

Research Report on Automatic Word Segmentation and Tagged Corpus part

Planned Completion Date : 12/31/09

Title: Research Automatic Word Segmentation

Researchers: Ngodrup NyimaTrashi TashiJia Suonamjiancuo GuanBai
PuDanzen

Presentation: National Standard, Papers and Documentations

Abstraction: Tibetan segmentation is the continual syllable sequence according to certain standard again group compound word sequence process. Automatic word segmentation is a basic subject in Tibetan Information Processing, also is the key subject in intelligent Tibetan information processing area. For resolve the Tibetan segmentation of the “word processing level” in Tibetan information processing, one of the precondition is the standards word classes and correct segmentation. In order to identify the automatic word segmentation and part-of-speech tags, firstly classify the Tibetan words according to requirements of Tibetan information processing and Secondly in accordance with Tibetan characteristics and its own formation rules and thirdly in accordance with Chinese segmentation, provide systemic and applied word segmentation criterions.

Based on processes the Tibetan real text in the computer, in this standard rules, must cover in the linguistics significance the word, but must cover the unit which is smaller than the word, like meets the ingredient (prefix), to meet the ingredient (decorates), meets the ingredient (suffix) and so on, as well as compared to a word bigger unit, like idiom, custom terminology, abbreviation, abbreviation as well as punctuation mark, non-Tibetan mark and so on. Only then like this, this standard can supply the information which Tibetan information processing needs, therefore this standard's part of speech mark collection and the above these is bigger than or information and so on unit which including Tibetan part of speech information the word as well as punctuation mark, non-Tibetan mark is smaller than the word. The current text corpora database contains about 1,000,000 words.

Status of Activity: Published research paper where providing word segmentation criterions.

The Contents for project:

- (1) Modern Tibetan words and expressions classification system
- (2) Part-of-speech tagging
- (3) Tibetan word segmentation vocabulary standard formulation
- (4) Tibetan word segmentation theory
- (5) Tibetan word segmentation algorithm
- (6) The parts-of-speech and tagging set standards of Tibetan Information Process (GB, National standards is applying)
- (7) Research on Tibetan Segmentation Criterion for Information Processing (GB,

National standards is applying)

Status of Activity: finished

Software: GangJian (Snow eyes) Tibetan word segmentation software is made in TU

Result:

ICS35.040
L71



中华人民共和国国家标准

GB ××××—××××

信息处理用藏语词类标记集规范

The parts-of-speech and tagging set standards of Tibetan Information Processing

(申报稿)

××××-××-××发布

××××-××-××实施

1. Main words classes and Code

虚实	体谓	大类	基本类	藏语名称	代码	序号
实词	体词	名词类 (N)	名词	ཚོས་ཚོད་ཀྱི་མིང་།	n	1
			处所词	གནས་ཡུལ་གྱི་མིང་།	l	2
			方位词	ཕྱོགས་ལྗོན་གྱི་མིང་།	f	3
			时间词	དུས་ཀྱི་མིང་།	t	4
			动名词	བྱ་འདུས་ཀྱི་མིང་།	nv	5
			形名词	གཞི་རྒྱན་གྱི་མིང་།	na	6
			辞藻	མདོན་བཟོ་ཀྱི་མིང་།	nm	7
			专职词	བདག་སྒྲ།	nh	8
		数词类 (M)	数词	གྲངས་ཀྱི་མིང་།	m	9
		量词类 (Q)	量词	འཇལ་བྱེད་ཀྱི་མིང་།	q	10
		代词类 (R)	代词	ངེས་བརྒྱུད་གི་མིང་།	r	11
	副词类 (D)		副词	མི་ཟད་པའི་མིང་།	d	12
	谓词	动词类 (V)	自动词	བྱེད་མེད་ཀྱི་མིང་།	vt	13
			他动词	བྱེད་འབྲེལ་གྱི་མིང་།	vi	14
			助动词	རྩེས་མཐུན་བྱ་མིང་།	vu	15
			存在动词	བཞེན་གནས་ཀྱི་མིང་།	ve	16
			判断词	རྣམ་གཞི་ཀྱི་མིང་།	vs	17
		形容词类 (A)	形容词	རྒྱན་མིང་།	a	18
		状态词	ངང་ཚུལ་གྱི་མིང་།	s	19	

		区别词	ལྷན་མིང་།	b	20
虚词	助词类 (U)	时态助词	དུས་གསལ་མིང་།	ut	21
		语气助词	བནན་གསལ་གྱི་མིང་།	un	22
		祈使助词	སྐུལ་སྒྲོན་མིང་།	ap	23
		比喻助词	མཚོངས་གསལ་གྱི་མིང་།	ui	24
		原因助词	རྐྱེན་གསལ་མིང་།	uc	25
		目的助词	དམིགས་གསལ་མིང་།	ue	26
		终结助词	ཚོགས་ཚེག	uf	27
	格助词类 (P)	格助词	ནམ་དཔྱེད་རྒྱུན།	p	28
	连词类 (C)	连词	ཚོག་ཐང།	c	29
	叹词类 (E)		叹词	འཕོད་ཟླ།	e
拟声词类 (O)		拟声词	རྗེས་ལུ་བྱེད་བའི་ཟླ།	o	31
附加类	大于词 的单位	成语	དཔེ་ཚེས།	i	32
		习惯语	རྒྱན་འཇགས་མིང་།	y	33
		简略语	བརྒྱུས་གཟུགས།	j	34
	小于词 的单位	前接成份	ཕྱ་རྒྱུན།	h	35
		中接成份	བར་གྱི་གསལ་བྱེད།	zh	36
		后接成份	མིང་མཐའ།	k	37

ICS35.040
L71



中华人民共和国国家标准

GB xxxx—xxxx

信息处理用藏语词类标记集规范

The parts-of-speech and tagging set standards of Tibetan Information Processing

(申报稿)

xxxx-xx-xx发布

xxxx-xx-xx实施

Standard general rule:

This standard take Tibetan information processing as a goal, according to Tibetan glossary construction word rule and characteristic, provide Tibetan segmentation principle. In this standard Tibetan syllable symbol “.” does not make the segmentation unit's mark, but “/” takes the segmentation unit's mark.

6.1 四个音节构成的结合紧密、使用稳定的固定词组，一律为切分单位。例如：

རང་ལྟོབས་རང་བྱེལ་ དབྱར་དགུན་ལྗོན་དཔྱིད་/ ལྷི་ཚོགས་རིང་ལུགས་/ དྲང་པོ་དྲང་བཞག་ མི་དྲན་དུལ་དྲན་/

6.2 能产的四字格一律为切分单位。例如：

རྒྱ་མེན་ལེར་མེན་/ དེས་མཛོན་དེས་མེབ་/ དེས་མོག་དེས་གསལ་/ དུས་བདེ་གནས་བདེ་/

6.3 四字成语一律为切分单位。例如：

བྱེན་ང་རྒྱང་བཟུས་/ རྒྱེབ་ལྷག་འཕྲེར་མཛོང་/ ངན་བ་སྤྲུག་འཕྲེན་/ ལྷ་ལྷ་གར་ལྷིད་/

6.4 习惯语 <རྒྱན་འཇགས་མིང་།>一律为切分单位。例如：

ཅི་བསམ་སྤྱན་འཇུབ་/ བཟུ་ཤེས་བདེ་ལོགས་/ ལུན་སྤམ་ཚོགས་བ་/

6.5 简略语 <བཟུས་གསུགས་>一律为切分单位。例如：

བྲེ་ལོག་ལྷང་ལོག་/ མི་ཙ་འགོ་ལེན་/ ལྷ་བྱི་ཚང་འཛོམས་ཤེར་བྱེན་/ དམངས་ཚེན་/ རྒྱེད་ལོས་ ཚོན་ཅལ་/

6.6 在藏语中出现的非藏文字符，如其他语言的符号串、数理化符号、阿拉伯数字等仍保留原形。例如：

=/ cm/ 12/ 3.13/ 10%/ H₂O/

6.7 藏语中的音译外来词不予切分。例如：

བུན་/ ཅུས་ ཁོ་རྩེ་ ཤུལ་ལུ་ལེ་/

6.8 谓词后缀“བར་བྱ།བར་བྱེད་”应予切分。例如：

གཅད་པར་བྱ། གཅོད་པར་བྱེད་/

6.9 粘着性“ས།ས།འ།འ།འ།འ།”应予切分，若粘着性“ས།འ།འ།”时用还原的方法来保留词的原形。例如：

ང་ས།བཤད་ བོ།འང་གོ། ལྷ་མཁའ་འི་སྤྱིན་ ལྷ་མཁའ་ར་སྤྱིན་ཡོད་ དག།འ།时先切分粘着词然后其

