

УДК 159.9.01

DOI: DOI: 10.26140/anip-2020-0904-0095

В ЧЕМ ОШИБОЧНОСТЬ ПРИМЕНЕНИЯ ФАКТОРНОГО АНАЛИЗА ТЕСТОВ, СООТВЕТСТВУЮЩИХ ТЕОРИИ ОТВЕТОВ НА ТЕСТОВЫЕ ЗАДАНИЯ (IRT)?

© 2020

SPIN-код: 6174-3930

AuthorID: 947445

Равен Джон, почетный профессор университета Эдинбурга, Печского университета (Венгрия), Католического Люблинского университета (Польша)*Эдинбургский университет**(Шотландия, Эдинбург, EH3 6QH, Грейт Кинг-стрит, 30, e-mail: jraven@ravenfamily.co.uk)***Фугард Энди**, Ph.D в области психологии, старший преподаватель кафедры

Исследовательских методов социальных наук

*Лондонский университет**(Великобритания, Лондон, Тауэр-Хамлетс, кафедра психологии, e-mail: a.fugard@bbk.ac.uk)*

© 2020 Перевод на русский язык – О.Н. Ярыгин

Аннотация. Многие исследователи, которые знакомы с теорией ответов на тестовые задания (TOTЗ, Item Response Theory - IRT), (или со шкалами Раша и Гутмана), знают, что применение факторного анализа в попытке оценить внутреннюю согласованность или одномерность, таких тестов, имеют тенденцию давать недостоверные результаты. К сожалению, это известно немногим из тех, кто работал только с тестами, разработанными с использованием классической теории тестирования (КТТ). Такое положение дел привело к тому, что многие исследователи пришли к серьезным ошибочным выводам, применив факторный анализ к матрицам корреляций между заданиями, составляющими тесты, построенные на основе TOTЗ (IRT). Данная статья иллюстрирует проблему, на примере факторного анализа данных, генерируемых компьютером и имитирующих то, что было бы получено при использовании этой архетипической формы TOTЗ-теста как портновский метр или метровая линейка для измерения роста или способности прыгнуть в высоту.

Ключевые слова: теорией ответов на тестовые задания (TOTЗ, Item Response Theory - IRT), задания тестов, корреляция трудности заданий, одномерность и многомерность теста, измерительная рулетка, однофакторный и многофакторный анализ, ошибочные результаты факторного анализа

WHAT'S WRONG WITH FACTOR-ANALYSING TESTS CONFORMING TO THE REQUIREMENTS OF ITEM RESPONSE THEORY?

© 2020

Raven John, Honorary Professor University of Edinburgh, University of Pecs (Hungary), Catholic University of Lublin (Poland)*University of Edinburgh**(Scotland, Edinburgh EH3 6QH, 30 Great King Street, e-mail: jraven@ravenfamily.co.uk)***Fugard Andy**, Senior Lecturer in Social Science Research Methods BEng, MSc PhD*University of London**(Great Britain, Birkbeck College, Department of Psychology, e-mail: a.fugard@bbk.ac.uk)*

© 2020 Translation into Russian - O.N. Yarygin

Abstract. Many researchers who are familiar with Item Response Theory (IRT) (or variants such as Rasch or Guttman scales) know that applying factor analysis in an attempt to assess the internal consistency, or unidimensionality, of such tests tends to yield misleading results. Unfortunately, few of those who have worked only with tests developed using Classical Test Theory are aware of this. This has resulted in many researchers coming to seriously misleading conclusions when they have applied factor analysis to the matrices of correlations between the items constituting IRT-based tests. The current paper illustrates the problem by factor-analysing computer-generated data simulating that which would be obtained from using that archetypical form of an IRT test – a tape measure or meter stick – to measure height or the ability to make high jumps.

Keywords: Item Response Theory, test items, correlation of difficulty of items, unidimensionality and multidimensionality of the test, measuring tape, one-factor and multifactor analysis, inadequate results of factor analysis

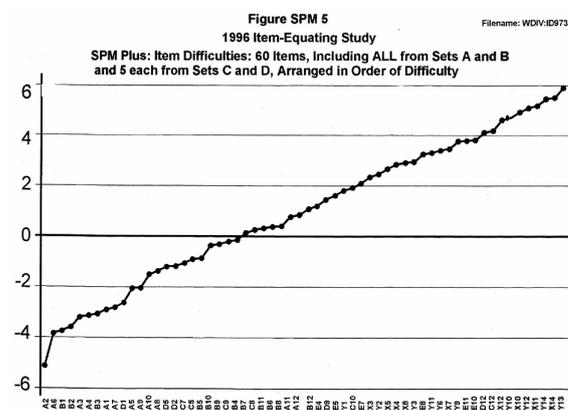
Цель этой статьи - проиллюстрировать как можно более наглядно то, что относительно хорошо известно исследователям, знакомым с прикладной теорией ответов на тестовые задания, но неизвестно большинству других. Речь идет о том, что приложение процедур факторного анализа, которые рутинно используются для установления «одномерности» (или наоборот неоднородности) тестов, сконструированных согласно классической теории тестирования (КТТ), приводят к «бессмыслице», в случае применения для проверки тестов, построенных в соответствии с TOTЗ (IRT) (или с шкалами Раша и Гутмана).

Процедуры IRT нацелены на создание теста, состоящего из набора заданий, будь то задания «проверки способностей» или задания на «лайкертовы отношения» или «личностных» заданий, так что респонденты пройдут или одобряют все задания (пункты) вплоть до такого, которое указывает максимум их способности (или максимальную силу их эмоций), и не пройдут все последующие задания (пункты) данного теста.

Данные на рисунке ниже, относящиеся к тесту «Стандартные прогрессивные матрицы Равена Плюс», могут служить примером теста, который почти соответствует этому критерию.

По сути, респонденты дают правильные ответы на все вопросы (задания), вплоть до самых сложных, которые они

могут решить, и не отвечают на остальные, хотя для полной демонстрации этого утверждения требуются дополнительные данные [1].



Исследование равномерного нарастания трудности заданий, 1996 г.
«Стандартные прогрессивные матрицы Равена Плюс».

Трудности заданий: 60 заданий, включающие все из блоков А и В, и по 5 из блоков С и D, расположенных в порядке возрастания трудности.

Такой тест будет похож на линейку для размера ноги или портновский метр.

В идеале, «итоговым баллом» будет уровень или сложность последнего пройденного или подтвержденного задания. Аналогом может служить наибольшая высота планки, которую смог преодолеть прыгун в высоту.

Такие итоговые баллы заметно отличаются от баллов, полученных с помощью сомнительной процедуры подсчета количества пройденных респондентом заданий среди тех, которые составляют один «фактор» или «размерность» «личностного» теста. Сомнительны и заключения о том, что тот, кто пройдет больше пунктов, имеет более высокую уровень рассматриваемого признака. Классическая теория тестирования рекомендует эту процедуру, призывая исследователя установить, что все задания, входящие в то, что представлено как конкретная область «способностей» или «черт» личности, умеренно коррелируют друг с другом, но мало коррелируют, если вообще коррелируют, с теми, которые, как говорят, отражают другое измерение или область.

К сожалению, идеал единственной надежной цифры как показателя результата теста IRT обычно не может быть достигнут. Это привело к созданию баллов, основанных на подсчете количества правильно решенных или пройденных заданий. Эти оценки внешне аналогичны оценкам, полученным в тестах, разработанных в соответствии с классической теорией тестирования, но их теоретическая основа сильно отличается.

Все это послужило источником бесконечной путаницы.

В этой статье мы показываем, что, когда процедуры, обычно применяемые для оценки внутренней согласованности тестов, разработанных в соответствии с классической теорией тестирования, применяются к матрицам корреляций между заданиями тестов, соответствующими требованиям ТОТЗ, они *всегда* и обязательно декларируют, что эти тесты многомерны.

Подчеркнем это еще раз:

- применение процедур, рекомендуемых классической теорией тестирования, к тестам на основе ТОТЗ (IRT) *всегда* приводит к выводу о том, что для учета наблюдаемой картины корреляций между заданиями теста необходимы три или более факторов. А из этого делается заключение, что исследуемый тест является многомерным.

Первая часть этого наблюдения верна. Но это никоим образом не подтверждает вывод о многомерности теста. «Факторы», которые процедура правильно указывает как необходимые для вычисления максимума объяснимой дисперсии в корреляционной матрице, на самом деле являются «силовыми» факторами, каждый из которых характеризуется заданиями аналогичной трудности и отличается от тех факторов, которые характеризуются группами более простых или более трудных по этому единственному фактору заданий.

Наша демонстрация производит то, что, как подчеркнул Целевая группа АПА (Американская психологическая ассоциация) по Статистическому выводу, *делается слишком редко*. Она основана на возвращении к матрице корреляций между заданиями (пунктами), составляющими любой тест [Отчет АПА не публиковался, но о нем можно прочесть в работе: L. Wilkinson and Task Force on Statistical Inference. (1999). *Statistical methods in psychology journals: Guidelines and explanations. American Psychologist, 54*, 594-604].

Мы ожидаем, что многим исследователям будет трудно полностью оценить актуальность того, что мы делаем.

Многие, если не большинство, исследователи довольствуются тем, что применяют *готовые компьютерные пакеты факторного анализа* к своим наборам

данных и считают такие показатели, как количество и характер факторов, полученных в различных условиях, долом дисперсии, приходящуюся на каждый фактор, нагрузки по каждому фактору, набор факторных оценок и т.д.

Несмотря на рекомендации Целевой группы АПА по статистическому выводу, эти исследователи редко изучают корреляционные матрицы вида задание-задание или задание-тест, которые лежат в основе результатов, выдаваемых применяемыми статистическими пакетами.

В этом и состоит проблема. Как говорится, дьявол кроется в деталях.

Итак, в этой статье мы сосредоточимся именно на этих скрытых матрицах корреляций (фактически ковариаций) между заданиями и их решениями.

Мы хотим проиллюстрировать, насколько неуместно стремиться к демонстрации «одномерности» (или наоборот многомерности) тестов, которые действительно удовлетворяют требованиям ТОТЗ (или шкалам Раша или Гутмана), с помощью применения критериев классической теории тестирования матрицам корреляции между заданиями, составляющими тест.

Рекомендации Целевой группы АПА по Статистическому выводу, требуют от исследователей внимательно изучить *корреляционную матрицу*, лежащую в основе их факторного анализа, и задаться вопросом, на основании какой модели эта матрица составлена, прежде чем приступить к факторному анализу. Нарушая эти требования, такие исследователи обычно затем выделяют явное содержание заданий с высокими «нагрузками» на каждый фактор и маркируют факторы на этом основании ... хотя на самом деле группы заданий состоят в основном из заданий одинаковой трудности, различаемых всего лишь как «менее трудные» или «более трудные» задания.

Повторим: мы начинаем с рассмотрения матриц корреляций, а не результатов, выдаваемых статистическими компьютерными программами.

Более конкретно, мы проиллюстрируем неуместность попытки использовать факторный анализ для установления одномерности шкал IRT в целом, используя со ссылкой на общедоступную измерительную рулетку или метр, используемые для измерения роста или способности совершать прыжки в высоту.

Обычная измерительная рулетка представляет собой идеальную шкалу IRT. «Люди» «проходят» (правильно решают задание) все сантиметровые отметки («задания») до той, которая регистрирует их рост (или высоту самой высокой планки, которую они могут перепрыгнуть) и «терпят неудачу» (не могут достигнуть) до всех сантиметровых отметок («заданий») выше этой отметки.

Мы представим две иллюстрации того, что происходит, когда кто-то пытается проанализировать матрицы корреляций между заданиями теста, которые возникают в результате взаимной корреляции этих «заданий» (сантиметровые отметки).

Одна основана на сгенерированных компьютером данных, приближенных к тем, которые были бы получены, если бы 36-сантиметровая рулетка использовалась для измерения высоты случайной выборки из тысячи особей одного вида или линии животных, имеющих средний рост 18 см. То есть компьютер был запрограммирован на создание набора данных, в котором среднее значение будет 18, а «баллы» распределены по всей шкале из 36 пунктов в соответствии с «гауссовым» распределением (авторы используют дискретное распределение, поэтому называют его «гауссовым» условно, т. е. нормальное распределение является непрерывным). В данном случае, видимо, используется биномиальное распределение. – прим. перев.). Естественно, каждая «оценка» (то есть «рост») предполагала, что конкретное животное «прошло» каждую сантиметровую отметку (задание) до этой точки и не смогло достичь каждой сантиметровой отметки над ней.

или «кластеры»).

Таблица 3. 3-факторное решение на основе корреляционной матрицы из таблицы 1. (Cumulative Var – накопленная объясненная дисперсия)

Table 3
3-factor solution from factor analysing the correlation matrix in Table 1.

Final Score/ cm mark	Loadings on:		
	Factor 1	Factor 2	Factor 3
1		0.30	
2		0.37	
3		0.51	
4		0.64	0.12
5	0.10	0.69	
6	0.14	0.71	
7	0.20	0.79	0.10
8	0.25	0.78	
9	0.35	0.72	
10	0.39	0.72	
11	0.45	0.65	
12	0.56	0.58	
13	0.63	0.57	
14	0.68	0.46	
15	0.74	0.40	0.15
16	0.75	0.33	0.18
17	0.77	0.28	0.21
18	0.76	0.21	0.23
19	0.77	0.17	0.31
20	0.76	0.14	0.37
21	0.69	0.15	0.41
22	0.66		0.48
23	0.61	0.12	0.53
24	0.54	0.10	0.62
25	0.48	0.10	0.68
26	0.41		0.72
27	0.33	0.12	0.72
28	0.28		0.75
29	0.19	0.10	0.76
30	0.12		0.66
31	0.14	0.12	0.64
32		0.13	0.61
33			0.51
34			0.39
35			0.21
36			
SS Loadings	7.47	6.01	5.85
Proportion Var	0.21	0.17	0.16
Cumulative Var	0.21	0.37	0.54

Для полноты и контраста, вот корреляционная матрица, полученная в результате изучения ответов 4000 подростков на анкету о стремлении к карьере после того, как она была перестроена в соответствии с результатами многофакторного факторного анализа [3].

TABLE 4: THE CORRELATION MATRIX ARRANGED ACCORDING TO THE RESULTS OF THE VARIAN ANALYSIS.

Ясно, что элементы делятся на несколько групп или кластеров, которые, как правило, мало пересекаются (хотя фактор 4 явно может быть объединен с фактором 3).

Таким образом, программа фактически сказала: «Смотрите. Здесь, в середине, находится группа элементов, которые сильно коррелируют друг с другом и относительно меньше с элементами в двух других группах элементов на нижнем и верхнем концах шкалы. Итак, ребята, вам нужно как минимум 3 фактора, чтобы учесть эти данные».

Способ, которым программа «сгруппировала» элементы, показан в Таблице 4.

Конечно, мы могли бы продолжать и действительно продолжили, то есть извлекли 5 факторов. (Заметим, что, если бы мы извлекли 36 факторов, мы фактически смогли бы использовать факторные нагрузки для точного воспроизведения исходной матрицы корреляций.)

Но мы сделали уже достаточно, чтобы доказать выдвинутое положение: мы же знаем, что рулетка одномерная.

Применение процедур, основанных на классической теории тестирования, к данным, полученным с ее же

помощью, чтобы установить, являются ли эти данные одномерными, ошибочно. Коротко, факторный анализ группирует вместе предметы аналогичной трудности и заявляет, что они представляют собой основные факторы или «размерности» в пределах тест. Со времен Гуттмана (наиболее известного своей работой по анализу «Шкалограмм», которые, по сути, является вариантом IRT) и позже эти факторы были известны как факторы «мощности».

Таблица 4. Корреляции в таблице 1 сгруппированные в кластеры процедурой 3-факторного анализа. (Десятичная точка опущена.)

Но, не заметив этого, тысячи исследователей, не знакомых с целями и моделью измерения, лежащими в основе IRT-тестов, и не выполнявших рекомендации рабочей группы АРА по статистическим выводам (которые могли быть еще не опубликованы, на момент проведения исследований), требующей «сначала взглянуть на исходные данные», из-за этого совершили ужасное преступление, которое повлияло на мышление целых поколений исследователей.

Как указывалось ранее, они исследовали явное содержание заданий с высокими нагрузками на эти 3 или 5 факторов и, исходя из этого, делали вывод, что в тесте было 3 или 5 (или более) «типов» заданий ... другими словами, тест был беспорядочным и объединял 3, 5 или более «независимых» размерностей 1, 2, 3.

На самом деле, использование слова «независимый» само по себе свидетельствует о более чем небольшом незнании того, как работает факторный анализ, потому что последовательные факторы в действительности не являются независимыми от тех, что были ранее, но фактически представляют собой следующую лучшую попытку исправить с помощью еще одного единственного фактора, ошибки, которые были сделаны при предположении, что матрица корреляции [фактически ковариационная] может быть «объяснена» в терминах ранее извлеченных факторов.

Термин «одномерный» на самом деле крайне неоднозначен. Подробное обсуждение термина см. в [4].

Эта ошибка привела многих исследователей к выводу, что Прогрессивные матрицы Равена измеряют несколько разных характеристик.

Хотя в каком-то смысле это может быть правдой, суть в том, что это не демонстрируется путем факторизации элементов. Здесь не место для подробного обсуждения этих вопросов, но, поскольку интересом к ним привел авторов к подготовке этой статьи, то стоит отметить, что обзор многочисленных демонстраций на основе TOT3 (IRT), которые различают качественно разные типы заданий, составляющих Прогрессивные матрицы Равена, измеряют один и тот же базовый континуум способности (по аналогии с тем, что качественно разные типы заданий, составляющих геологическую шкалу, используемую для измерения «твердости», все измеряют одну и ту же основную переменную «твердость»), можно найти в главе 1 книги Raven J. & Raven, C.J. (2008) Uses and Abuses of Intelligence.(Opus Cit.) [5] (<http://eyeonsociety.co.uk/resources/UAIChapter1.pdf>), а примером исследова-

