



现代语言测试与评估丛书

曾用强 总主编

形成性评估研究

李清华 王伟强 张 放 著



科学出版社

现代语言测试与评估丛书

曾用强 总主编

形成性评估研究

李清华 王伟强 张 放 著

科学出版社

北京

图书在版编目(CIP)数据

形成性评估研究 / 李清华, 王伟强, 张放著. —北京: 科学出版社, 2014.2

(现代语言测试与评估丛书 / 曾用强主编)

ISBN 978-7-03-039664-8

I. ①形… II. ①李… ②王… ③张… III. ①语言-评估-研究 IV. C4109

中国版本图书馆 CIP 数据核字(2014)第 017486 号

责任编辑: 刘彦慧 张翠霞 / 责任校对: 鲁 素

责任印制: 钱玉芬 / 封面设计: 无极书装

联系电话: 010-6401 9074 电子邮箱: liuyanhui@mail.sciencep.com

科学出版社出版

北京东黄城根北街 16 号

邮政编码: 100717

<http://www.sciencep.com>

双青印刷厂印刷

科学出版社发行 各地新华书店经销

*

2014 年 2 月第一版 开本: A5 (890×1240)

2014 年 2 月第一次印刷 印张: 7

字数: 230 000

定价: 58.00 元

(如有印装质量问题, 我社负责调换)

形成性评估是教室里沉睡的巨人，是唤醒他的时候了！

(Brookhart, 2007: 57)

总序

据 Spolsky 考证，正式的语言测试起源于中国东汉时期的科举考试。但是，现代意义上的语言测试却于 20 世纪中叶诞生在英美等发达国家。20 世纪 60 年代，外语测试作为一门新的学科从外语教学中独立出来。作为语言学、教育与心理测量学、计算机技术等的交叉学科，半个世纪以来，国外大批语言学家在语言测试领域取得了卓越的成就。两本专业期刊——《语言测试》(*Language Testing*) 和《语言评估季刊》(*Language Assessment Quarterly*) 相继诞生，在应用语言学界的影响越来越大，语言测试已经成为应用语言学领域的显学之一。在我国这样一个具有浓郁考试文化的大国，考试一直备受国人青睐，甚至受到顶礼膜拜。中国的高考和大学英语考试(CET) 虽有数百万考生规模，但在研究方面仍落后于英美等发达国家。至今，以美国 ETS(Educational Testing Service) 开发的 TOEFL 和英国剑桥大学考试委员会(CESOL) 的 IELTS 为代表的西方国家的研究水平仍执全球之牛耳。但是，我们欣喜地看到，国内学者没有妄自菲薄，外语测试研究日益受到人们的重视，并已经取得一些成绩，一些学者的论文在国际期刊发表，国内专业期刊《外语测试与教学》也在 2011 年于上海外国语大学问世。虽然有若干著述出版，但它们大多关注于测试的开发实践，而对测试理论与实践的研究较少。在此背景下，我和我的博士们策划了“现代语言测试与评估丛书”。在国内学界享有盛誉的科学出版社高瞻远瞩，大力扶持外语研究，欣然同意出版这套丛书，可谓语言测试界的盛举。丛书为国内语言测试研究者提供一个平台，系统展示国内外语言测试领域的新成果，特别是国内学者的原创研究，供广大同行分享。

本丛书分为两个系列：①语言测试与评估：研究系列；②语言测试与评估：实践系列。前者以理论和研究为重点，主要面向应用语言学的研究生和语言测试研究者，后者以实践和应用为重点，主要读者是广大外语教师和教育行政管理人员。本丛书的第一系列围绕语言测试的热点和经典问题展开，主要涉及以下话题：语言测试的效度理论与实证研究、基于任务的语言测试研究、形成性评估研究、ESP 测试研究、动态评估研究、语言测试的评分研究、语言测试计算机自动评分研究、基于语料库的语言测试研究、语言测试的后效研究等。每一本书在保持各自特色的前提下，主要内容包括：①系统介绍相关理论；②本领域的主要研究方法；③实证研究成果分析；④附录：本领域近十年的研究成果。

本丛书的编著者均为语言测试方向的博士和知名学者，相信本丛书的出版将进一步促进国内语言测试研究的发展。本丛书是一个开放的平台，欢迎广大同仁提供自己的新作，欢迎广大读者提出批评与建议。本丛书编著者愿与国内同行一起，为使我国从考试人数大国早日发展成为考试研究大国而努力。

曾用强

2013 年于广州

前　　言

数百年以来，教育评估主要用来选拔和问责(accountability)。近几十年来，教育评估改革的浪潮席卷全球(Berry, 2011)。从世界范围来看，教育评估正在从“对学习的评估”(assessment of learning)转向“为学习的评估” / “学习性评估”(assessment for learning)，从“测试文化”(testing culture)转向“评估文化”(assessment culture)。评估的促学作用越来越受到重视。形成性评估(formative assessment)具有巨大的促学潜力，也被称为“学习性评估”(Berry & Adamson, 2011; Berry, 2008; Stiggins, 2005; Broadfoot & Black, 2004; Stiggins, 2002)或“促学评估”(Huhta, 2008)。尽管斯克里芬(Scriven)早在1967年就明确提出将评估分成形成性的和总结性的两类评估的思想，但直到Black和William(1998a)关于形成性评估的综述的发表，形成性评估实践才在全世界的教育评估中迅速普及起来。

在外语教育领域，形成性评估的研究和实践也风靡全球，但没有得到像大规模高风险测试一样的重视。尽管面临诸多问题和困难，课堂形成性评估的巨大潜在作用吸引了越来越多的学者和教师。很多评估改革对课堂形成性评估寄予厚望。如何改变高考，以及大学英语四级、六级考试和英语专业四级、八级考试等总结性评估(summative assessment)一统天下的局面，使外语评估既达到选拔人才的目的又对教与学产生应有的促进作用？形成性评估如何成为标准化测试的有效补充？如何提高外语课堂评估的质量？如何设计开发适合我国实际的课堂形成性评估？使用哪些技术标准来评价形成性评估的效果？这是我国教育测量界和语言测试界亟待研究的课题。实际上，一些有识之士已着手这方面的工作，

例如，韩宝成(2009)、罗少茜(2003)、李清华(2012, 2006)、李清华等(2013)、王华和富长洪(2006)、王红艳和解芳(2004)等对国外测试评估理念进行的讨论，曹荣平等(2004)、李清华(2008)、王华和甄凤超(2008)、文秋芳(2011)、周娉婷和秦秀白(2005)等进行了形成性评估的试探性研究。《英语课堂教学形成性评价研究》(罗少茜, 2003)介绍了形成性评估在幼儿园和小学的英语教学中的应用，《新课程与教育评价改革译丛》(董奇, 2005)系引进国外的原版著作的译文，这两种书的读者都为中小学教师和管理者，但在理论和研究层面多有欠缺。

本书分为四章和附录。第1章阐述形成性评估的理论基础，包括形成性评估的起源、形成性评估的界定，以及形成性评估与终结性评估、动态评估、课堂评估的关系，主要从学习理论、心理学理论、测量学理论的角度阐述形成性评估的理论基础，讨论形成性评估的效果和信度问题。第2章介绍国内外教育领域，特别是ESL/EFL领域的形成性评估的实践，分别从课堂形成性评估、大规模形成性评估、计算机辅助形成性评估三个维度以实例说明形成性评估的方法。第3章讨论形成性评估的研究方法，分别从量的研究方法和质的研究方法入手，并辅以实证研究成果分析。第4章从全球和中国两个视角讨论形成性评估的现状，指出亟待研究的问题，并展望未来发展的前景。附录部分介绍本领域近十年来的研究成果，供研究者参考之用。

本书的编写分工如下：王伟强负责第3章，张放负责第2章第3节及附录部分，其他章节和全书统稿由李清华负责。

本书被荣幸列入《现代语言测试与评估丛书》并获得出版资助，在此特别感谢作者的博士生导师曾用强总主编的支持和帮助！

科学出版社致力于扶持学术研究，刘彦慧女士为本书的编辑付出了巨大心血，作者深怀感激。

本书面向在读硕士、博士，语言测试研究者和广大外语教师，既有深入的理论探讨，又有丰富的实践方法和研究个案，还提供本领域的最

新研究成果，为读者展示形成性评估的学术思想，促进我国形成性评估的研究与发展。由于作者水平所限，书中难免存在疏漏之处，恳请广大同仁不吝批评指正。

作　　者

2013年于广州

目 录

总序

前言

第1章 形成性评估的理论	1
1.1 形成性评估溯源	2
1.2 形成性评估的概念	10
1.3 形成性评估的理论基础	40
1.4 形成性评估的理论	77
第2章 形成性评估的实践	88
2.1 形成性评估的操作框架	88
2.2 课堂形成性评估实例	93
2.3 大规模形成性评估实践	126
2.4 计算机辅助形成性评估	133
第3章 形成性评估的实证研究	143
3.1 形成性评估实证研究的方法论	145
3.2 以定量研究方法为主的实证研究	149
3.3 以定性研究方法为主的实证研究	159
3.4 小结	165
第4章 形成性评估的现状与未来	166
4.1 国外形成性评估现状	166
4.2 中国形成性评估现状	169
4.3 形成性评估展望	171
参考文献	175

图 目 录

图 1.1 测试、测量、评估和评价的关系	14
图 1.2 自主学习、形成性评估和自我评估的关系	28
图 1.3 诊断性评估和形成性评估与其他评估的对比	36
图 1.4 形成性评估与其他评估的关系	37
图 1.5 评估的使用论证链	55
图 1.6 评估论证的流程	56
图 1.7 形成性推断的效度评价框架	65
图 1.8 信度块示意图	69
图 1.9 形成性评估的效度验证框架	72
图 1.10 形成性评估的社会文化模式	84
图 1.11 形成性评估理论框架	86
图 2.1 KLT 行动理论	89
图 2.2 形成性评估的循环框架	91
图 2.3 课堂评估的过程和策略	92
图 2.4 正式任务的形成性评估的过程	93
图 2.5 教学流程图	95
图 2.6 本课程中期的教学流程	96
图 2.7 形成性评估的操作框架	97
图 2.8 形成性评估流程	106
图 2.9 形成性评估流程修正	113
图 2.10 外语教学的形成性评估体系	114
图 2.11 portfolio 的基本特征	117

图 2.12 实验班和对照班的教学与评估安排	119
图 2.13 PBWA 操作模式	120
图 2.14 能力证据的构成	135
图 3.1 研究思路	149

表 目 录

表 1.1 形成性评估和总结性评估的对比	15
表 1.2 课堂形成性评估与总结性评估的特征	18
表 1.3 评估目的与评估类别的关系	19
表 1.4 语言行为表现评估和传统标准化语言测试的主要差异	25
表 1.5 语言行为表现评估的主要优点	26
表 1.6 形成性评估的特征的变体	39
表 1.7 语言测试效度观的对比	52
表 1.8 Lynch 和 Shaw 的效度理论框架	54
表 1.9 课堂测试效度的证据来源	63
表 1.10 大规模评估与课堂评估概念比较	70
表 1.11 形成性评估效度验证的主要问题及收集数据的方法	74
表 1.12 评估类型及其特点	78
表 1.13 实证主义范式与后实证主义范式的对比	79
表 1.14 心理计量范式、情景化范式和个人化范式的比较	80
表 1.15 社会建构主义的课堂教学理念及评估原则	82
表 2.1 形成性评估主要的教学过程	90
表 2.2 “应用语言学文献阅读与评价”课程安排	94
表 2.3 阅读每篇文章需要回答的问题	98
表 2.4 评价文章需要回答的问题	98
表 2.5 口头报告与小组合作的要求	100
表 2.6 参加者背景	118
表 2.7 教学活动安排	138
表 3.1 研究工具	156

第1章

形成性评估的理论

形成性评估尽管具有巨大的促学潜力，但没有得到像大规模测试一样的重视。大规模测试的统治地位影响了课堂评估重要性的发挥(Cizek, 2009)。尽管面临诸多问题和困难，课堂形成性评估的巨大潜在作用吸引了越来越多的学者和教师。很多评估改革对课堂形成性评估寄予厚望。例如，我国香港地区的“为学习的评估”改革项目明确提出，从2007~2008学年起，基于学校的评估部分取代外部大规模测试的作用(Davison, 2004)；英国威尔士地区从2007年起取消11~14岁学生的标准化测试(Leung & Lewkowicz, 2006)。中国外语教育中出现的围绕高考、大学英语考试(College English Test, CET)等大规模测试的应试教育，已引起越来越多的关注与担忧。近几年来出台的《英语课程标准(实验稿)》(2001年)、《普通高中英语课程标准(实验)》(2003年)和《大学英语课程教学要求》(2004年)则试图改变中国英语教学与评估的现状，突出了形成性评估的重要地位。形成性评估为何难登大雅之堂，为何不能成为标准化测试的有效补充？如何提高外语课堂评估的质量？如何设计开发适合我国实际的课堂形成性评估？使用哪些技术标准来评价形成性评估的效果？这是我国教育测量界和语言测试界亟待研究的课题。实际上，一些有识之士已着手这方面的工作，例如，国家基础教育课程改革“促进教师发展与学生成长的评估研究”项目组主持的“新课程与教育评估改革译丛”(2003~2005年)，韩宝成(2009)、罗少茜(2003)、李清华(2006)、

王华和富长洪(2006)、王红艳和解芳(2004)等对国外测试评估理念的讨论，曹荣平等(2004)、李清华(2008)、王华和甄凤超(2008)、文秋芳(2011)、周娉婷和秦秀白(2005)等进行的形成性评估的试探性研究等。为了改变高考和大学英语四、六级考试等总结性评估一统天下的局面，使外语评估既达到选拔人才的目的又对教与学产生应有的促进作用，课堂形成性评估大有可为。

毋庸讳言，形成性评估面临巨大挑战。人们使用“形成性评估”时，其概念往往相去甚远；形成性评估的实践灵活多变，似乎无章可循；形成性评估的理论也鱼龙混杂。没有理论指导的实践是盲目的，没有理论基础的学术研究方法和结果是混乱的。本章讨论形成性评估的理论问题：追溯形成性评估的源头，理清形成性评估的概念，明确形成性评估的理论基础，构建形成性评估的理论。

1.1 形成性评估溯源

形成性评估是教育评估(educational assessment)的理论之一，教育评估是从教育评价(educational evaluation)和教育测量(educational measurement)发展而来的。教育评估的渊源可追溯至中国西周时期的科举考试制度，但现代意义上的教育评估却产生于美国。从世界范围来看，教育评估的发展历史可大致划分为以下四个阶段。

1.1.1 教育评估的萌芽时期(19世纪中叶至20世纪30年代)

19世纪下半叶，西方国家在实验心理学和数理统计学的基础上，用检查考核的手段对个体在智能上的差异进行定量研究，即探索对学生学力的客观化、标准化测量，从而为教育测量理论的建立奠定了基础。

1845年，美国的梅恩(Mann)首先在马萨诸塞州波士顿文法学校引入统一试卷的书面考试。

1879年，德国心理学家冯特(Wundt)在莱比锡大学建立了世界上第一个心理学实验室，摸索出一套心理测量的方法。1882年，英国科学家高尔顿(Galton)在伦敦设立了人类学实验室，对人类心理遗传及个体差异进行研究，并设计了许多统计方法。冯特和高尔顿的研究对学生学力测量的研究产生了较大影响。1894年，美国心理学家卡特尔(Cattell)在哥伦比亚大学使用各种测量考核本校大学生。这些研究为20世纪初教育测量运动奠定了基础。美国学者桑代克(Thorndike)和他的学生做出了突出的贡献。桑代克的《心理与社会测量导论》(1904年)具有划时代的意義。他提出了“凡是存在的东西都有数量，凡有数量的都可测量”的著名信条。他与他的学生积极投入教育测量工作，陆续编制了各科标准测验^①(standard test)(包括学业测验、智力测验和人格测验)和标准测量表(standard scale)。此后，各种修订的量表层出不穷(如1905年问世的《比奈-西蒙智力量表》)，智力测验风靡世界。随着教育测量的发展，人们开始用学生学力测验结果来评估学校教育。与学力测验相关的升级率、退学率、教学效率等指标及其评估方法开始出现。教育测验运动取得了巨大成就。然而，人们逐渐认识到，教育测验尽管能使考试客观化、标准化，并能把人的能力换算成数字，甚至个别差异的程度也可以度量，但测验毕竟不能测量人的全部，即便是研究成果最多的学力测验，也不能测得学力的全部领域。例如，社会态度、创造力、兴趣、鉴赏力等重要的学力内容，因难以数量化，教育测验不能充分把握，往往被教育者冷落。因此，对教育测验的批评越来越多。

教育评估正是为弥补教育测验之缺陷而发展起来的。当然教育评估并非取代教育测验，而是在重视原有教育测验的同时，也注重测验以外的评估方法，从而把所有能够用以考查教育效果的方法综合起来，以评定教育是否实现全部教育目标。

^① test在教育和心理测量界多译为“测验”，在语言测试界统称为“测试”。

1.1.2 教育评估的形成时期(20世纪30年代至50年代)

美国在1933~1940年开展了一次历时八年的课程改革，史称“八年研究”，该研究的目的是改革中学的核心课程(core curriculum)。为检验课程改革实验的结果，分析新课程与大学学习的关系，全面衡量学生的各项进步，成立了以泰勒(Tyler)为首的评估委员会，他们进行了卓有成效的评估改革实验研究，取得了一系列新成果。后人把以泰勒为首的评估委员会八年的研究成果《史密斯-泰勒报告》，称为“划时代的教育评估宣言”，泰勒也因此享有“教育评估之父”的美誉。

泰勒教育评估的基本思想包括：①教育是使人的行为方式发生变化和改进的过程；②这些形形色色的行为方式的变化就是教育目标；③教育评估就是确定教育目标实现程度的过程；④人的行为是复杂的，有的可以量化，有的难以量化。因此，除测验以外，还需要用其他各种评估手段(如观察、调查等)来检查教育效果。

泰勒教育评估的过程分为四个步骤：第一步，确定教育目标；第二步，设计评估情境；第三步，选择和编制评估工具；第四步，分析评估结果。这就是著名的泰勒模式(行为目标模式)，这一模式把确定教育目标作为评估过程的核心和关键，行为目标模式也因此而得名。从教育评估的历史来看，泰勒对教育评估发展的贡献突出表现在以下四个方面：

第一，泰勒在实验研究和评估实践的基础上首次提出了“教育评估”的概念，使评估与测验区分开来，并据此提出了富有创新意义的评估体系和模式。

第二，泰勒用具有学生行为对应物的具体教育目标作为评估标准，用预定的结果作为尺度来衡量学生的进步水平，从而避免了教育评估的任意性和主观性，在一定程度上提高了评估的客观性和科学性。

第三，泰勒的评估是一种目标参照评估，他注重的是绝对的教育目标实现的程度，而不是像以往测验那样只关心学生团体中的成绩差异和