

## ИССЛЕДОВАНИЕ ДОСТОВЕРНОСТИ ПЕДАГОГИЧЕСКИХ ИЗМЕРЕНИЙ С ИСПОЛЬЗОВАНИЕМ АНАЛИТИЧЕСКИХ СВОЙСТВ МОДЕЛИ G. RASCH

**Сергей Бутенков,  
Михаил Бойченко,  
Виталий Кривша**

Южный федеральный университет, Таганрог  
saab@tsure.ru

В работе вводятся методы получения оценок достоверности тестирования и шкалирования тестовых заданий, основанные на использовании аналитических свойств модели педагогических измерений по G. Rasch. В классической математической статистике для этих целей используются методы, основанные на применении функций Лапласа, не имеющих аналитического выражения и требующих применения численных методов расчёта. Использование предложенных аналитических формул вычисления основных показателей качества измерений позволяет значительно упростить расчёты, сводя их к вычислению элементарных функций. Наличие аналитических зависимостей позволяет теоретически исследовать зависимость показателей тестов от параметров тестовых заданий. На основе полученных формул даются практические рекомендации по выбору некоторых параметров тестов.

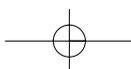
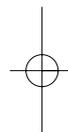

**Ключевые слова:** проектирование тестов, теория педагогических измерений, Rasch Measurement, логистические функции, доверительные границы, оценки достоверности.

### Введение

Любое измерение, особенно педагогическое, от результатов которого зависит личная судьба больших масс обучаемых как в школах, так и в других учебных заведениях, должно иметь математически обоснованные доказательства того, что используемая методика тестирования является корректной. В классической теории тестиро-

Методология

Методология



вания [1] используются методы математической статистики, основанные на теоремах *закона больших чисел*. Эти методы успешно применяются также для контроля качества массовой продукции и для аналогичных задач в других отраслях науки и техники [2].

Математической основой многих статистических методов является применение функций Лапласа [3]. Этот класс функций не имеет аналитического выражения и требует для своего вычисления специальных методов расчёта [4]. Это обстоятельство заметно усложняет вычисления, поскольку при ручных вычислениях требуются таблицы основных статистических распределений, а при использовании компьютеров требуются значительные затраты машинного времени.

Оценки достоверности получаемых при этом результатов связаны с широким использованием *нормального закона распределения*, согласно которому независимо от частных распределений случайных величин их сумма будет распределена по *нормальному закону*. Для практического применения закона больших чисел центральную роль играет интегральная функция нормального распределения

$$N(x; m; \sigma) = \frac{1}{\sigma \cdot \sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{1}{2} \left( \frac{u-m}{\sigma} \right)^2} du, \quad (1)$$

которая широко использовалась в ранних моделях педагогических измерений L.L. Thurstone, M.W. Richardson, W.A. Fergusson, D.M. Lawly, F.M. Lord и других [3]. Однако подобные модели имеют недостатки:

**1.** Функция (1) записана в виде интеграла с переменным верхним пределом и не может быть выражена через элементарные функции. Поэтому её значения приходится вычислять путем разложения в ряд или численного интегрирования [4], что значительно увеличивает объём вычислений.

**2.** Невозможны аналитические исследования формул, использующих функцию (1) и вывод на их основе простых рабочих формул, с использованием всех полезных свойств функции (1).

В процессе развития теорий педагогических измерений G. Rasch предложил *априорно модельный* подход к решению задач определения вероятности правильного ответа, который основан на использовании вместо функции (1) произвольных функций, имеющих график, сходный с графиком (1) и нормируемых с помощью искусственно вводимых параметров [5, 6]. Наиболее простым и удобным для аналитических расчётов является семейство *логистических функций* вида

$$L(x; D) = \frac{1}{1 + e^{-D \cdot x}}, \quad (2)$$

в котором параметр  $D$  играет роль *нормирующего множителя*. При правильном выборе  $D$  вместо значений функции (1) можно вычислять значения её модели (2), причём такая замена даёт среднеквадратическую погрешность вычисления не выше  $10^{-5}$ , что вполне достаточно для педагогических измерений [9].

Априорно модельный подход, предложенный G. Rasch, неоднократно доказывал свою актуальность и практическую полезность, однако не все его потенциальные возможности раскрыты и в настоящее время. Например, при оценке достоверности результатов педагогических измерений (в том числе, и по модели G. Rasch) в настоящее время используются *численные методы* математической статистики [2, 7]. Между тем, априорно-модельный подход, благодаря использованию аналитических функций типа (2), позволяет получить ряд *аналитических решений* для задач оценки достоверности результатов тестирования, приводящих к сравнительно простым и удобным для практического использования формулам.

### Задачи исследования

В работе предлагается модельный подход к получению оценок достоверности результатов педагогических измерений с помощью математической модели

(2). Для уточнения математической формулировки задачи введем формальное описание классического подхода к получению статистических оценок результатов тестирования.

Статистическим материалом для вычислений при проведении педагогических измерений является матрица исходных тестовых баллов, или тестовая матрица. Формально представим тестовую матрицу  $T$  размером  $m \times n$  в виде

$$T = \{t_{ij} \in (0,1)\} \begin{matrix} i=1,2,\dots,m; \\ j=1,2,\dots,n. \end{matrix}$$

Здесь  $m$  — число испытуемых,  $n$  — число заданий теста. Суммированием по строкам матрицы  $T$  можно найти статистику, называемую *относительной частотой правильных ответов*  $i$ -го испытуемого на  $n$  заданий теста:

$$P_n^*(A) = \frac{1}{n} \sum_{k=1}^n t_{i,k}. \quad (3)$$

Относительная частота (3) является эмпирической статистической оценкой вероятности события  $A$  ( *$i$ -й испытуемый имеет высокий уровень знаний по теме теста*),  $P(A) = \lim_{n \rightarrow \infty} P_n^*(A)$ .

Другой важной в теории педагогических измерений статистикой является сумма по столбцам тестовой матрицы  $T$ , называемая *относительной частотой правильных ответов*  $m$  испытуемых на  $j$  задание теста:

$$P_m^*(B) = \frac{1}{m} \sum_{k=1}^m t_{k,j}. \quad (4)$$

Относительная частота (4) является статистической оценкой вероятности события  $B$  ( $j$ -е задание имеет низкий уровень трудности),  $P(B) = \lim_{m \rightarrow \infty} P_m^*(B)$ .

Вычисление вероятностей этих событий  $P(A)$  и  $P(B)$  по матрице исходных тестовых результатов  $T$  является ключевым моментом, определяющим достоверность педагогического измерения [3], поскольку оценки (3) и (4) *сходятся по вероятности* (т.е. достаточно медленно) при значительном увеличении объёма выборки. Для (3) объёмом выборки является количество заданий теста, которое не может быть очень большим. Для (4) объём выборки — это количество  $m$  тестируемых по каждому заданию, которое в процессе пробного тестирования для шкалирования заданий может быть сделано весьма большим. Поскольку методики определения достоверности для (3) и (4) одинаковы, в дальнейшем будем описывать исследование только одной из них.

В инженерных приложениях для обеспечения достоверности полученных значений вероятностей по (3) и (4) используется следующий критерий [8]:

$$\begin{cases} \sqrt{n \cdot p \cdot (1-p)} \gg 1, \text{ при } p \neq 0,5; \\ n \cdot p \cdot (1-p) \gg 1, \text{ при } p = 0,5, \end{cases} \quad (5)$$

где  $n$  — объём выборки,  $p$  — оценка вероятности. Эмпирическим здесь является *отношение сравнения величин  $x \gg y$* , означающее « $x$  намного больше, чем  $y$ ». В разных источниках предлагаются разные численные оценки этого отношения для различных практических приложений методов математической статистики [2].

Задачей настоящей работы является объективизация такого отношения (с помощью возможностей модели G. Rasch) применительно к задаче оценки достоверности результатов тестирования, т.е. получение рабочих формул для вычисления необходимого значения объёма выборки в процессе проектирования тестов.

## Концептуальная основа работы

В основу метода повышения достоверности статистических оценок (3) и (4) положены идеи метода интервальных оценок случайных величин [2]. Пусть мы имеем относительную частоту правильных ответов по (3). В статистике (и в теории педагогических измерений по модели G. Rasch) предполагается, что эта оценка распределена асимптотически нормально (по закону (1)) с параметрами

$$\begin{aligned} M_{P_n^*(A)} &= p, \\ S_{P_n^*(A)} &= \sqrt{D_{P_n^*(A)}} = \sqrt{\frac{p \cdot (1-p)}{n}}, \end{aligned} \quad (6)$$

где  $p = P_n^*(A)$  согласно (3). Такие оценки в статистике называются *точечными оценками* случайной величины, однако достоверность таких оценок весьма невысока [2]. Для улучшения точечных оценок переходят к *интервальным оценкам* случайной величины, которые определяются заданным параметром *уровня достоверности оценки*  $\alpha \in (0,1)$ . Обычно в статистике выбирают стандартные значения уровня достоверности  $\alpha = 0,1; 0,05; 0,01$ . Заданное значение уровня  $\alpha$  определяет *доверительные границы*, в которых лежит значение точечной оценки.

Пусть  $(X_1, X_2, \dots, X_n)$  есть выборка из генеральной совокупности с признаком  $X$ , распределение которой зависит от параметра  $\gamma$ . Пусть  $\underline{\Gamma}(X_1, X_2, \dots, X_n)$  и  $\overline{\Gamma}(X_1, X_2, \dots, X_n)$  — такие функции выборки, что при произвольном значении параметра  $\gamma$  выполняется условие

$$P(\underline{\Gamma}(X_1, X_2, \dots, X_n) < \gamma < \overline{\Gamma}(X_1, X_2, \dots, X_n)) = 1 - \alpha \quad (7)$$

Тогда случайный интервал  $(\underline{\Gamma}, \overline{\Gamma})$  называется *доверительной оценкой параметра*  $\gamma$  с мерой достоверности  $1 - \alpha$ .

Если имеется реализация  $(x_1, x_2, \dots, x_n)$  выборки  $(X_1, X_2, \dots, X_n)$ , то реализация доверительной оценки даёт интервал  $(\underline{\gamma}, \overline{\gamma})$ , и в большом ряду выборок истинное значение  $\gamma$  лежит при-

мерно в  $(1 - \alpha) \cdot 100\%$  случаев внутри вычисленных доверительных границ. Равенство (6) можно интерпретировать так: случайный интервал  $(\underline{\Gamma}, \overline{\Gamma})$  покрывает истинный параметр с вероятностью  $1 - \alpha$ . Такая интервальная интерпретация даёт возможность делать выводы о достоверности полученных оценок случайных величин.

### Основные теоретические положения

Для получения интервальной оценки величин (3) и (4) используются свойства интегральной функции распределения случайной величины [2]. При этом, чтобы свести вычисления к типовым, значения случайной величины обычно нормируют. Так, если исходная величина  $X$  распределена по нормальному закону (1), то нормированная величина

$$Z = \frac{X - m_x}{\sigma_x} \quad (8)$$

имеет *стандартный нормальный закон* распределения с параметрами  $m=0$ ,  $\sigma=1$ , что записывается как  $Z \in N(z; 0, 1)$ .

С учётом (8) можно записать условие попадания оценки в доверительный интервал с заданным уровнем достоверности в виде

$$P(-z_\alpha < Z < z_\alpha) =$$

Фасет — это форма записи возможных параллельных вариантов задания, что является обязательным требованием при разработке теста.

$$= \frac{1}{\sqrt{2\pi}} \int_{-z_\alpha}^{z_\alpha} e^{-\frac{x^2}{2}} dx = 2\Phi_0(z_\alpha) = \quad (9)$$

$$= 1 - \alpha,$$

где  $z_\alpha$  — пороговое значение оценки, которое и определяет доверительные границы (7) для случая распределения (9). В стандартных методах статистики значения  $z_\alpha$  находятся численным решением уравнения относительно функции Лапласа  $\Phi_0(x)$  [2]:

$$2\Phi_0(z_\alpha) = 1 - \alpha. \quad (10)$$

Введем, согласно идее метода G. Rasch, модель интегральной функции распределения типа (2), и относительно неё запишем условие (10) в виде

$$\left| \frac{1}{1 + e^{-D \cdot z_\alpha}} - 0.5 \right| = \frac{1 - \alpha}{2}, \quad (11)$$

где  $D$  — нормирующий коэффициент модели,  $D \approx 1,7$  согласно [7].

В отличие от уравнения (10), из уравнения (11) можно аналитически найти пороговые значения  $z_\alpha$  как

$$z_\alpha = \pm \frac{1}{D} \ln \left( \frac{2 - \alpha}{\alpha} \right). \quad (12)$$

Теперь мы можем аналитически найти границы доверительного интервала оценки вероятности исходной случайной

$$\text{величины } x_\alpha = m_x \pm \sigma_x \cdot |z_\alpha|$$

или с учётом (6), (12)

$$p_\alpha = p \pm |z_\alpha| \cdot \sqrt{\frac{p \cdot (1 - p)}{n}}, \quad (13)$$

где значение  $p$  определяется выражением (6).

Для оценки точности полученной оценки вероятности (3) или (4) важную роль играет длина доверительного интервала  $l = \bar{p} - \underline{p}$ , которая с учётом (12) может быть найдена аналитически в виде функции основных параметров теста:

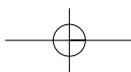
$$l(p, \alpha, n) = \frac{2}{D} \ln \left( \frac{2 - \alpha}{\alpha} \right) \cdot \sqrt{\frac{p \cdot (1 - p)}{n}}. \quad (14)$$

На основе функции (14), в силу её аналитичности, можно получить функцию, явно выражающую объём выборки  $n$ , при котором обеспечивается заданный уровень достоверности  $\alpha$  в зависимости от желаемого значения длины доверительного интервала  $l^*$  и оцениваемой вероятности  $p$ :

$$n(p, \alpha, l^*) = \left[ \frac{4 \cdot p \cdot (1 - p) \cdot \left( \ln \left( \frac{2 - \alpha}{\alpha} \right) \right)^2}{(D \cdot l^*)^2} \right], \quad (15)$$

где стандартная целочисленная функция вещественного аргумента  $[\cdot]$  означает выделение целой части аргумента.

С помощью полученных рабочих формул (11–15) можно полностью исследовать параметры проектируемого теста и выбрать те, которые обеспечивают



необходимую достоверность результатов тестирования. Примеры применения рабочих формул приведены в следующем разделе.

## Исследование полученных результатов

В предыдущих разделах работы были выполнены преобразования, основанные на замене функций, порождаемых нормальным распределением (1) на более простые модельные функции типа (2). В результате получены достаточно простые аналитические формулы для исследования достоверности как оценки вероятности правильного ответа на задания теста (3), зависящей от уровня знаний каждого тестируемого. С помощью тех же формул возможна

также и оценка вероятности правильного выполнения каждого задания (4), которая зависит от уровня трудности каждого задания [5].

Рис. 1 демонстрирует интервальную оценку вероятности с помощью аналитических выражений (2) и (13).

Кривая 1 соответствует точному значению вероятности  $p$  правильного ответа  $i$ -го испытуемого на  $n=20$  заданий теста на уровне достоверности  $\alpha=0,1$ . Кривая 2 соответствует верхней границе  $\bar{p}$  доверительного интервала, а кривая 3 — нижней границе  $\underline{p}$  доверительного интервала для того же теста. Рисунок подтверждает, что с изменением значения вероятности  $p$  изменяется и доверительный интервал  $(\underline{p}, \bar{p})$  для этого значения согласно (13).

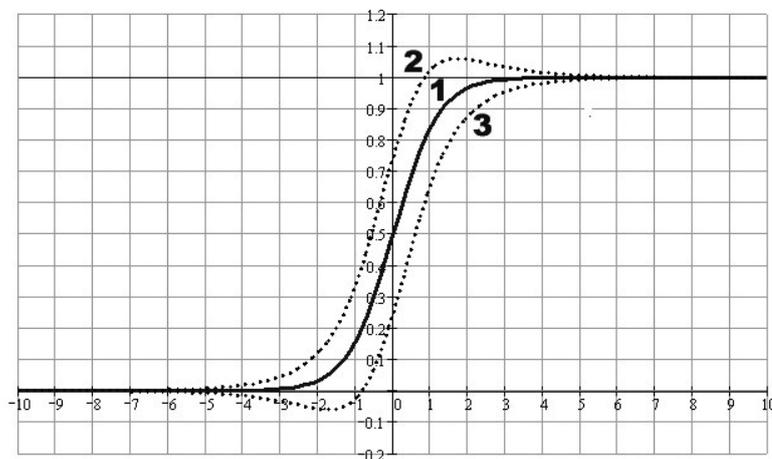
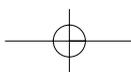


Рис. 1. Кривые точной интегральной функции распределения вероятности  $p$  и её верхнего и нижнего значений, получаемых при обработке результатов тестирования



Аналитическое исследование полученной в работе функции (14) на максимум по переменной  $p$  показывает, что, к сожалению, наибольшая длина доверительного интервала  $(\underline{p}, \bar{p})$  и, соответственно, наименьшая точность вычисления вероятности имеет место как раз в точке наибольшей разрешающей способности теста при  $x = 0$ ,  $p(x) = 0,5$ .

Аналитическое исследование функции (14) показывает также, что влияние уровня достоверности на длину доверительного интервала значительно меньше, чем влияние других параметров, поскольку  $\alpha$  входит в (14) под знаком логарифма. Поэтому в дальнейшем рассмотрим влияние на точность оценок вероятностей объёма выборки.

Рис. 2 изображает зависимость максимального значения длины доверительного интервала  $(\underline{p}, \bar{p})$  по формуле (14) от объёма  $n$  выборки для (3) или (4) при одинаковом уровне достоверности  $\alpha = 0,1$ .

Кривая 1 — тест из 12 заданий, 2 — из 25 заданий, 3 — из 50 заданий, 4 — из 100 заданий. Очевидно, что даже при числе заданий теста  $n = 100$  не достигается приемлемое значение длины доверительного интервала  $l = (\underline{p}, \bar{p})$ , например,  $l = 0,1$  (десятипроцентная точность).

Рис. 3 демонстрирует аналитическую зависимость длины доверительного интервала  $(\underline{p}, \bar{p})$  от объёма выборки  $n$  (количество заданий теста при оценке знаний и количества тестируемых, ответивших на данное задание). Здесь также

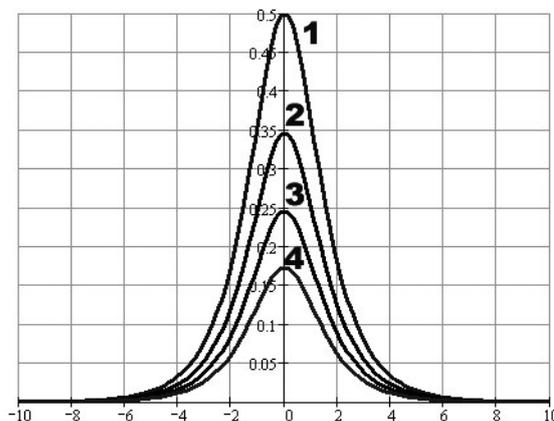


Рис. 2. Зависимость длины доверительного интервала  $(\underline{p}, \bar{p})$  для вероятности  $p=0,5$  от значения для различного числа заданий теста

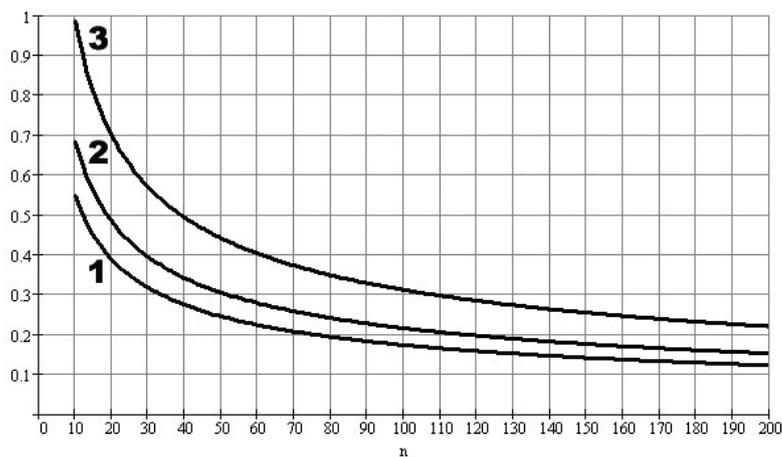


Рис. 3. Зависимость максимальной длины доверительного интервала  $(\underline{p}, \bar{p})$  по вероятности от доверительного уровня и числа заданий теста

выбрано значение  $p = 0,5$  для получения верхней оценки точности.

Кривая 1 соответствует значению доверительного уровня  $\alpha = 0,1$ , 2 — уровню  $\alpha = 0,05$ , 3 — уровню  $\alpha = 0,01$ . Очевидно, что в случае, когда  $n$  — число заданий, достижение высокой точности вычисления вероятности правильного ответа по (3) невозможно при разумном числе заданий ( $n < 100$ ), в том числе и при большом значении доверительного уровня  $\alpha = 0,1$ . Зато для оценки уровня трудности задания по (4) малая длина интервала  $(\underline{p}, \bar{p})$  может быть достигнута при  $n > 2000$ , в том числе и при достаточно малом доверительном уровне  $\alpha = 0,01$ .

Рассмотрим теперь решение обратной задачи с помощью рабочей формулы (15). Задавшись желаемыми значениями основных параметров теста, можно оценить необходимые объёмы выборок как для вероятности правильного ответа (3), так и для вероятности правильного выполнения задания (4).

Следующий рисунок демонстрирует зависимости, показывающие, при каких объёмах выборки достигается желаемая длина доверительного интервала  $(\underline{p}, \bar{p})$ .

Точки 1 соответствуют доверительному уровню  $\alpha = 0,1$ , 2 — уровню  $\alpha = 0,05$ , 3 — уровню  $\alpha = 0,01$ . Очевидно, что в силу свойств выведённой в работе аналитической зависимости

ПЕД  
измерения

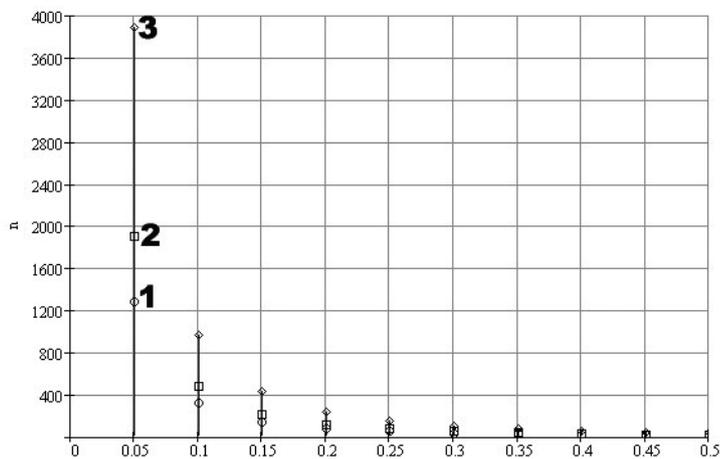


Рис. 4. Зависимость необходимого объема выборки  $n$  от доверительного уровня и желаемой длины доверительного интервала  $l = (\underline{p}, \bar{p})$

(15) требуемые объемы выборок значительно возрастают при уменьшении желаемой длины доверительного интервала  $l = (\underline{p}, \bar{p})$  для вероятности. Тем не менее, при использовании контингента около 4000 человек для шкалирования тестовых заданий, полученные оценки вероятности правильного

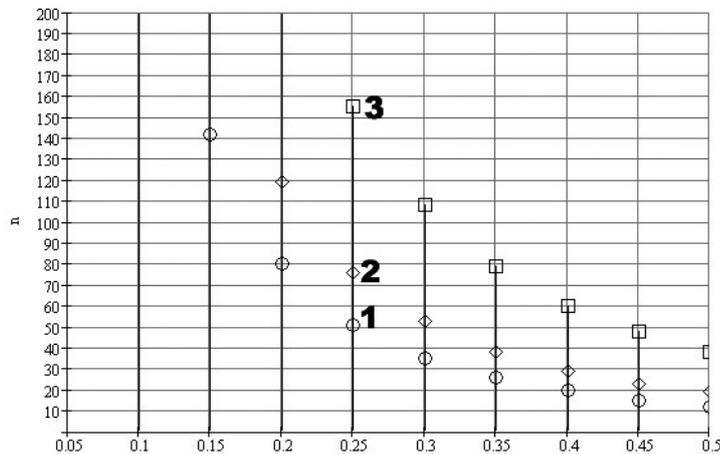


Рис. 5. Зависимость необходимого количества заданий теста  $n$  от доверительного уровня и желаемой длины доверительного интервала  $l = (\underline{p}, \bar{p})$



выполнения задания (4) могут быть вполне точными.

Следующий рисунок изображает эту же зависимость в области малых объёмов выборок заданий, что имеет место при вычислении вероятности правильного ответа (3).

Точки 1 соответствуют значению  $\alpha = 0,1$ , 2 — значению  $\alpha = 0,05$ , 3 — значению  $\alpha = 0,01$ . Перспективы получения точного значения вероятности (3) по тестам с числом заданий до  $n = 40$  представляются печальными, так как длину доверительного интервала не удаётся сделать меньше, чем 0,25 даже при низком доверительном уровне  $\alpha = 0,1$ .

## Выводы

Полученные результаты позволяют аналитически исследовать точность получаемых при тестировании вероятностей (3) и (4) и проектировать тесты с учётом требуемой достоверности, задаваемой уровнем  $\alpha$ .

При выборе числа заданий теста можно использовать

оценку (3) а при шкалировании трудности заданий теста — оценку (4).

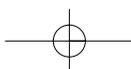
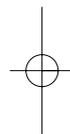
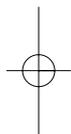
Полученные в работе аналитические зависимости можно использовать для выбора основных параметров теста по заданным значениям уровня достоверности и длины доверительного интервала, которые являются объективными оценками точности педагогических измерений и позволяют определять величину  $n$  в (5).

Ещё более полезными будут полученные формулы при использовании в автоматических системах тестирования [9], позволяющих оперативно менять показатели тестов в процессе работы с тестируемым.

На основании полученных в работе результатов возможно дальнейшее развитие методов построения статистик, используемых в модели G. Rasch, которые основаны на функциях, обратных к модельным функциям (2). Это приведёт к уточнению и улучшению оценок не только в начальной форме (вероятностей) но и в логитах.

## Литература

1. Аванесов В.С. Определение исходных понятий теории педагогических измерений. «Педагогические измерения» № 3, 2005.
2. Смирнов Н.В., Дунин-Барковский И.В. Краткий курс математической статистики для технических приложений. М.: Физматгиз, 1959.



ПЕД
измерения

3. *Аванесов В.С.* Методологические и теоретические основы тестового педагогического контроля. Дис. ... д-ра пед. наук. Санкт-Петербургский гос. университет, 1994. 339 с.
4. *Фихтенгольц Г.М.* Курс дифференциального и интегрального исчисления. М.: Физматлит, 1969.
5. *Rasch G.* Probabilistic Models for Some Intelligence and Attainment Tests. With a Foreword and Afterword by B.D. Wright. The Univ. of Chicago Press. Chicago & London, 1980.
6. *Karabatsos G.* Axiomatic measurement theory as a basis for model selection in item response theory. Paper presented at 32<sup>nd</sup> annual conference of the Society for Mathematical Psychology, Santa Cruz, CA. July, 1999.
7. *Булыгин В.Г.* Основы автоматизации процесса обучения. - Йошкар-Ола, 2003.
8. *Бендат Дж., Пирсол А.* Измерение и анализ случайных процессов. М.: Мир, 1974.
9. *Бойченко М.М.* Современная система контроля знаний обучаемых. – В кн.: Материалы международной конференции «Динамика процессов в природе, обществе и технике: информационные аспекты», часть I, Таганрог: ТРТУ, 2003, с. 12–13.