i,q}$ сходится по распределению к случайной величине v_m , имеющей следующую функцию распределения:

$$P(v_m \leq k) = B_m(k, p_0), \quad k = 0, 1, \dots, m; \quad (7)$$

где

$$B_m(k, p_0) = \sum_{l=0}^k C_m^l p_0^l (1-p_0)^{m-l} \quad (8)$$

— функция биномиального распределения [4].

Рассмотрим теперь $\chi_{i,q}$, когда n и m стремятся к бесконечности одновременно. Введем нормированную случайную величину

$$\xi_{i,q} = (\chi_{i,q} - E(\chi_{i,q})) / \sqrt{D(\chi_{i,q})}.$$

Из теоремы 10, § 1, [1] получим такое утверждение.

Утверждение 4. В обобщенной схеме испытаний Бернулли при $n \rightarrow \infty$ и $m \rightarrow \infty$, если

$$i/(n+1) \rightarrow p^*, \quad q/(n+1) \rightarrow p_0 \quad (p^*, p_0 \in (0, 1)),$$

то случайная величина $\xi_{i,q}$ сходится по распределению к случайной величине ξ_0 , имеющей стандартное нормальное распределение

$$P(\xi_0 \leq x) = \Phi(x), \quad x \in R^1, \quad (9)$$

где

$$\Phi(x) = (\sqrt{2\pi})^{-1} \int_{-\infty}^x e^{-y^2/2} dy. \quad (10)$$

Рассмотрим поведение $\chi_{i,q}$ при $m \rightarrow \infty$, $n \rightarrow \infty$, но интервал $\mathcal{E}_{i,q}$ при этом будем выбирать так, чтобы $i/(n+1) \rightarrow p^*$, а q было фиксированным числом.

Тогда из теоремы 13, § 1 [1] следует утверждение 5.

Утверждение 5. В обобщенной схеме испытаний Бернулли при $m, n \rightarrow \infty$, если

$$m/(n-2) \rightarrow r \quad (r \in R^+), \quad i/(n+1) \rightarrow p^* \quad (p^* \in (0, 1)),$$

q фиксировано, то случайная величина $\chi_{i,q}$ сходится по распределению к случайной величине η_q , имеющей следующую функцию распределения:

$$P(\eta_q \leq k) = F_q(k) \equiv \sum_{l=0}^k C_{l+q-1}^l \frac{r^l}{(1+r)^{l+q}}, \quad k = 0, 1, \dots; \quad (11)$$

где $F_q(k)$ — функция отрицательного биномиального распределения [4].

Этим исследованием статистики $\chi_{i,q}$ обобщенной схемы Бернулли завершено.

3. Некоторые критерии однородности двух выборок. Используя свойства статистик $\chi_{i,q}$ и $\xi_{i,q}$, можно предложить ряд критериев однородности двух выборок. Рассмотрим некоторые из них.

Пусть \bar{x} и \bar{y} — две независимые выборки объема n и m соответственно, принадлежащие генеральным совокупностям G_x и G_y с функциями распределения $F_x(u)$ и $F_y(u)$. Будем считать, что $F_x(u)$ и $F_y(u)$ являются непрерывными, строго возрастающими функциями. Тогда существует идентификатор генеральных совокупностей $G(v) = F_y[F_x^{-1}(v)]$, который является непрерывно строго возрастающей функцией, отображающей отрезок $[0, 1]$ в себя. Обозначим через $\mathcal{G}[0, 1]$ класс всех таких функций $G(v)$. Проблема однородности двух выборок состоит в следующем: является ли идентификатор генеральных совокупностей $G(v)$ единственным отображением $I[0, 1]$, отображающим отрезок $[0, 1]$ в себя; или же $G(v)$ принадлежит классу $\mathcal{G}[0, 1] \setminus I[0, 1]$. Назовем первое предположение основной гипотезой $H_0 = \{G(v) \equiv v, v \in [0, 1]\}$, а второе предположение — сложной альтернативной гипотезой $H_1 = \{G(v) \in \mathcal{G}[0, 1] \setminus I[0, 1]\}$.

Для того чтобы построить критерий или тест проверки гипотезы H_0 против альтернативы H_1 , воспользуемся статистиками $\chi_{i,q}$ и $\chi_{i,q}^*$. В силу того что распределение $\chi_{i,q}$ не зависит от функций распределения выборок $F_x(u)$ и $F_y(u)$ (см. утверждения 1—5, 2), построим доверительный интервал $\mathcal{J}(\chi_{i,q}) = (\chi_{i,q}^H, \chi_{i,q}^P)$, симметричный относительно математического ожидания $\chi_{i,q}$ и содержащий основную массу значений случайной величины $\chi_{i,q}$ с заданным уровнем значимости 2β :

$$\chi_{i,q}^H = E(\chi_{i,q}) - a\sqrt{D(\chi_{i,q})}, \quad (12)$$

$$\chi_{i,q}^P = E(\chi_{i,q}) + a\sqrt{D(\chi_{i,q})},$$

где $E(\chi_{i,q})$, $D(\chi_{i,q})$ — математическое ожидание и дисперсия случайной величины $\chi_{i,q}$ (см. (2) — (4)); величина a определяется из соотношения

$$P(\chi_{i,q} \in \mathcal{J}(\chi_{i,q})) = 1 - 2\beta. \quad (13)$$

Предлагается следующий критерий проверки гипотезы H_0 против альтернативы H_1 :

1) выбирается два натуральных числа q и i , где $1 \leq q \leq n$, $0 \leq i \leq n - q + 1$, n — объем выборки \bar{x} ;

2) по заданному уровню значимости 2β и числам i, q , исходя из распределения (1) или одной из его аппроксимаций (утверждения 1—5), строится доверительный интервал $\mathcal{J}(\chi_{i,q})$ согласно формулам (12)—(13);

3) по выборке \bar{x} строится вариационный ряд, а по числам i и q — случайный интервал $\mathcal{J}_{i,q} = (x^{(i)}, x^{(i+q)})$;

4) вычисляется значение статистики $\theta_{i,q}$, равное числу элементов выборки \bar{y} , попавших в интервал $\mathcal{J}_{i,q}$;

5) если $\theta_{i,q} \in \mathcal{J}(\chi_{i,q})$, то принимается гипотеза H_0 ; в противном случае принимается гипотеза H_1 .

Из описания предложенного критерия следует, что независимые выборки \bar{x} и \bar{y} образуют модифицированную схему Бернулли, если имеет место гипотеза H_1 .

Статистика критерия $\theta_{i,q}$ при справедливости гипотезы H_1 совпадает со статистикой $\chi_{i,q}$, изученной в § 1 [1], а если верна гипотеза H_0 — со статистикой $\chi_{i,q}$, изученной в п. 2.

Критической областью критерия является интервал $\bar{\mathcal{J}}(\chi_{i,q}) = R^1 \setminus \mathcal{J}(\chi_{i,q})$, при этом $P(\bar{\mathcal{J}}(\chi_{i,q})/H_0) = 2\beta$. Поэтому в дальнейшем описанный критерий будем именовать как тест $\bar{\mathcal{J}}(\chi_{i,q})$ размера 2β .

Исследуем свойства этого теста. Предположим, что имеет место гипотеза H_1 . Обозначим $h_{i,q} = \theta_{i,q}/m$. Если учесть выражения для математического ожидания и дисперсии $\chi_{i,q}$ (см. (14)—(15) § 1 [1]), то из предложения 2 (см. введение [1]) следует

$$E(h_{i,q}/H_1) = p_{i,q} + O(n^{-1}), \quad (14)$$

$$D(h_{i,q}/H_1) = p_{i,q}(1 - p_{i,q})/m + O(n^{-1}), \quad (15)$$

где

$$p_{i,q} = G\left(\frac{i+q}{n+1}\right) - G\left(\frac{i}{n+1}\right). \quad (16)$$

Поскольку функция $G(v)$ непрерывна на отрезке $[0, 1]$, а $i/(n+1) \rightarrow p^*$, $q/(n+1) \rightarrow p_0$ ($p^*, p_0 \in (0, 1)$), когда $n \rightarrow \infty$, то

$$E(h_{i,q}/H_1) \rightarrow p_1 \equiv G(p^* + p_0) - G(p^*), \quad (17)$$

$$D(h_{i,q}/H_1) \rightarrow 0 \quad (18)$$

при $m, n \rightarrow \infty$.

Пусть теперь имеет место гипотеза H_0 , тогда согласно результатам п. 2 математическое ожидание и дисперсия $\theta_{i,q}$ определяются выражениями (3) и (4) соответственно и при $m, n \rightarrow \infty$, когда $q/(n+1) \rightarrow p_0 \in (0, 1)$,

$$E(h_{i,q}/H_0) \rightarrow p_0, \quad (19)$$

$$D(h_{i,q}/H_0) \rightarrow 0, \quad (20)$$

где $h_{i,q} = \theta_{i,q}/m$.

Из соотношений (17)–(20) на основании неравенства Чебышева [5] следует такая теорема.

Теорема 1. Если при $m, n \rightarrow \infty$ $i/(n+1) \rightarrow p^* \in (0, 1)$, $q/(n+1) \rightarrow p_0 \in (0, 1)$, то 1) в случае истинности гипотезы H_1 частота $h_{i,q}$ сходится по вероятности к $p_1 = G(p^* + p_0) - G(p^*)$; 2) в случае истинности гипотезы H_0 частота $h_{i,q}$ сходится по вероятности к p_0 .

Исследуем состоятельность теста $\bar{J}(X_{i,q})$. Для этого покажем, что при $m, n \rightarrow \infty$

$$P(\bar{J}(X_{i,q})/H_1) \rightarrow 1.$$

Согласно (12)–(13)

$$P(\bar{J}(X_{i,q})/H_1) = P(X_{i,q} \leq mp_q - a\sqrt{p_q(1-p_q)m(m+n+1)/(n+2)}) + \\ + P(X_{i,q} \geq mp_q + a\sqrt{p_q(1-p_q)m(m+n+1)/(n+2)}).$$

На основании теоремы 9, §1 [1] при $m, n \rightarrow \infty$ имеет место следующее асимптотическое равенство:

$$P(\bar{J}(X_{i,q})/H_1) = \Phi\left(\frac{p_q - p_{i,q}}{V D(h_{i,q})} - a\sqrt{\frac{(m+n+1)p_q(1-p_q)}{(n+2)mD(h_{i,q})}}\right) + \\ + \Phi\left(\frac{p_{i,q} - p_q}{V D(h_{i,q})} + a\sqrt{\frac{(m+n+1)p_q(1-p_q)}{(n+2)mD(h_{i,q})}}\right), \quad (21)$$

где $p_{i,q} = G\left(\frac{i+q}{n+1}\right) - G\left(\frac{i}{n+1}\right)$; $D(h_{i,q})$ — дисперсия случайной величины $h_{i,q}$ в случае истинности гипотезы H_1 ; $\Phi(u)$ — функция стандартного нормального распределения.

Если предположить, что $p_0 > p_1$ ($p_0 < p_1$) (см. теорему 1), то для достаточно больших m и n справедливо неравенство $p_q > p_{i,q}$ ($p_q < p_{i,q}$). Из него с учетом предельных соотношений (17)–(18) получаем, что $P(\bar{J}(X_{i,q})/H_1) \rightarrow 1$.

Таким образом, тест $\bar{J}(X_{i,q})$ будет состоятелен при условии $p_0 > p_1$ ($p_0 < p_1$). Рассмотрим подробнее это условие. Согласно (17) $p_1 - p_0 = G(p^* + p_0) - G(p^*) - p_0$.

Поскольку $G(v) \in \mathcal{G}[0, 1]$, то почти всюду в $[0, 1]$ существует суммируемая конечная производная $G'(v) \equiv g(v)$, поэтому $p_1 - p_0 = \int_E (g(v) - 1) dv$, где $E \subset (p^*, p^* + p_0)$, $\mu E = p_0$ (μE означает Лебегову меру множества E). Для того чтобы интеграл, стоящий в правой части последнего равенства, был строго положителен (строго отрицателен), достаточно потребовать, чтобы почти всюду в E выполнялось неравенство $g(v) \geq 1$ ($g(v) \leq$

≤ 1), а множество точек E_1 , на котором имеет место строгое неравенство, имело бы положительную меру.

Определим класс $\mathcal{G}[p^*, p^* + p_0] \subset \mathcal{G}[0, 1]$ функций $G(v)$ следующим образом: 1) почти всюду в интервале $(p^*, p^* + p_0)$ $G'(v) \geq 1$ ($G'(v) \leq 1$); 2) множество точек v таких, что $G'(v) > 1$ ($G'(v) < 1$), $v \in (p^*, p^* + p_0)$, имеет положительную меру.

Рассмотрим гипотезу

$$H_1^* = \{G(v) \in \mathcal{G}[p^*, p^* + p_0]\},$$

тогда в силу изложенного выше справедлива теорема.

Теорема 2. Если интервал $\mathcal{I}_{i,q}$ выбран таким образом, что при $n \rightarrow \infty$ $i/(n+1) \rightarrow p^*$, $q/(n+1) \rightarrow p_0$ ($p^*, p_0 \in (0, 1)$), то при $m, n \rightarrow \infty$ тест $\bar{J}(\chi_{i,q})$ для проверки гипотезы H_0 будет состоятелен против альтернативы H_1^* .

Из теоремы 2 следует, что при фиксированном интервале $\mathcal{I}_{i,q}$ в общем случае тест $\bar{J}(\chi_{i,q})$ не будет состоятельным против альтернативы H_1 . Однако, при фиксированном n существует $N = [n(n+1)/2]$ интервалов вида $\mathcal{I}_{i,q} = (x^{(i)}, x^{(i+q)})$ ($[x]$ означает целую часть числа x).

Обозначим через $\mathcal{I}_N(\bar{x})$ класс всех интервалов $\mathcal{I}_{i,q} = (x^{(i)}, x^{(i+q)})$, которые можно построить с помощью любых двух порядковых статистик при фиксированном n :

$$\mathcal{I}_N(\bar{x}) = \{\mathcal{I}_{i,q} : \mathcal{I}_{i,q} = (x^{(i)}, x^{(i+q)}), 1 \leq q \leq n, 0 \leq i \leq n - q + 1\}.$$

Справедлива такая теорема.

Теорема 3. В классе $\mathcal{I}_N(\bar{x})$ существует такой интервал \mathcal{I}_{i^*,q^*} , что при условиях $i^*/(n+1) \rightarrow p^*$, $q^*/(n+1) \rightarrow p_0$ ($p^*, p_0 \in (0, 1)$), когда $n \rightarrow \infty$, тест $\bar{J}(\chi_{i^*,q^*})$ гипотезы H_0 будет состоятельным против альтернативы H_1 при $m, n \rightarrow \infty$.

Доказательство. Предположим, что имеет место гипотеза H_1 . Тогда $G(v) \neq v$ и $G(v)$ — непрерывная строго возрастающая функция. Рассмотрим функцию $H(v) = G(v) - v$, которая является непрерывной с конечным изменением. Следовательно, почти всюду в $[0, 1]$ существует конечная производная $H'(v)$, которая является суммируемой функцией. Выберем точку $v_0 \in [0, 1]$ такую, что $H'(v_0) \neq 0$. Существование указанной точки v_0 следует из того, что $G(v) \neq v$; но тогда на основании известной теоремы анализа (см., например, [6, с. 223]) получаем, что существует окрестность точки

$$V_{0,\varepsilon} = (v_0 - \varepsilon, v_0 + \varepsilon) \subset [0, 1],$$

в которой функция $H(v)$ строго монотонна. Среди всех точек v_0 , в которых $H'(v) \neq 0$, выберем точку v_0^* , имеющую наибольшую связную открытую окрестность $V_{0^*,\varepsilon^*} = (v_0^* - \varepsilon^*, v_0^* + \varepsilon^*) \subset [0, 1]$, в которой функция $H(v)$ монотонна.

Зафиксируем ε^* и точку v_0^* . Положим $q^* = [2\varepsilon^*(n+1)]$, $i^* = [(v_0^* - \varepsilon^*)(n+1)]$ и построим интервал $\mathcal{I}_{i^*,q^*} = [(x^{(i^*)}, x^{(i^*+q^*)})]$. В силу выбора ε^* и v_0^* справедливы неравенства $1 \leq q^* \leq n$, $0 \leq i^* \leq n - q^* + 1$. Следовательно, $\mathcal{I}_{i^*,q^*} \in \mathcal{I}_N(\bar{x})$. Построим теперь тест $\bar{J}(\chi_{i^*,q^*})$. Поскольку при $n \rightarrow \infty$ $i^*/(n+1) \rightarrow v_0^* - \varepsilon^*$, $q^*/(n+1) \rightarrow 2\varepsilon^*$, а функция $H(v)$ строго монотонна в интервале $(v_0^* - \varepsilon^*, v_0^* + \varepsilon^*)$, то $G(v)$ будет принадлежать классу $\mathcal{G}[v_0^* - \varepsilon^*, v_0^* + \varepsilon^*]$, и в силу теоремы 2 при $m, n \rightarrow \infty$ $P(\bar{J}(\chi_{i^*,q^*})/H_1) \rightarrow 1$. Теорема доказана.

4. Практические рекомендации при построении критериев. Рассмотрим следующую модификацию проблемы проверки гипотез о равенстве гипотетических функций распределения на основании обучающих выборок, которая достаточно часто встречается в приложениях. Пусть G_1 и G_2 — две генеральные совокупности, заданные своими обучающими выборками $x_i = (x_{i1}, \dots, x_{in_i}) \in G_i$ ($i=1, 2$), а их гипотети-

ческие функции распределения $F_i(u)$ ($i = 1, 2$) считаются неизвестными. Пусть, далее, $\bar{x} = (x_1, \dots, x_n)$ — выборка, полученная путем простого случайного выбора из какой-либо одной генеральной совокупности G_i ($i=1, 2$); требуется определить номер этой генеральной совокупности G_i (т. е. установить генеральную совокупность, из которой взята выборка \bar{x}). Эту задачу можно решить с помощью классического порядкового критерия Колмогорова — Смирнова путем вычисления статистики (или метрики)

$$\rho(F^*(u), F_i^*(u)) = \sup_{u \in R^1} |F^*(u) - F_i^*(u)|, \quad (22)$$

где $F^*(u)$, $F_i^*(u)$ — эмпирические функции распределения, полученные на основании выборок \bar{x} и \bar{x}_i соответственно, и построения доверительных интервалов для этой статистики, отвечающих заданному уровню значимости. Однако эта классическая метрика, наряду со значительными достоинствами, обладает рядом недостатков, из которых укажем здесь лишь один, связанный с видом метрики (22). Легко видеть, что эта метрика является обычной чебышевской метрикой в классе ограниченных функций со счетным множеством точек разрыва. Чебышевская метрика является достаточно грубой, поскольку она не в состоянии учесть различия производных функций распределения, т. е. их плотностей вероятности. В приложениях, однако, это различие возникает довольно часто. Например, в онкоморфологии, при дифференциальной диагностике опухолей, изучается модель генеральных совокупностей G_i , когда $F_2(u) = (1 - \alpha)F_1(u) + \alpha\Phi(u)$, где $\alpha \in (0, 1)$, а $\Phi(u)$ — некоторая функция распределения, плотность вероятности которой сосредоточена на достаточно малом носителе $[\alpha - \varepsilon, \alpha + \varepsilon]$. Ясно, что с помощью метрики (22) при соответствующем выборе α и ε мы не можем заметить различия между распределениями $F_1(u)$ и $F_2(u)$; это можно делать лишь с помощью более тонких дифференциальных метрик, в которых используются плотности вероятностей $f_1(u) \equiv F_1'(u)$ и $f_2(u) \equiv F_2'(u)$. Можно показать, что введенные в этой работе статистики $\kappa_{i,q}$ и $\chi_{i,q}$ как раз и являются мерами близости между выборками \bar{x} , \bar{x}_i , которые относятся к типу более тонких, чем грубая метрика (22), дифференциальных мер близости. В связи с этим построенные выше критерии рекомендуем использовать при идентификации функций распределения в моделях смесей распределений

$$F_2(u) = (1 - \alpha)F_1(u) + \alpha\Phi(u).$$

Перейдем теперь к проблеме построения интервала $\mathcal{I}_{i,q}$, на котором основаны предложенные в этой работе критерии. Ясно, что этот интервал следует выбирать в той области (a, b) числовой прямой, где наиболее велико различие (например, в метрике C или \mathcal{L}_1) плотностей вероятности $f_1(u)$ и $f_2(u)$. Поскольку эти плотности вероятностей являются неизвестными, то их следует заменить на гистограммы $f_1^*(u)$ и $f_2^*(u)$, построенные с помощью известных методов оценки гистограмм по обучающим выборкам \bar{x}_1 , \bar{x}_2 соответственно. Определить интервал (a, b) , где наблюдается наибольшее различие $f_1^*(u)$ и $f_2^*(u)$, с помощью графиков этих гистограмм обычно не трудно; зная этот интервал (a, b) , можно найти порядковые статистики $x_1^{(i)}$ и $x_1^{(i+q)}$, построенные по выборке \bar{x}_1 , которые содержат интервал (a, b) или образуют интервал $\mathcal{I}_{i,q}$, мало отличающийся от интервала (a, b) .

1. Матвейчук С. А., Петунин Ю. И. Обобщение схемы Бернулли, возникающее в вариационной статистике. // Укр. мат. журн.— 1990.— 42, № 4.— С. 518—528.
2. В. Epstein. Tables for distribution of the number of exceedances // Ann. Math. Stat.— 1954.— 25.— P. 762—768.
3. Справочник по специальным функциям / Под ред. Абрамовица М., Стиган И.— М.: Наука, 1979.— 832 с.
4. Большой Л. Н., Смирнов Н. В. Таблицы математической статистики.— М.: Наука, 1983.— 416 с.

5. *Крамер Г.* Математические методы статистики.— М. : Мир, 1975.— 648 с.
6. *Фихтенгольц Г. М.* Курс дифференциального и интегрального исчисления : В 3-х т.— М. : Наука, 1966.— Т. 1.— 607 с.

Получено 07.08.89