汉语构词法概要

詹卫东
北京大学中文系
zwd@pku.edu.cn
http://ccl.pku.edu.cn/doubtfire

词的构成单位：语素

- **词是由语素构成的。语素是语言中最小的音义结合体。** morpheme

- **语素可从三个角度分类：**

1）语素在词中的地位

词根：表示基本词汇意义的语素

词缀：表示附加意义的语素

词尾：表示同一个词的变化形式，构形词缀

老师	挑战者	歌手	同学们
孩子	鞋子	杯子	椅子
玩儿	朵儿	份儿	桃儿

2）语素的独立程度

自由语素：可以独立

粘着语素：依赖其他成分

3）语素的位置

定位语素：在语法结构体中位置固定

不定位语素：在语法结构体中位置不固定，可前，可后

语素和词的关系

- 语素是语言的备用单位 vs. 词是语言的使用单位
- 语素是构词单位

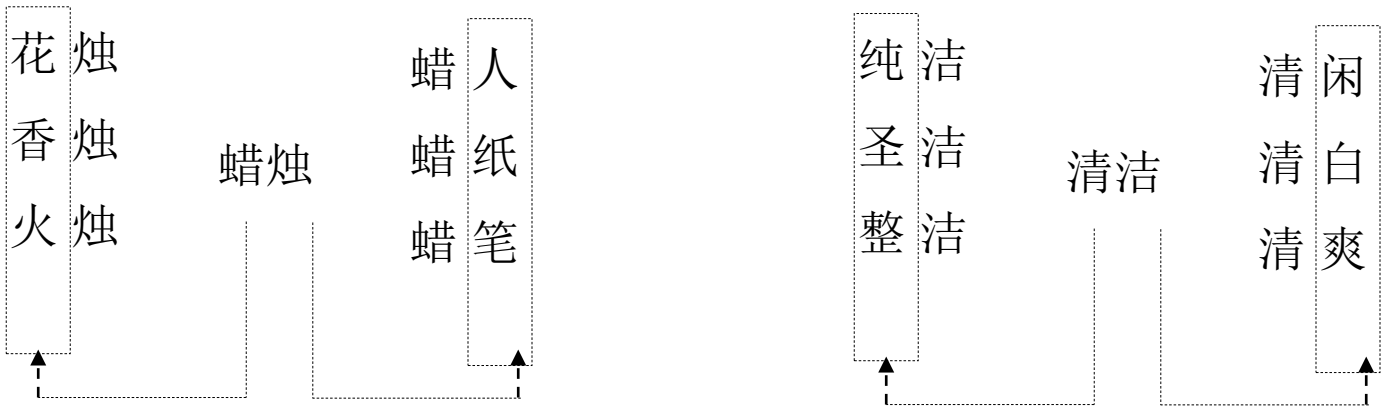

用替换法来鉴定语素

用替换法鉴定语素

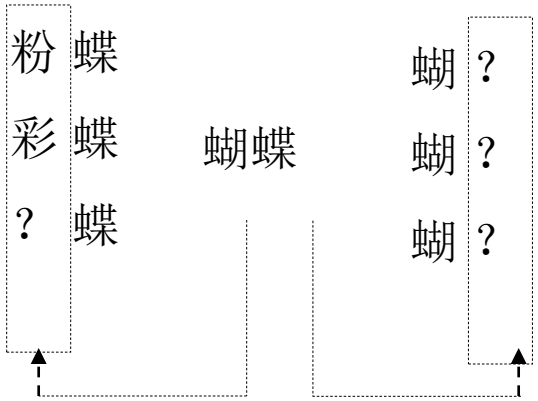

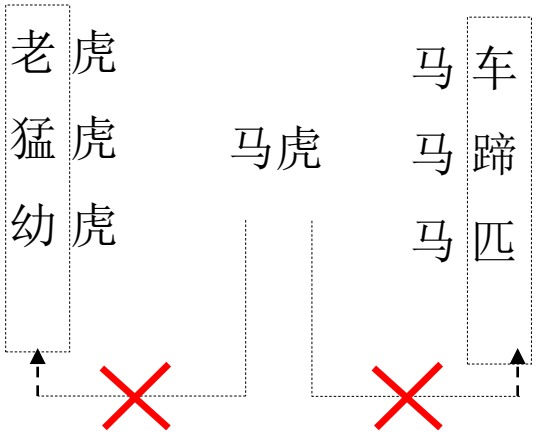

马虎 ＝ 马糊

一个语言单位x能被替换，表示x具有一定的活动能力，可以“备用”

音节和语素

- 单音节语素 vs. 多音节语素
  人 民 风 险 严 峻
  徘徊 雷达 （radar） 盘尼西林 （penicillin）

- **英格兰（England）→ 英国 → 英**
- **巴**士（**bus**） → 大**巴** 中**巴** 小**巴**
  的士（**taxi**） → 面**的** 摩**的** 马**的** 打**的** **的**哥 **的**姐
- 蝴**蝶** → 蝶**泳**
  蚂**蚁** → 工**蚁** **蚁**兵 **蚁**后 **蚁**巢
  骆**驼** → **驼**毛 **驼**峰

有些纯粹的“音节”，由于活动能力增强，可“升格”成为“语素”。

语素、词、词组

- 不成词语素 ＋ 不成词语素 → 词
  民众　思索　历史　观赏

- 不成词语素 ＋ 成词语素 → 词
  民兵　观看　朗读　高耸　瞎子　人格

- 成词语素 ＋ 成词语素 → 词 / 词组
  马路　建设　迟到　大人
  大雨　吃饭　吃饱　站稳

词组可扩展，内部成分易替换

- 实义语素 vs. 偏义语素
  窗户　人物　忘记　国家

词义和语素义的关系

词的构造类型

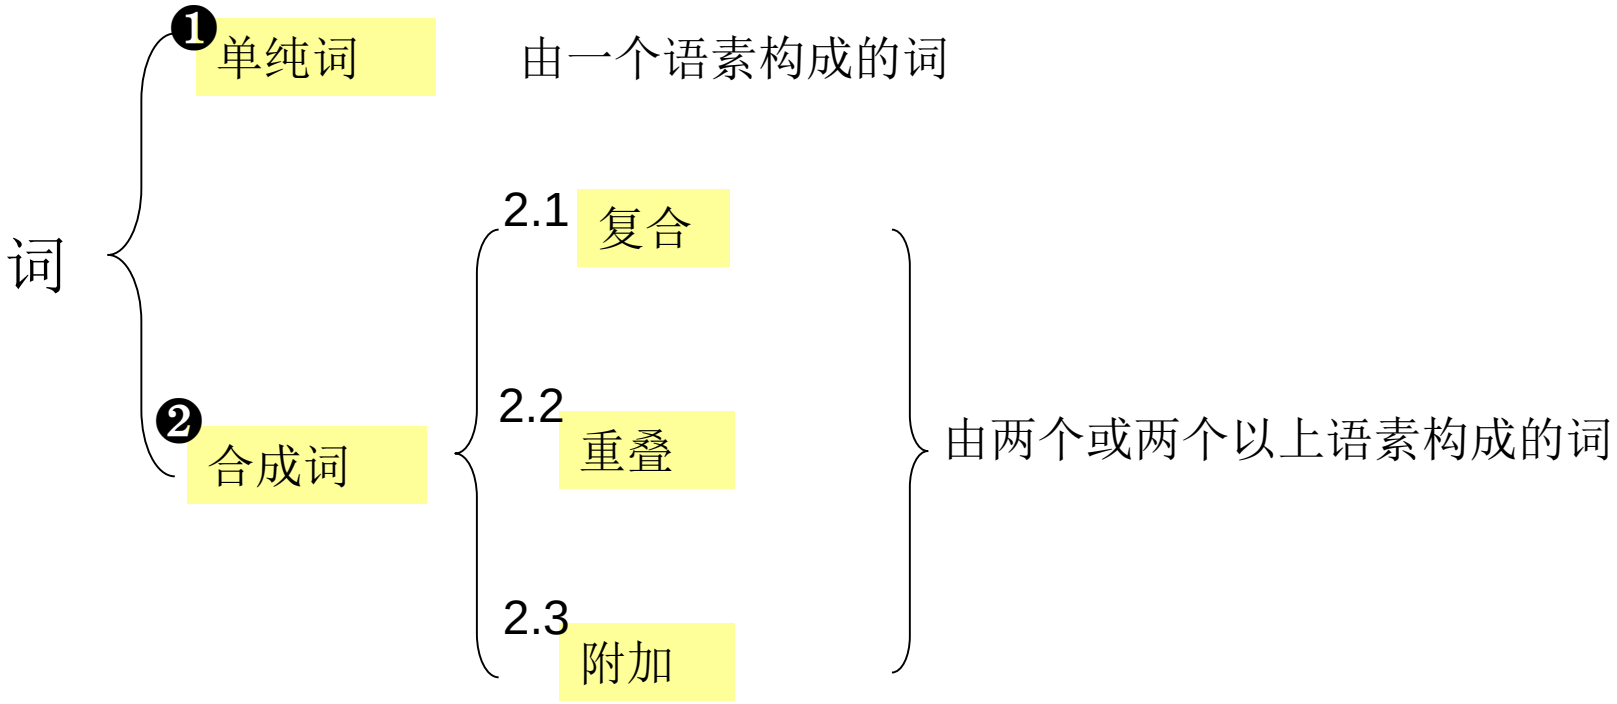

单纯词

- 单纯词
  - 单音节：山 水 鱼 高 很 二 次 这 着 吗 的
  - 多音节
    - 联绵词
      - 双声词：琉璃 淋漓 吩咐 秋千 恍惚
      - 叠韵词：玫瑰 从容 腼腆 唠叨 徘徊
      - 非双声叠韵词：蝙蝠 妯娌 狼狈 犹豫 垃圾
    - 译音词：沙发 拷贝 摩托 巧克力 乌托邦 哈达 菩萨 和尚
    - 叠音词：猩猩 太太 姥姥 皑皑 悄悄
    - 拟音词：扑通 哗啦 轰隆 劈拍 呜呼 哎呀

合成词

- 复合（词根＋词根）
  - 并列式
  - 连动式
  - 偏正式
  - 补充式
  - 支配式
  - 陈述式
- 重叠（词根＋词根）
  - AA式
  - AABB式
- 附加（派生）（词根＋词缀）
  - 真词缀 附加
    - 词根＋后缀
  - 类词缀 附加
    - 前缀＋词根

并列式复合词

	名 + 名	动 + 动	形 + 形
同义	声音 仓库 头绪 根本	制造 休息 计算 喜欢	孤独 完全 奇怪 干净
反义	天地 矛盾 彼此 师生	裁缝 教学 开关 来往	高低 早晚 轻重 缓急
类义	江山 眉目 国家 窗户	飞跃 整理 忘记 考试	聪明 广大 细软 小巧

连动式复合词

V1＋V2：先后续接

查封　抽调　割让　借用　认领　领养　扮演　退休
撤换　叫卖

例：　查封报馆：

查**报馆** + 封**报馆**

V1＋V2：中间嫁接

逼供　请教　促进　逗笑　逗乐　遣返　引见　召见
召集　劝退　劝降　迫降

例：对他进行逼供：

逼 **他**（招）供

偏正式复合词

前偏后正

正 偏	名	动	形
名	草帽　货车 手表　电灯	席卷　瓦解 龟缩　意译	火红　雪白 肤浅　漆黑
形	黑板　新房 红旗　平台	重视　轻信 热爱　小看	鲜红　浅黄 狂热　嫩绿
动	试卷　考场 住宅　摇篮	跳投　飞扑	飞快　透明 滚圆　喷香

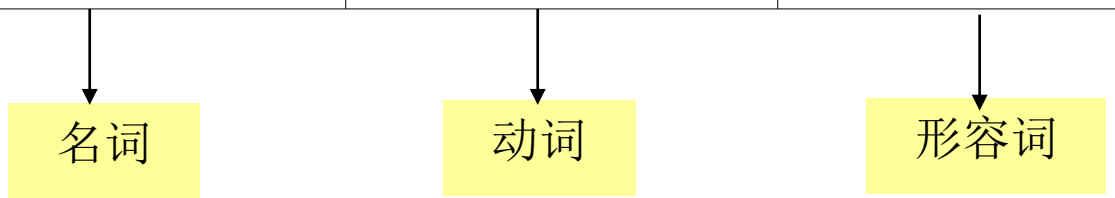

偏正式复合词：名＋动

- **比况**：像N一样地V
  鱼跃　蝉联　蚕食　虎视　鸟瞰　鼠窜　粉碎
  鼎立　蜂拥　狐疑　云集

- **凭借**：以/用N来V
  笔谈　笔试　面试　口试　言传　身教　目送
  目击　力争　力荐　法治

- **处所**：在/向/从N处V
  中立　空袭　左倾　右倾　上传　下载

- **时间**：在N时V
  春耕　秋收　晨练　午休　午睡　夜游

陈述式复合词

后 / 前	动	形
名	海啸　事变　眼花 地震　耳鸣　口吃	性急　手软　肉麻 心虚　心疼　胆怯

不同于“名＋动”偏正式复合词，V说明N的性状变化

偏正式复合词：物产　口罩　木刻　球拍

NV → VN

支配式复合词

后 / 前	名	形	动
动	关心　开心 惊人　吓人 开幕　闭幕 司机　司仪	举重　入迷 失明　讲和	怀疑　抱怨 催眠　效劳

补充式复合词

后 / 前	形	动
动	改善 纠正 证明 冻僵 降低 说明	看见 打倒 撤回 展开 推翻 放开

后 / 前	量	名
名	船只 车辆 枪支 书本 房间 花朵	雪花 脑海 耳朵？

前主
后次

真词缀 附加

前缀 ＋ 词根	老师 老虎 老鼠 老百姓 阿姨 阿婆 阿爸 阿哥 阿妹 小丑 小偷 小姐 小青年
词根 ＋ 后缀	桌子 椅子 骗子 矮子 凳子 刀儿 皮儿 画儿 零碎儿 破烂儿 圆乎乎 胖乎乎 傻乎乎 粘乎乎

类词缀 附加

类前缀 ＋ 词根	半自动 半元音 半封建 超音速 超音质 超短波 非金属 非晶体 非卖品
词根 ＋ 类后缀	学员 教员 会员 指挥员 电工 技工 木工 瓦工 临时工 绿化 美化 僵化 恶化 扩大化 自由主义 虚无主义 社会主义

重叠词

AA

爸爸　哥哥　姐姐　妈妈　舅舅　叔叔　娃娃　爷爷

星星

偏偏　常常　刚刚　仅仅　单单　万万　稍稍

好好　久久　远远　慢慢

AABB

骂骂咧咧　婆婆妈妈　形形色色　风风火火

兢兢业业　密密麻麻　鬼鬼祟祟　堂堂正正

主要构词模式小结

大类	中类	小类	示例
单纯词		1. 单音节单纯词	山 水 鱼
	连绵词	2. 双声连绵词	琉璃 淋漓
		3. 叠韵连绵词	玫瑰 从容
		4. 其他连绵词	蝙蝠 妯娌
		5. 译音词	沙发 拷贝
		6. 叠音词	猩猩 太太
		7. 拟音词	扑通 哗啦
合成词	复合	8. 并列式复合词	声音 仓库
		9. 偏正式复合词	草帽 货车
		10. 支配式复合词	关心 留意
		11. 连动式复合词	查封 抽调
		12. 补充式复合词	改善 纠正
		13. 陈述式复合词	性急 手软
	重叠	14. AA 式重叠词	偏偏 常常
		15. AABB 式重叠词	骂骂咧咧
	附加	16. 后缀附加	桌子 椅子
		17. 前缀附加	老虎 老鼠

仿词

一个**阔人**说要读经，嗡的一阵一群**狭人**也说要读经。岂但‘读’而已矣哉，据说还可以‘救国’哩。

（鲁迅 《这个与那个》）

正如“**水感**”特好的人有可能成为世界级游泳运动员一样，让有“**球感**”的人去打球踢球，有“**生意感**”的人去担任厂长经理，有“**新闻感**”的人去当记者，“**群众感**”特强的人当干部，这于本人于国家于事业都大有好处。

（《文汇报》）

词的缩略形式

AB → A　　美国→ 美　　澳门→澳　　眼睛→眼

AB → B　　香港→港　　历史→史　　学校→校

ABCD→AC　　北京大学→北大　　初级中学→初中

ABCD→AD　　高等学校→高校　　归国华侨→归侨

ABCD→BC　　香港大学→港大　　人民警察→民警

ABCD→BD　　香港小姐→港姐

紧缩

政治协商会议 → 政协　　人民代表大会 → 人大

香港出产的影片 → 港产片　　人工影响天气办公室 → 人影办

ABCD→AB　　清华大学→清华

ABCD→CD　　人民公社→公社

减缩

词的缩略形式

出入境　技战术　中西医　军烈属　离退休

高中低档　老少边穷地区　中小学

大到暴雨　小到中雪

合缩

三好　三峡　三通　三包

七情六欲　七窍　五脏六腑　五讲四美

缩略的基本原则：

（1）保留区别性特征成分　美国-> 美　美国-/-> 国

（2）避免缩略后成分造成混淆　澳门-/-> 门　香港-/-> 香

词的变形

- 喜 不 喜欢　相 不 相信　认 不 认识　小 不 小便
- 学习 不 学　考试 不 考　游泳 不 游

- 连 头 都 不 抬 一 下　连 澡 都 不 洗　连 个 屁 都 不 敢 放 一 个
- 帮 什么 忙　什么 忙 都 帮 不 上
- 帮 了 几次 忙　帮 不 帮 得 上 忙
- 帮 了 大 忙
- 他 帮 了 我 的 大 忙
- 拜托 你 帮 帮 忙

- 大人：你这衣服袖口怎么这么脏啊?
  孩子：幼儿园升国旗啊
  大人：升国旗把你衣服升脏了?

傻里傻气　糊里糊涂　古里古怪　慌里慌张

王海峰，2011，《现代汉语离合词离析形式功能研究》，北京：北京大学出版社。

网络新词语

- 酱紫（这样子），造（知道），表（不要）　合音
- 尼玛、有木有、肿么、童鞋、妹纸、内牛满面、灰常、杯具、洗具、餐具　谐音
- 分特、粉丝　译音
- 哥屋恩（滚）　拼音
- 高富帅，累觉不爱，人艰不拆　白骨精　无知少女　缩略
- 减肥控、微博控、香水控　X控
- 刷屏、高级黑
- 二逼、屌丝
- 顶、汗、囧
- ……

网络新词语（续）：注音心声体/虚伪体

例1： 这种有（qí）趣（guài）的「注音心声体」最初是怎么来的？ （知乎 问答）

例2： A：我做的菜好吃吗？
B：嗯，厨（tai）艺（nan）不（chi）错（le）。

例3： 迎奥运，树（tree）新（new） 风（bee）

例4： A: Do I act like the Big Knowledge Woman?
B: No.
A: Is that "no" spelled y-e-s?
B: S-o-r-t of.

http://www.zhihu.com/question/22061464?rf=22114531

词的内部层次

语素 → 语素组 → 词

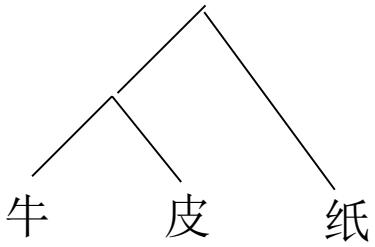

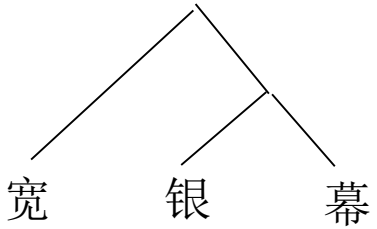

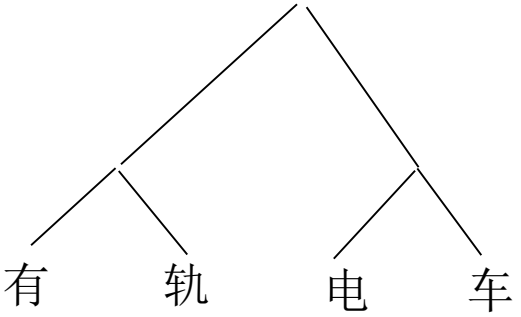

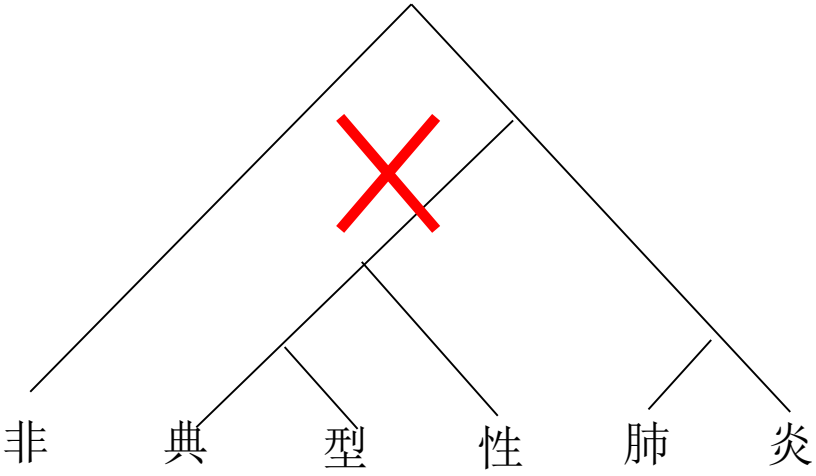

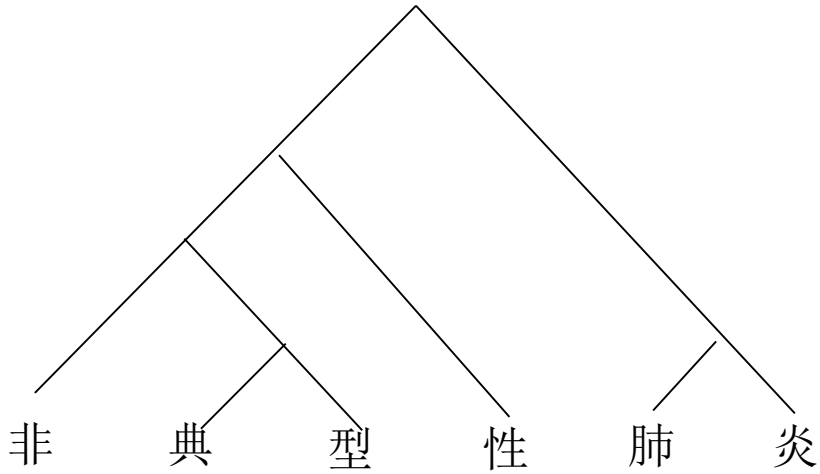

附：构词法知识的应用

- 郑家恒、李文花，2002，基于构词法的网络新词自动识别初探，《山西大学学报》2002年第2期，115-119页。
- 徐艳华，2011，面向自动分词的三音节新词语构词法研究，孙茂松、陈群秀主编《中国计算语言学研究前沿进展（2009-2011）》（第十一届全国计算语言学学术会议CCL-2011会议论文集），清华大学出版社2011年版，58-63页。
- 邹刚、刘洋、刘群、孟遥、于浩、西野文人、亢世勇，2004，面向Internet的中文新词语检测，《中文信息学报》2004年第6期，1-9页。
- Jian-Yun Nie, Marie-Louise Hannan, Wanying Jin, 1995, Unknown Word Detection and Segmentation of Chinese using Statistical and heuristic Knowledge, Communication of COLIPS 1995; 5(1–2): pp. 47-57.
- Tao Liu, Bing-Quan Liu, Xiao-Long Wang, Ming-Hui Li, 2007, The Effectiveness Study of Local Maximum Feature for Chinese Unknown Word Identification, Journal of Chinese Language and Computing 17 (1): 15-26.

❶ 自动发现文本中的新词，辅助编纂新词语词典

❷ 自动分词系统中识别未登录词

附：基于构词法的一些新词过滤规则示例

郑家恒、李文花（2002）

常规构词规则

if wordtype (A B) = ’N ’and wordtype (C) = ’N ’then new (A B C) = ’N’

如果汉字串ABC的构成形式为A B + C 型，且满足A B 、C 分别为名词，则将A B C做标记，认为是新词。

特殊构词规则

if firstwordtype (A) = ’N ’ and secondword (B) = ’吧’ then new (A B) = ’N’

若二元组中的第二个字是“吧”，且第一个单字词为名词，则认为该二元组为新词。

“互斥性字串”过滤规则

if wordtype (A) = ’P ’and wordtype (B) < > ’N ’ then delword

若A 为介词，B 为非名词类，则将字串“A B”去除。

附：基于构词法的一些新词过滤规则示例

邹刚 等（2004）

1. [a-z]*d ： 所有以副词结尾的词性序列；
2. u[a-z]* ： 所有以助词开头的词性序列；
3. [a-z]*u ： 所有以助词结尾的词性序列；
4. [a-z]*c[a-z]* ： 所有包含连词的词性序列。
5. q[a-z]* ： 所有以量词起始的词性序列。
6. [m]+ ： 单纯的数字；
7. [t]+ ： 所有的日期；

例： “岁/qt 就读/vi 于/p”

附：汉语语义构词模式标注统计表

序号	构词结构	二字词	多字词	总计	比率	例词
1	定中	19581	6796	26377	40.41%	红旗
2	联合	11414	2138	13552	20.76%	丰满
3	述宾	8141	1141	9282	14.22%	选材
4	状中	4215	601	4816	7.38%	热爱
5	后附加	2308	424	2732	4.19%	杯子
6	单纯词	2078	266	2344	3.59%	克隆
7	连谓	1709	403	2112	3.24%	进攻
8	主谓	524	917	1441	2.21%	年轻
9	述补	630	398	1028	1.57%	提高
10	前附加	698	21	719	1.10%	老虎
11	重叠	310	2	312	0.48%	哥哥
12	方位	189	29	218	0.33%	野外
13	介宾	157	7	164	0.25%	从小
14	名量	78	5	83	0.13%	纸张
15	数量	56	15	71	0.11%	一些
16	复量	20	3	23	0.04%	场次
	合计	52108	13166	65274	100.00%	

北京大学计算语言学研究所《中文概念词典》语义构词模式标注，2016，康思辰、田元贺、刘扬等