



语言记录 中的 语料库建立

蘇沙

马克思普朗克 心理语言学研究所

hilario@bambooradical.com hilario.desousa@mpi.nl

ELDP 语言记录培训 ELDP School on Language Documentation 玉溪师范学院 Yuxi Normal University

Corpus construction in Language Documentation

Hilário de Sousa

Max Planck Institute for Psycholinguistics

语言描述
*Language
Description*

≠

语言记录
*Language
Documentation*

语料库语言学的
语料库
Corpus
for Corpus Linguistics

≠

语言记录的
语料库
Corpus
for Language Documentation

语言描述
*Language
Description*

≠

语言记录
*Language
Documentation*

透过语言资料描述语言结构

*Describing language structure through
language data*

- 收集语言资料并非主要目的
- *Collecting language data is not the
primary goal*
- 收集语言资料种类不一定要很
广
- *Range of language data do not
necessarily need to be very wide*

语言记录的焦点是 可以观察的语
言行为与知识。语言记录的目
的是对于 [在某一个时间某一
个话语社团观察到的的语言行
为、和话者对这些语言行为的
知识] 的持续、多功能纪录。

“Language documentations [...] focus
on observable linguistic behavior
and knowledge. The goal is a
lasting, multifunctional record of
the linguistic practices attested at a
given time in a given speech
community and the knowledge
speakers have about these
practices.” (Himmelman 2008:
346)

语言描述
Language
Description

≠

语言记录
Language
Documentation

透过语言资料描述语言结构

Describing language structure through language data

- 收集语言资料并非主要目的
- *Collecting language data is not the primary goal*
- 收集语言资料种类不一定要很广
- *Range of language data do not necessarily need to be very wide*

全面性纪录一个话语社团的语言行为（与话者对之的认识）：

Comprehensive record of the linguistic practices of a speech community:

- 词汇 *lexicon*
- 语用方程式 *speech formula*
- 对话 *conversation*
- 独白 *monologue*
- 语言艺术 / 语言游戏 *linguistic art/ language game*
- 仪式语言 *ceremonial language*

等等 etc.

语言描述
*Language
Description*

≠

语言记录
*Language
Documentation*

透过语言资料描述语言结构

*Describing language structure through
language data*

- 收集语言资料并非主要目的
- *Collecting language data is not the
primary goal*
- 收集语言资料种类不一定要很
广
- *Range of language data do not
necessarily need to be very wide*


多功能纪录 *multifunctional record*

对象 *target:*

- 提供资料的语言社团 *speech
community that provided the data*
- (不同类型的语言学家和其他学
者 *various types of linguists and
other scholars*)

等等 *etc.*

语言描述
Language
Description



语言记录
Language
Documentation

提供资料的语言社团 *speech community that provided the data*

- 语言文化保育 / 复兴 *maintenance/ revival of language and culture*

语言学及其他相关学科 *linguistics and related disciplines*

- 语音学 / 音韵学 *phonetics/phonology*
 - 词法学 / 句法学 *morphology/syntax*
 - 语义学 *semantics*
 - 语用学 *pragmatics*
 - 社会语言学 *sociolinguistics*
 - 心理语言学 *psycholinguistics*
 - 认知语言学 *cognitive linguistics*
 - 计算语言学 *computational linguistics*
 - 语料库语言学 *corpus linguistics*
 - 语言教学 *language teaching*
 - 语言政策 *language policy*
- 文体学 *stylistics*
 - 人类学 *anthropology*
 - 语言人类学 *linguistic anthropology*
 - 民族音乐学 *ethnomusicology*
- 等等 etc.

语言描述
*Language
Description*

≠

语言记录
*Language
Documentation*

透过语言资料描述语言结构

*Describing language structure through
language data*

- 收集语言资料并非主要目的
- *Collecting language data is not the
primary goal*
- 收集语言资料种类不一定要很
广
- *Range of language data do not
necessarily need to be very wide*

持续纪录 *lasting record*

- 档案格式 / 媒体 *file format/
medium*
- 档案命名 *file naming*
- 原数据 *metadata*

语料库语言学 的
语料库
Corpus
for Corpus Linguistics

≠

语言记录 的
语料库
Corpus
for Language Documentation

代表性 & 平衡性
Representativeness & Balance

对象 *Target*:

- 学者 *scholars*

语料库建立 *Corpus construction*:

- (资料来源的版权问题
copyright issues of source data)
- 学者的需求 *scholars' needs*


对象 *Target*:

- 学者 *scholars*
- 话语社团 *speech community*

语料库建立 *Corpus construction*:

- (资料来源的版权/隐私问题
copyright/privacy issues of source data)
- (学者的需求 *scholars' needs*)
- 话语社团的需求 *speech community's needs*

语料库语言学的
语料库
Corpus
for Corpus Linguistics



语言记录的
语料库
Corpus
for Language Documentation

语料库语言学的代表性与平衡性

*Representativeness & Balance in
Corpus Linguistics*

- 数量上的严格控制(统计学原因)
tight quantity control (statistical reasons)
- 资料有数量上的上限 *upper limits in quantity of data*
- 标写必须划一(&计算机可读)
transcriptions must be consistent (and machine-readable)

语言纪录的代表性与平衡性

*Representativeness & Balance in
Language Documentation*

- 平衡各人的需求 *Balancing the needs of various people*
 - 话语社团各人 *various people of the speech community*
 - (不同学者 *different scholars*)
- 平衡性可以因应代表性稍为调节 *Balance can be slightly adjusted due to representativeness*
- 资料无上限 *no upper limits of data*
- 标写的划一... *consistency of transcriptions...*

语料来源

Source of data

- 田野调查 *fieldwork*
 - 一手资料 *first hand data*
 - 二手资料 *second hand data*
 - 准不准你用 *permission for usage*
 - 可不可靠 *is it reliable*
 - 「适不适合」 *is it 'suitable'*
- 公开的文字 / 录音 / 录像 (注意版权问题) *public text/audio/video*
(*beware of copyright issues*)
 - 已出版的文章 *published articles*
 - 网上发言 / 对话 (注意隐私问题) *internet speech/conversation*
(*beware of privacy issues*)
 - 电台 / 电视台 / 网上广播 *radio/television/internet broadcast*
 - 准不准你用 *permission for usage*
 - 可不可靠 *is it reliable*
 - 「适不适合」 *is it 'suitable'*

语料种类 - 语言行为与知识

Type of data - Linguistic Behaviour and knowledge

沟通活动 *communicative events*

列表式资料 *lists*

- 词形系列 *paradigms*
- 民俗分类 *folk taxonomy*

分析资料 *analytic matters*

要有语言学分析 / 翻译 / 注释 *with linguistic analysis/translation/
commentary*

语料种类 - 沟通活动的自然程度

Type of data - naturalness of communicative events



(自然沟通活动 natural communicative events)

被观察的沟通活动 observed communicative events

- 半自然沟通活动 semi-natural communicative events
 - 不受调查者控制的录音录影 records not directed by the investigator
 - 已出版文字 published texts
- 被设计/布局式沟通活动 staged communicative events
 - 无工具 without props
 - 有工具 with props
- 直接提问 elicitation
 - 语境化 contextualisation
 - 翻译 translation
 - 判断 judgment

话语自我意识 *linguistic self awareness*
调查者的控制 *investigators' control*
不自然 *unnatural*

语料种类 - 计划程度

Type of data - level of planning

无计划 *unplanned*



有计划 *planned*

大类 <i>major types</i>	例 <i>examples</i>
感叹 <i>exclamative</i>	「哎呀！」 <i>'Aiya!'</i> 「救命呀！」 <i>'Help!'</i>
指令 <i>directive</i>	「叉烧包！」 <i>'Porkchop bun!'</i>
对话 <i>conversational</i>	问候 <i>greetings</i>
	寒暄 <i>small talks</i>
	聊天 <i>chat</i>
	讨论 <i>discussion</i>
独白 <i>monological</i>	访问 <i>interview</i>
	叙述 <i>narrative</i>
	描述 <i>description</i>
	演说 <i>speech</i>
仪式 <i>ritual</i>	官方通报 <i>formal address</i> 连祷 <i>litany</i>

准许 *Consent*

合作人要清楚明白录音／录影可能的用途；合作人有资料发放的权控制。

The consultant needs to clearly understand the potential usage of data; the consultant has rights over the distribution of data.

同意书（签名）／口头同意的录音录像

consent form (signature)/ audio-video recording oral consent

典藏机构的同意书样本

example consent form from an archiving agency

- 资料索取条件 *condition for data access*
 - 可能的发布形式 *possible method of data dissemination*
 - 学术／教学用途 *academic/ educational use*
- 等等 *etc.*

隐私 / 版权 *Privacy/Copyright*

语料库往后会公开 / 出版 *corpus will become publically accessible/
published*

- 准许你录音 / 录影 ≠ 准许你公开 / 出版 *permission for audio/video recording ≠ permission for publication*
- 内容的控制权在话语社团的手里 *content of corpus is controlled by the speech community*
- 会不会侵犯到别人的隐私 / 令人受损 *will it breach people's privacy/
cause damage*
- 出版物的版权 *copyright of publications*
 - 批准使用要有明确的证明 *clear evidence of permission of usage*

资料及原数据的处理 - 档案格式
Treatment of Data and metadata - file format

典藏格式, 显示格式, 工作格式

archival format, presentation format, working format

典藏格式 *archival format*:

- 非专有 *non-proprietary*
 - 公共领域 *public domain*
 - 没有版权/专利问题 *no copyright/patent problem*
 - 兼容度高 *high compatibility*
 - 将来转成别的格式容易 *easy to export to other formats in the future*
- 可携, 可再用, 多用途 *portable, reusable, repurposeable*
- 原本/品质最好的副本 *original, or best possible reproduction*

资料及原数据的处理 - 档案格式
Treatment of Data and metadata - file format

典藏格式, 显示格式, 工作格式
archival format, presentation format, working format

	文字档 <i>text files</i>	录音 <i>audio recordings</i>	图片 <i>images</i>	录影 <i>audio recordings</i>
典藏格式 <i>archival format</i>	<i>XML, PDF/A, plain-text UTF-8</i>	<i>.wav (48Khz/16 bits)</i>		
显示格式 <i>presentation format</i>	<i>pdf, html</i>			
工作格式 <i>working format</i>	文字处理器/ 排版系统的格式 <i>format of word processor/type setting program</i>			<i>mp4</i>

资料及原数据的处理

Treatment of Data and metadata

文字资料及元数据的格式 <i>Representation of data and metadata</i>	<i>XML-based (e.g. IMDI)</i> <i>plain-text (e.g. toolbox)</i>
影音资料的处理 <i>Treatment of audiovisual materials</i>	与时同步标注 <i>time-aligned transcription of audiovisual material (e.g. ELAN, Transcriber)</i>
语言材料发放 <i>Distribution of language materials</i>	语言典藏 <i>language archives (e.g. ELAR, PARADISEC)</i> 独立网页 <i>individual websites,</i> 纸 / 光盘 等 <i>paper/DVD etc.</i>
注解工具 <i>Annotation tools</i>	<i>(Corpus linguistics has semi-automated annotation tools for tagging, lemmatisation etc. Generally not available for language documentation.)</i>

档案的命名，与原数据
Naming of files, and metadata

格式要 **一致!!!**

format must be **CONSISTENT!!!**

最好按照一个典藏组织的规定，

It is best to follow the requirements of an archival organisation

e.g. ELAR 的档案命名格式:

www.soas.ac.uk/elar/preparing-materials/file-names-and-folders/

uruan001.mp4

uruan001.wav

uruan001.eaf

uruan002.wav

uruan003-1.jpg

uruan003-2.jpg

uruan003-3.jpg

原数据 *Metadata*

最好按照一个典藏组织的规定,
It is best to follow the requirements of an archival organisation
e.g. ELAR 用 CMDI maker 或者 Arbil

最少有: *At least:*

- 录音/录影人 *creator*
- 录音/录影对象 *participants*
- 语言名称 *name of language*
 - 尽量具体! *As specific as possible!*
 - ❌ 汉语 *Chinese*
 - ✅ (汉语)普通话 *Standard Mandarin*
 - ✅ 南宁普通话 *Nanning Mandarin*
 - ✅ 河口粤语 *Hekou Yue/ Hekou Cantonese*
- 年月日时, 地点 *date/time, place*
- 资料索取条件 *condition for data access*
 - e.g. 要有密码 *password protected*
- 资料种类 *genre*
 - e.g. 叙述 *narrative*, 词表 *word list*

文献
Bibliography

- Cox, Christopher. Corpus linguistics and language documentation: challenges for collaboration. In Newman, John & Baayen, R. Harald & Rice, Sally (eds.). *Corpus-based studies in language use, language learning, and language documentation*, 239–264. Amsterdam: Rodopi.
- Himmelman, Nikolaus P. 1998. Documentary and descriptive linguistics. *Linguistics* 36(1): 161–195.
- Johnson, Heidi. 2004. Language documentation and archiving, or how to build a better corpus. *Language documentation and description* 2: 140–153.

备份!!! 备份!!! 备份!!!

back up!!!