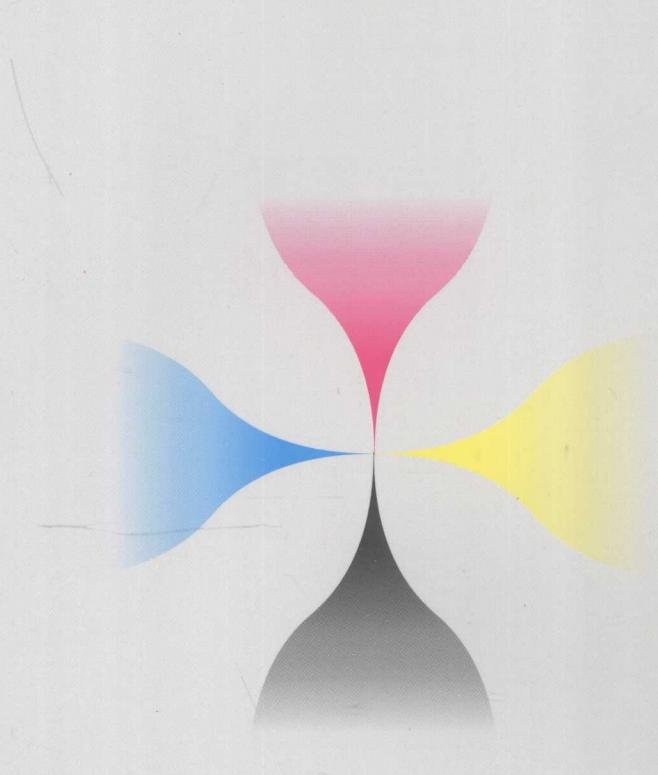


中国外语教育研究中心 外语考试自动评分研究系列丛书



大规模考试 英语作文 自动评分系统的 研制

梁茂成 著



中国外语教育研究中心 外语考试自动评分研究系列丛书

1538853

张凌云 编著 目录设计并图

张凌云 编著 中国大学出版社协会推荐教材
2012年全国优秀教材一等奖 荣誉证书
2010-2011学年 甲类教材

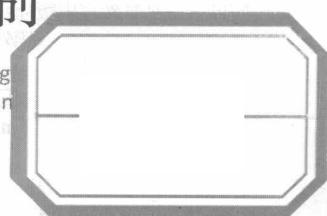
张凌云 编著 中国大学出版社协会推荐教材
2010-2011学年 甲类教材

张凌云 编著 中国大学出版社协会推荐教材

大规模考试 英语作文 自动评分系统的 研制

梁茂成 著

daguimo kaoshi yingyu zuowen zidong ping
xitong de yan



高等教育出版社·北京
HIGHER EDUCATION PRESS BEIJING

张凌云 编著 中国大学出版社协会推荐教材
2010-2011学年 甲类教材

图书在版编目（C I P）数据

大规模考试英语作文自动评分系统的研制 / 梁茂成
著。-- 北京 : 高等教育出版社, 2012.7
ISBN 978-7-04-035572-7

I . ①大… II . ①梁… III . ①计算机系统 - 评分 - 应用 - 英语 - 写作 - 考试 - 研究 IV . ①H315-39

中国版本图书馆 CIP 数据核字 (2012) 第 122281 号

策划编辑 贾巍巍 责任编辑 巩 媛 封面设计 刘晓翔 版式设计 刘 艳
责任编辑 巩 媳 责任印制 田 甜

出版发行	高等教育出版社	咨询电话	400-810-0598
社址	北京市西城区德外大街4号	网 址	http://www.hep.edu.cn
邮政编码	100120		http://www.hep.com.cn
印 刷	北京市联华印刷厂	网上订购	http://www.landraco.com
开 本	787mm×1092mm 1/16		http://www.landraco.com.cn
印 张	9.75	版 次	2012 年 7 月第 1 版
字 数	175千字	印 次	2012 年 7 月第 1 次印刷
购书热线	010-58581118	定 价	25.00元

本书如有缺页、倒页、脱页等质量问题, 请到所购图书销售部门联系调换
版权所有 侵权必究
物 料 号 35572-00

序 言

美国未来学家Nicholas Negroponte在他的《数字化生存》里谈到，美国的《电视导报周刊》（TV Guide）的利润超过所有四家电视网利润的总和，这意味着关于信息的信息（the information about information），其价值可以高出信息本身。在因特网的风火轮推动下的信息社会里，每一个人都可以说是拥有一个全世界的数据库，淹没在海量的信息里。所以他提出“少就是多”的重要概念；这也正是Google这样的搜索引擎能够大行其道的原因。Google所依赖的技术是自动文本分类（text classification）或文本归档（text categorization），其目标就是从浩如烟海的信息中提取最有效的信息。上一个世纪90年代以来，建立以人工智能技术为基础的文本分类系统成为信息科学中的一个重要目标。用Google检索text classification这两个词，可以得到13,600,000个条目，光pdf格式的文章就差不多有1,240,000篇（2006年2月1日检索，可能有重复），就是一个明证。

文本分类是一个应用范围甚广的领域，将学生在考试中的作文进行分类（即评分）就是一个很有前景的研究方向。Mark Shermis 和Jill Burnstein（2003）所主编的*Automated Essay Scoring: A Cross-Disciplinary Perspective*就介绍了5种评分系统。我国是一个考试大国，一个考试动辄几十万考生，而从语文（包括汉语和外语）试卷到其他科目的试卷都有许多开放性试题，改卷评分不但牵涉到很多阅卷员，而且很容易造成评分信度不高的问题，有失考试的公正。

在我国，也有不少仁人志士力图结合我国实际找出一条作文自动评分的路子，这是一个有很大现实意义的课题。但这也是一个复杂的攻坚课题，不可能一蹴而就，因为它牵涉到跨学科的研究和团队的共同努力。

我十分高兴地看到梁茂成教授的新著《大规模考试英语作文自动评分系统的研制》的问世。该研究不但对当前作文自动评分的各种探索进行评论和总结，而且结合我国的实际提出一个综合运用语料库语言学和统计学而构建的模型，并设计了可运行的程序。研究中所构建的模型包括了一些足以影响作文评分的变量，而且运用多元回归的方法建立了一个预测分数的公式，并进行验证。整个研究思路广阔、设计合理、论证充分，为我国日后建立更完善的自动作文评分系统做出了很有意义的尝试。

当然，作为一个模型，还有许多变量（如语言失误）有待摸索，而真正作

为一个自动化系统而建立和实施，也还有许多问题（如结合人工智能算法和建立语法分析器；除评估信度外，采用文本分类领域更常见的评价指标，如准确率（precision）和查全率（recall）等等）需要进一步考虑。但是梁茂成博士的研究的重要价值在于它在中国建立自动化评分系统的科学攀登中拉开了序幕，迈出了可贵的第一步。坚冰在融解，希望在前头！



2012年夏

我与“大规模考试英语作文自动评分系统的研制”一文的缘分，要追溯到2006年。那一年，我从中国科学院大学（原中国科学院研究生院）毕业，获得博士学位。我的导师是梁茂成博士，他也是这篇文章的作者之一。当时，我正在读研二，梁茂成博士已经退休，但仍然活跃在学术界。他经常在实验室里工作，有时会带一些研究生一起讨论。我印象最深的一次，是他在实验室里给我展示了一个名为“自动评分系统的原型”的软件。这个软件可以自动批改学生的作文，并给出评分。我当时觉得这个系统非常神奇，因为它能够自动识别文章中的语法错误、拼写错误以及句法结构等问题，并根据这些错误给出相应的评分。我问梁茂成博士：“这个系统是怎么做到的？”他告诉我，这个系统使用了自然语言处理技术，通过分析文章的语义和语法结构，来判断文章的质量。他还说，这个系统在当时的考试中表现得非常好，准确率很高。我被这个系统的神奇功能深深吸引，决定以后也要从事这方面的工作。从那时起，我就开始关注这个领域的研究进展，并尝试自己动手实践。2012年夏天，我写下了这篇文章，分享我对这个领域的看法和理解。这篇文章后来被发表在《中国科学院大学学报》上，引起了广泛关注。之后，我继续在这个领域深耕，逐渐成长为一名优秀的学者。现在，我已经成为了中国科学院大学的一名教授，同时也担任着多个项目的负责人。我将继续努力，为推动我国的自然语言处理技术发展做出贡献。

中文 摘要

本研究在梁茂成（2005）的基础上，挖掘新的文本特征变量，设计英语作文自动评分系统，并对该评分系统的评分信度、最低训练集样本量、适用文体类型、信度影响因素等问题进行探讨。

研究中收集了5个不同题目共1,067篇大学生英语命题作文，其中4个题目为议论文，1个为说明文。首先组织多名人工评分员对以上作文进行分析型人工评分，分析其评分信度，然后对这些作文进行多轮、多次抽样，组建训练集，对自行设计的作文评分系统的性能进行较大规模的验证。此外，研究中还对自动评分系统的构架、变量类型、汇编语言等进行了介绍，并就几个有代表性的变量进行了研究，对这些变量在自动评分系统中的应用进行了描述。

研究中主要回答以下问题：

- 1) 以统计模型为基础设计而成的作文自动评分软件是否达到可操作水平？
评分系统的评分信度是否能够达到语言测试的要求？
- 2) 人工评分信度对自动评分信度和评分模型的稳定性有何影响？
- 3) 训练集作文的最低样本量至少应该达到多少？
- 4) 作文自动评分系统对不同文体学生作文进行自动评分时是否具有同等效果？

研究发现，由于我们在英语作文自动评分系统中设置了一些对作文质量具有较强预测能力的文本变量，使得系统在接受了足够的训练之后，自动评分的评分信度达到了 $r = 0.752$ 或更高，可以满足统计学和测试学的要求。在训练集信度可靠的前提下，自动评分系统的评分信度最高达到 $r = 0.83$ 以上，作文评分系统的评分结果与人工评分的结果之间的吻合率（在0~5的量表上）高于ETS的E-rater，表明当训练集样本信度可靠时，本研究中设计的英语作文自动评分系统的评分信度高于E-rater。因此，该系统已经达到了可操作水平。

本研究还发现，人工评分信度从两个方面对自动评分模型的稳定性产生影响。首先，当人工评分信度较低时，机器学习遵循“Garbage in, garbage out”的规则，自动评分信度也相应较低；当训练集人工评分信度较高时，自动评分信度也随之升高。其次，不同的人工评分员之间的评分信度差异对自动评分的信度也存在影响。由于训练集数据存在内在的不一致性，致使自动评分系统学习困难，评分信度降低。

对于第三个问题，研究中通过多轮多次、大小不同的训练集来对机器评分模型加以训练，并对验证集作文的自动评分信度加以比较和分析，发现当训练集样本量达到125时，自动评分系统的评分的信度开始趋于稳定并达到统计学和测试学要求。研究还表明，当训练集样本量达到125这个临界点后，大幅度增加训练集的样本量对提高机器评分的信度可能没有很大的作用。

有关自动评分系统能否适应对不同文体的作文进行自动评分的问题，研究发现，由于本研究中设计的作文自动评分系统中设置了一些可以侦测文体特征的变量，使得作文自动评分系统对学习者写作的英语议论文和说明文都可以实现自动评分，且评分信度可靠。在议论文和说明文评分模型中，权重变量既有相同的，也有不同的，表明模型中部分变量在对议论文进行自动评分时起较大作用，另一些变量在对说明文进行自动评分时起较大作用，还有一些变量在对两类文体的作文进行自动评分时都起作用。

关键词：作文自动评分，机器学习，统计模型，信度

自动评分系统是近年来研究的一个热点，其主要研究方法有机器学习、统计模型等。机器学习方法通过大量的训练数据，利用算法自动地从数据中学习，从而完成特定任务。统计模型则通过建立数学模型，利用概率论和数理统计的方法，对数据进行分析和预测。这两种方法在自动评分系统中的应用，使得自动评分系统的准确性和可靠性得到了显著提高。本文将介绍机器学习和统计模型在自动评分系统中的应用，并探讨它们各自的优缺点。

机器学习方法在自动评分系统中的应用，主要是通过构建一个能够自动识别作文特征的模型，从而实现对作文的自动评分。这个模型通常由输入层、隐藏层和输出层组成。输入层接收作文文本，通过预处理（如分词、去除停用词等）后，将其转换为向量形式。隐藏层则通过神经元之间的连接，对输入信息进行处理，从而提取出作文的特征。输出层则根据这些特征，输出一个评分值。这种方法的优点在于，它不需要手动标注大量的训练数据，而是通过大量的样本自动地学习到作文的特征，从而实现自动评分。然而，这种方法的缺点在于，它需要大量的训练数据，而且训练过程可能非常耗时。另外，这种方法的准确性可能受到输入数据的质量和数量的影响。

统计模型在自动评分系统中的应用，主要是通过建立一个能够描述作文特征与评分之间关系的数学模型，从而实现对作文的自动评分。这个模型通常由输入层、中间层和输出层组成。输入层接收作文文本，通过预处理后，将其转换为向量形式。中间层则通过线性或非线性函数，对输入信息进行处理，从而提取出作文的特征。输出层则根据这些特征，输出一个评分值。这种方法的优点在于，它不需要大量的训练数据，而且训练过程相对简单。然而，这种方法的准确性可能受到输入数据的质量和数量的影响，而且模型的解释性可能不如机器学习方法。

English Abstract

On the basis of a previous research project (Liang, 2005), this study attempts to add new variables into the existing automated essay scoring (AES) model, and design an operational AES system. The study also reports results of an analysis of the reliability of the essay scores generated by the system designed herein. In addition, the research reported in this study also attempts to reveal the minimum requirement for the sample size of the training set needed for the system to yield reliable essay scores, the genre types of the essays the system can handle, as well as factors which may affect the reliability of the scores generated by the system.

Five sets of essays, totaling to 1,067, were collected, with each set addressing a different essay prompt. Among the 5 sets of essays, 4 are argumentative and 1 expository in nature. Multiple human raters were recruited to rate the essays with analytical essay scoring schemes. Reliability of the human-generated essay scores was then analyzed. The resulting data, composed of essays and their corresponding human-generated scores, were fed into the computer system to construct essay scoring models and to validate the model so constructed. During this process, multiple training sets were created by way of multiple sampling to avoid the possible heterogeneity of the data, and the remaining essays in each set were then used as data for validating the models. Mean reliability estimates for the validation are reported. Besides, the report also introduces the architecture of the AES system, the types of variables in the scoring model, and the programming language employed to design the computer program. Further, a few representative variables in the scoring model are highlighted, with their research backgrounds and findings reported separately. Descriptions are also given as to how these variables are embedded in the architecture of the computer application.

The study attempts to address the following research questions:

- 1) Is the statistically-based AES system operational in terms of the reliability of the scores automatically generated? Can the reliability of the computer-generated scores meet the requirement described in the testing literature?
- 2) In what way does the reliability of the human-generated essay scores for the training set affect the reliability of the computer-generated scores?
- 3) In order for the system to generate reliable essay scores, what is the minimum requirement for the sample size of the training set?
- 4) Is the AES system equally effective in handling student essays of different genres?

Findings of the study indicate that, thanks to the predictive power of the text variables in the essay scoring model, the AES system can yield essay scores with a reliability estimate of $r = 0.752$ or higher, so far as the minimum requirement for the sample size of the training set is satisfied. Such a reliability estimate is undoubtedly higher than what statisticians and language testers can expect in subjective testing items such as essay writing. It is also found that, as far as reliable scores have been assigned to the essays in the training set, the AES system can yield a maximum reliability of $r = 0.83$ or higher, and the consensus estimate (exact agreement and exact-plus-adjacent agreement on a 0-5 scale) of the essay grades generated by the computer runs higher than that reported of ETS' E-rater, an indication that the AES system is capable of generating more reliable scores than the E-rater. Therefore, the reliability analysis shows that the AES system can be reliably put into operation.

Investigation into the second research question shows that human scores assigned to the essays in the training set can affect the reliability of computer-generated scores in two ways. First, the maxim in machine learning, "Garbage in, garbage out", turns out to hold true. When scores of low reliability are taken as input for learning, the AES system correspondingly outputs less reliable scores, and vice versa. Second, the magnitude of the differences between inter-rater reliability estimates in the training data also has a role to play in affecting the reliability of computer-generated essay scores. When all human raters think alike, the computer follows. When some human raters have consensus while others do not, expectedly, the computer is at a loss for what to learn.

To address the third research question, multiple training sets were created by way of multiple sampling, with results derived from each sampling. Results for such sampling are then compared. It is found that, when the sample size of the training set reaches 125, computer-generated scores become more stably reliable. Data analysis also seems to indicate that a large increase in the sample size of the training set beyond 125 may not bring about an expected growth of the reliability of computer-generated scores.

Whether or not the AES system can handle student essays of different genres is an issue related to the applicability of the computer program. A comparative study of the validation data shows that while some variables in the scoring model are equally predictive of the quality of both argumentative and expository student essays, some other variables in the model seem to be sensitive to different genres. The different weighting of the beta values for these variables in the scoring model

renders it possible for the AES system to use different marking schemes, an ability which enables the AES system to handle student essays of different genres.

Key Words: automated essay scoring, machine learning, statistical model, reliability

目 录

第1部分 绪论及相关研究回顾 1

第一章 绪论	2
1.1 本研究的背景	2
1.2 研究目的及研究问题	3
1.3 本研究报告的结构	4

第二章 国外作文自动评分系统评述 5

2.1 引言	5
2.2 二语及外语作文评分要素	5
2.3 国外现有作文自动评分系统述评	6
2.4 国外作文自动评分系统的启示	11

第2部分 研究方法 15

第三章 数据准备	16
3.1 本研究中使用的语料	16
3.2 文本转换、清理与预处理	21
3.3 人工评分	21
3.4 人工评分信度报告	25

第四章 系统构架及研究的操作步骤 29

4.1 引言及系统概要	29
4.2 研究工具	29
4.3 变量类型	36
4.4 多元回归	39
4.5 汇编语言	39

4.6 研究的操作步骤	40
-------------------	----

第3部分 学习者作文的三项分析 46

第五章 学习者作文中的连贯性分析	47
------------------------	----

5.1 话语的连贯性	47
5.2 相关文献回顾	48
5.3 研究方法	50
5.4 结果与讨论	54
5.5 小结及本研究在英语作文自动评分系统中的应用	58

第六章 潜在语义分析在学生作文内容分析中的应用	60
-------------------------------	----

6.1 引言	60
6.2 潜在语义分析与学习者作文内容的自动评价	60
6.3 研究方法及程序设计	62
6.4 研究结果及其在英语作文自动评分系统中的应用	67

第七章 学习者作文中的情态序列分析	68
-------------------------	----

7.1 情态动词、情态序列与情态意义	68
7.2 对二语学习者情态动词习得情况的研究	70
7.3 研究设计	71
7.4 研究结果与讨论	74
7.5 小结及本研究在英语作文自动评分系统中的应用	84

第4部分 系统的评分信度和系统的应用 86

第八章 作文自动评分信度分析	87
----------------------	----

8.1 引言	87
8.2 自动评分信度的影响因素	88
8.3 机器评分与人工评分之间的相关性分析	93
8.4 吻合率分析	95
8.5 自动评分系统对不同文体学生作文的适应能力	99
8.6 小结	102

第九章 作文自动评分系统的应用	103
-----------------------	-----

9.1 适用文体	103
----------------	-----

9.2 人工评分阶段	103
9.3 机器学习及机器评分阶段	105
9.4 机器评分结果的利用	106
9.5 小结	107
第5部分 结论	108
第十章 结论	109
10.1 本研究的主要发现	109
10.2 本研究的局限	110
10.3 后续研究	110
参考文献	112
英文参考文献	112
中文参考文献	118
附录	120
附录I: PEG的变量及其beta值 (Page 1968)	120
附录II: Page (1995) 的模型及其变量	121
附录III: CLAWS4 赋码集	122
附录IV: Treetagger 赋码集	127
附录V: 演示光盘使用说明	129
一、光盘结构及系统运行设置	129
二、英语作文自动评分系统 (演示版)	129
三、光盘中的数据及其来源	130
四、系统运行前准备	131
五、系统操作方法	131
六、自动评分结果的分析	134

表格目录

表格 1：三种作文自动评分系统比较	9
表格 2：本研究中的主要文本数据信息	18
表格 3：印象评分与分析型评分的比较	22
表格 4：作文评分主要方面	23
表格 5：作文内容评分量表	24
表格 6：第一组作文人工评分信度	25
表格 7：第二组作文人工评分信度	26
表格 8：第三组作文人工评分信度	26
表格 9：第四组作文人工评分信度	27
表格 10：第五组作文人工评分信度	27
表格 11：五组作文人工评分信度对比	28
表格 12：名词短语自动标注	37
表格 13：训练和验证的轮次及训练集样本量的递增变化	44
表格 14：与连词相关的变量一览表	52
表格 15：连贯性先导性研究中所用数据的人工评分信度	53
表格 16：各种衔接纽带与作文得分相关性一览表	55
表格 17：局部连贯能力、整体连贯能力与作文质量间的相关性	56
表格 18：分组后局部连贯能力与整体连贯能力对照	57
表格 19：句法环境与情态动词语义间的对应关系	70
表格 20：情态序列研究所用语料基本信息	72
表格 21：情态序列研究文本处理方法示例	73
表格 22：情态动词的过多和过少使用	75
表格 23：学习者语料库中过多使用的情态序列 （主题性最高的20个正主题词）	77
表格 24：学习者语料库中过少使用的情态序列 （主题性最低的20个负主题词）	80
表格 25：高、低分组间两类情态序列的频数差异（卡方检验）	81
表格 26：情态动词后使用频率最高的动词（前20）	82

表格 27：本族语者和学习者“人称代词+情态动词”频率对照	83
表格 28：“人称代词+情态动词”序列的频数与 学习者作文水平间的关系	84
表格 29：五组作文人工评分信度对比（同表格11）	93
表格 30：E-rater评分信度（Burstein et al., 2001）	95
表格 31：第一组作文机器评分与人工评分之间的完全及相邻吻合率	95
表格 32：第二组作文机器评分与人工评分之间的完全及相邻吻合率	96
表格 33：第三组作文机器评分与人工评分之间的完全及相邻吻合率	96
表格 34：第四组作文机器评分与人工评分之间的完全及相邻吻合率	97
表格 35：第五组作文机器评分与人工评分之间的完全及相邻吻合率	98
表格 36：说明文自动评分模型和议论文自动评分 模型中权重变量的异同（前10位）	101

插图目录

图 1: 外挂词典示例	30
图 2: patcount.pl的输出结果	34
图 3: Treetagger的命令行运行方式	35
图 4: 运行R	36
图 5: 名词短语列表示例	38
图 6: 评分模型训练结果输出示例	43
图 7: 自动评分信度验证结果输出示例	44
图 8: 学生英语写作中局部连贯能力和整体连贯能力发展变化	58
图 9: 矩阵构建	66
图 10: 学习者与本族语者情态动词使用频率对比	75
图 11: 训练集样本量与验证信度的关系	89
图 12: 第三组和第四组作文训练集样本量与评分信度间的关系	92
图 13: 第五组作文训练集样本量与评分信度间的关系	94
图 14: 说明文训练集样本量与验证信度（第四组作文）	100

第1部分

绪论及相关研究回顾

第1部分共分两章，第一章介绍研究背景，提出研究问题；第二章综述国外具有代表性的作文自动评分系统，并分析其得失，为本研究提供启示。