

从写作测验信度研究看开 测

冯瑞龙

(, 519085; , 361102)

摘要:

关键词: ; ; ;
中图分类号:G449 文献标志码:A 文章编号:2221-9056(2014)02-0160-08

过 帮助 帮助 步 。 点还 它 多
武 。 ， 又 劣势，除 分/级 准
难 厘 、过程费 耗 严 恐怕就 难 想 水平 。
不仅 衡 质 ， — 。
程 人 ， 不 严 、 ， 不 步， 。
手 。

收稿日期:2014-02-17

作者简介:冯瑞龙,男,澳大利亚格里菲斯大学文学博士,北京师范大学香港浸会大学联合国际学院副教授、博士生导师,研究方向文学。

，男，大学教 学博士，大学 教 学学院副教授、 学 博士生导师,研究方向
国际教 国 。Email:zhuyu@xmu.edu.cn

基金项目:UIC Research Grant (2012 - 13) R201307 教 国 研 。

二、信度理论流派的简介与比较

(CTT) (Inter-rater Reliability Intraclass Correlation Coefficient, ICC) 大 ICC (Wikipedia, 2010) 。 ICC

总 (Yij = $\mu + \alpha_i + \epsilon_{ij}$) 第 i , Yij 第 i , ϵ_{ij} 第 j , 第 j , μ

ICC (Julius Sim & Chris Wright, 2000; 335)。

() (IRT) Linacre (1989) (George Rasch, 1980)
外, 外, 外, 1。 : 161 :

外合 0.5 1 之 时, 测评是富 的。当 大 1.5 2 时, 测评
 , 但 。大 2 时, 测评 是 信的。
 型 用 性 能。这 性 能, 能 当
 题 式 能 当 其 ; 性 能, 能 当
 的 提 , 一 的 同 其 的 评 (George
 Engelhard, 2008); 性 能, 题 度 同 的 提 , 题
 的 其 外 题 的 (George Johanson & Abdalla Alsmadi,
 1998)。是 存 性 能是 过 之 的 用的 的。一
 用 的 性 能 予一 偏 , 当 Z 的 绝 大 2 时,
 一般认 的 性 能 。 存 性 能则暗 的 测 题 能
 待 ; 性 能 则 提 能 了 较大 偏 ; 的 性
 能则能 映 测的 , 能 掌 的 。
 信度也是 型涉猎的范畴之一。用 型的 据 能提供 信度统 量,
 一 是 范围 0 1 之 的 割 信度, 一 是 范围 1 穷之 的 割比。
 尽管 型 一 的 能 这种 , 但 的 这 大 ,
 其 的 这 则 。 其 各 中各要素带 的 性 能 。倘若
 这 各要素 的 性较 则能 映测量 较高的一 性。但 各要素(一
)之 性较 , 映的 是 评 , 属 一种 理 的 情况。

() 理论(GT)的信度评

理论认 测 的 方 是 方 量的。这其中既 希望
 过 测 的 的 造 的 方 量(称 测量 方), 也
 扰 素造 的 方 量。采用 理论的 G 据 能 这 方 量
 测量 方 量 方 中 的 比重 大, 靠。了 提高
 的 推 性 靠性, 要 过 控制降低 比重大的 扰性方 量, D
 则能让 G 的 了 变 扰变量的 量, 变 评 、 题的 量
 方 会造 测 信度的 何种 变 , 帮 助 能保证理 信度的最佳 测 评 措 。
 理论 信度时, 了 照 照 测 的 信度 。 g ,
 Phi 。这 种 时 测 象 的 方 子, 方 也 是 母的
 之一。一 g 是 方 , 测 象 G 的 各
 的 用 造 的 方 量之 。 Phi , 是 绝 方 , 是 了 测 象
 方 量 外的 各 方 之 。

() 信度 的 评

经典测量理论 的 信度 最大的 用经典测量理论 型的 提 较低, 实
 测 据 。 一 是 能 方 之外的 一 方 量, 也
 认 控制的 一 方 素, 何 测量的 信度 提 测 方 的 。
 外, 其 用的 本 大, 是 能 本的 。
 理论的 型 经典测 理论的 信度 理论 信度 理 最大的 同 的
 是 本的。 其着 。 信度的 是 测 的
 信度, 是给 一 的 一 要素的 测量 信度 (割 信度 割比)。若要 信
 度, 信 度 理 的 。 比 , 评 信度 较低,
 性 评 能 , 何合理 评 、 评 控 评 过

。然

q 不

分 素

如

5 ② f 1 8 分析 1 虽然不 1 3 样 9 立, 9 2 9 8 取 ② D 3 8 8

。

素 8 5 2

, 够 认 分 , 够 过全

b10.2 1.3 881 Tf 0 TR10623 63.89646 TD (cX)Tj 41.77359 -1.82285 76 TD é G



属统

属统属割素属素

属统属 素

更有于提 写作成绩的可 性和概化 。

有研究 同时使用了概化理论以外的 具。 :Sudweeks (2004) 的 研究使 用概化理论和 型同时估算了写作评 在的误差源和写作成绩的信度,并据此提出了 改善评 的 。结果 写作题目以及被试与题目的 作用比较 ,而评卷 和考试 成的方差较低。这也 加写作题目是改善此项写作测试成绩可 性的有 。

Schoonen (2005) 以 G 研究估算了被试写作 、作文题目、评 的项目(内 或 用) 以及评 方式(体性评 或 性评)的 应,并通 结 方 型估算了写作 的方差 成 。 研究的被试是 89 6 年 学 , 被要求写 作文, 作文的内 及 用 个方 被 5 评卷 以 体和 种方式评 。 结果 写作成绩的可 性以及评 卷 和写作题目的 应在 大 度上 于评 方式与评 项目。 体而 ,写作题 的方差 要 于评卷 的方差。

在国内, 和 (1998) 的研究 发现写作题目对测试成绩可 性的 应,但 发现了 同文体对评 误差有重要 , 论文的评 误差最大。 、 (2008) 用 概化理论对出国 学 测试的 30 试的写作 进 ,测试有 个写作 , 1 要求 试发 力, 据提供的 自 写 ; 2 是 试较 的 题作文, 述自 的学 与 经历、 好 。评 用 Jacobs 1981 年设计的 作文评 量 “ESL Composition Profile”。研究结果 个写作 的合成总 的评 信度较 。

可 ,写作题型和题量 是 写作成绩可 性的要 。 题型而 , 些新题型 写写 作或 写写作成绩的可 性并 低于 的 写作,考 到这些题型更 合真实测评的 , 写作 测试也可以 用此 题型为 题写作的 。而 所测的 体来 ,对 论文的 评 可能相对更主 一些,其成绩的可 性会相对 差。 合考 被试的 ,或 在 、 中 写作 考试时,应 强 考 写 论文体的作文。至于题量方 ,所参考的文 一 相关测评应有 或 以上的写作试题,以 被试写作成绩的可 性。

() 关于评卷

上述研究 或 或 地 加评卷 是提 写作成绩概化 的有 , 之,评卷 一 是写作成绩方差的主要来源,但写作评 中, 同评卷 对同一 作文评 的差 是 了 内一些学 的 。例 :Johnson 及其同 (2005) 以概化理论研究了 评卷 评 出现差 应 理的问题, 理 问题的 同方法会对 作性评 的信 度 同 。具体而 ,Johnson 及其同 比较了以评卷 的 为被试最终 和通 论 一 性评 种 同方法所 被试写作成绩的 确度,并考 了 论 中是 会出现个 评卷 于 性地 的 。研究结果 ,以计算 或 论解 评 差 的 果并 有 差 , 对于提 评 确性 无 大 。在进 体性评 时, 以 论方式解 评 差 ,相对更 出现个 评卷 于 性地 的 。

相较 方的研究,国内的相关研究更 地发现了评卷 对于作文成绩可 性的 应。 例 , 和 (1998) 使用概化理论 了 6 评卷 对 20 学 三种文体的作文 进 性评 的 据。结果 在作文评 中,评卷 应最大,题目 应 。

此外,国内的一些相关研究 评卷 的评卷经验和 学 也考 在评卷 应当中。

(2010) 以个案 的方法对新 评卷 在 HSK 写作测试的评卷 信度进 考 ,研究从 2009 年 4 的 HSK() 写作测试评 的 48 评卷 中 了 (中一 新 评卷), 用概化理论对 的评 信度进 了 验,结果 的测验信度较 ,同时了解到新 评卷 在对评 标 的 中存在的差 。 (2005) 用概化理论对有、无 学

的评卷 给 20 试 试(HSK) 测 的概化 进 行了比较。研究发现 评卷 评 的 误差 于 的。实 中, 种的 测 的评卷 一 经 比较 的 , 式阅卷 会进 比较 的评卷 , 而 研究发现的评卷 评 经 、 学 的差 可能 实际的大 度, 测文阅卷 会 试文 的可 性。的是 Johnson 及其同 对 发 评卷 评 差 时 同理方 的 果的研究。据 的发现, 以 论一 的最 评 和通 计算 测 为最 评 对 测文 的可 性 的 较大差 。 的研究可 方向 开, 发现与 一 , 大可 用计算 的 评 方。

(三) 于评

评 是 性评 同 也会 测 信度。(2006)的 学 论文 了 40 试 HSK 的 测及评 据, 对 同的 测 (文 论文)、评 方 (评 性评)、评 项目(章结 用) 测文 各 的 应及 之 的 进 了实 研究。研究发现 测 和评卷 应 大 度 评 方 和评 项目 。 (2008)对 36 大学 测文 评 结果的 量 进 了 , 实 项 项评 结果的可 性 于 评 结果, 项 合 的可 性 于 项 项 的可 性, 同 了 的信度 对于评 评 结果的总 量是一 恰当的 。 的, 李智(2009)也从 同 测 和评 式 发, 用概化理论 了 4 评卷 评 的 30 大学 测试的 测文(一 测文、一 题 测文)的 项 , 为 而 , 性评 的 测 有较 的信度。

、 (2008)的研究 进一 比较了 测 性评 量 五 评 的评 信 度, 结果 : 测 、 章结 、词汇 用这三 的评 较为一 , 对而 , 对 的评 信度最 , 而对书 规范的评阅有 提 。 的研究 向 了 与 评 卷 对 性评 的理 与 用 的 同: 评 的理 与 用方 , 评 卷 重 测文 、词汇 方 , 而 评卷 重 测文 和连贯性 。 合这 研究发现, 结合当 的 测评实 , 有 理 性评 来评 试的 测能 , 这 为 能 来较 的 测 信度, 而 提供的评 信息可以 用于 测 评 实 , 从而 低对评 的主 度, 评卷 信度, 最 进一 提 测 可 性的目 。

() 其

评卷 是 年 测开 的 测 可 性的一 。针对 115 试 测文和 测文的 据, Gebril (2010) 测 的 一项 结果发现: 同 一 可 评卷 种题型的 测文()与 评卷 给 种题型 的可 性也 常 。 于 方 的研究 量 常有 , 有赖于 对 问题 的 究, 以期 对 、 的理 和 。 外, 较之对题目 的 测 方差的 度重 而 , 试本 的一 征 的 测 的方差 的 当有 , 中于第 外 。 : Solano - Flores 和 Li (2008)通 应用概化理论发现对于 学 而 , 试 测文题以及题目本 的 (外)的 测 用是 测 最大的方差源。 Huang (2008)用概化理论研究了 拿大 ESL 试 省 试 测 的方差源及信度。三年的 据 结果发现: ESL 和 为 的 试的 同。 ESL 试 测文 的残余方差 比 为 的要 。 一年 ESL 试能 释 的方差 于 为 试的, 其 ESL 试 测 的概化 低于 为 试

。 疑 ESL 公 。
Brennan(2001) 若
, 且 G 稳 。 D 策 兑 。
令 弃 带 诸 便 。 Gao
Brennan(2001) , 推
情 。 建 变 情况 , 尽 ,
。

四、结 论

言 蔽 , 映, 诸
素带 影响, 推思 ,采
纵 , 措 保证 靠 。
日益凸 , / 十 客 ,
返 , 。 / 归绝 
推 保 , 日益 螺旋推 归。 ,
古 / 靠 田。 凭 , 且
长 秘笈, 且 / 器。
, 20 推 ,
献, 望 , 日 借鉴 便 。

文献:

- :《 HSK 高 》, 语言 ,2005 。
- 何莲珍、闵 超:《 证 》,《语 》,2008 6 。
- 李 智:《 语 》,《湖 报》(社 版),2009 2 。
- :《 变 》,《语 》,2006 。
- 、 :《 语 》,《报》,1998 2 。
-  :《 语 》,《 》,2008 5 。
- 乔治·恩舟 德:《 Rasch 》, 译,《 》,2007 4 。
- 、祁宗 、席仲恩:《 整 》,《语 》,2008 5 。
- :《HSK —— 调 》,《 》,2010 10 。

Bachman, L. *Fundamental considerations in language testing*. Shanghai: Shanghai Foreign Language Education Press, 1999.

Engelhard, Jr., G. Differential Rater Functioning. *Rasch Measurement Transactions*, 2008, 21(3).

Gao, X. & Brennan, R. L. Variability of estimated variance components and related statistics in a performance assessment. *Applied Measurement in Education*, 2001, 14(2).

Gebril, A. Bringing reading-to-write and writing-only assessment tasks together: A generalizability analysis. *Assessing Writing*, 2010, 15(2).

Gebril, A. Score generalizability of academic writing tasks: Does one test method fit it all? *Language Testing*, 2009, 26(4).

- Huang, J. How accurate are ESL students' holistic writing scores on large – scale assessments? ——A generalizability theory approach. *Assessing Writing*, 2008 , 13(3).
- Johanson, G. & Alsmadi, A. (1998). *Differential Person Functioning*. ED 420 691.
- Johnson, R. , Penny, J. , Gordon, B. , Shumate, S. R. , & Fisher, S. P. Resolving score differences in the rating of writing samples: Does discussion improve the accuracy of scores? *Language Assessment Quarterly*, 2005 , 2(2).
- Lee, Y.-W. & Kantor, R. Evaluating prototype tasks and alternative rating schemes for a new ESL writing test through G-theory. *International Journal of Testing*, 2007 , 7(4).
- Linacre, J. M. *Many-facet Rasch measurement*. Chicago, IL: MESA Press, 1989.
- Nie, Y. , Yeo, S. M. & Lau, S. Application of generalizability theory in the investigation of the quality of journal writing in mathematics. *Studies in Educational Evaluation*, 2007 , 33(3 – 4).
- Rasch, G. *Probabilistic models for some intelligence and attainment tests* (revised and expanded ed.). Chicago: The University of Chicago Press, 1980.
- Schoonen, R. Generalizability of writing scores: An application of structural equation modeling. *Language Testing*, 2005 , 22(1).
- Sim, J. & Wright, C. *Research in health care: concepts, designs and methods*. Cheltenham, UK: Stanley Thorne, 2000.
http://books.google.com/books?id=vwjhgtUoNZIC&pg=PA335&lpg=PA335&dq=%22estimate+of+Intra-rater+reliability%22&source=bl&ots=6FQUepr6X5&sig=fY5VEyJ_BqG54wSv0w61GVazYAM&hl=en&ei=It7LTIH2EYmAvg00iZnMDw&sa=X&oi=book_result&ct=result&resnum=1&ved=0CBIQ6AEwAA#v=onepage&q=%22estimate%20of%20Intra-rater%20reliability%22&f=false. 2010 – 10 – 30.
- Solano-Flores, G. & Li, M. Examining the dependability of academic achievement measures for English language learners. *Assessment for Effective Intervention*, 2008 , 33(3).
- Sudweeks, R. R. , Reeve, S. & Bradshaw, W. S. A comparison of generalizability theory and many – facet Rasch measurement in an analysis of college sophomore writing. *Assessing Writing*, 2004 , 9(3).
- Wikipedia. *Intraclass correlation*. <http://www.answers.com/topic/intraclass-correlation>. 2010 – 10 – 30.

The Developmental Trend of Open-Ended Assessment Based on Reliability Research of Writing Tests: A Perspective of Generalizability Theory

FUNG Shui-Lung & ZHU Yu

(Beijing Normal University-Hong Kong Baptist University United International College,
 Zhuhai 519085 , China;
 Overseas Education College, Xiamen University, Xiamen 361102 , China)

Abstract: Subjective test has a long history , a strong vitality , and a prosperous future. Meanwhile , its low reliability , considered as its ‘ chronic disease ’ , has been disturbing practitioners and researchers in the field of educational measurement. This paper reviewed the three major schools of reliability theory , and clarified that Generalizability Theory is a forward – looking theory which can offer approaches of improvements based on estimates of variance components of various effects potentially lowering the reliability of a test. Implications to the development of subjective tests were briefly discussed based on a literature review of writing assessment studies from the perspective of Generalizability Theory.

Key words: subjective test ; reliability ; Generalizability Theory ; writing study