



## 第2章：文本规范化

课件制作：王新宇、楼超、屠可伟  
讲解人：王新宇

# 文本规范化

---

- 每个 NLP 任务都需要文本规范化：
  - 分词
  - 词规范化
  - 分句



分词

ElitesAI

## 基于空格和标点符号的分词

---

- 一种非常简单的分词方法
  - 对于在单词之间使用空格字符的语言
    - 阿拉伯语、西里尔语、希腊语、拉丁语等书写系统
  - 在空格（和标点符号）实例之间分割分词

- 例子

- 句子:

*I learn natural language processing with dongshouxueNLP, too.*

- *I \_learn \_natural \_language \_processing \_with \_dongshouxueNLP \_ , \_too \_.*

- “\_”：分隔符

## 分词问题

---

不能盲目删除标点符号：

- Ph. D. , A. M. , P. M. ;
- 价格 ( \$45.55 )
  - 日期 ( 01/02/06 )
  - 网址 ( <https://www.boyuai.com/>)
  - 标签 ( #nlproc )
  - 电子邮件地址 ( [someone@somewhere.com](mailto:someone@somewhere.com))
- 不能独立存在的词：
  - we ‘re中的“ are ”，法语“j’ ai ”中的“je”
- 多个词有时也是词元
  - New York、rock ‘ n’ roll

## 例句

---

- 句子:

Did you spend \$3.4 on arxiv.org for your pre-print? No, it's free! It's ...

- 预期的分词结果:

Did\_you\_spend\_\$3.4\_on\_arxiv.org\_for\_your\_pre-print\_?\_No\_,\_it's\_free\_!\_It's\_...

- 内部带有连字符的单词: pre-print
- 网页: arxiv.org
- 货币和百分比: \$3.4
- 省略号: ...
- 标点符号: ] [ . , ; ” ’ ? ( ) : - \_ `

# 自然语言工具包中的分词 (NLTK)

- 方法：
  - 编写一个匹配所有可能分词但不匹配任何非分词的模式。
  - 输出所有不重叠的匹配项。
- 工具：正则表达式 (RE)
  - 带有可选内部连字符的单词：
    - RE 中的模式：`\w+ (- \w+ )*`
    - 接受的字符串：
      - `pre-train`、`fine-tune`、`pre-print`、...
    - 被拒绝的字符串：
      - `U.S.A.`、`arxiv.org`、`$3.4`、...
      - `non-`、`-ly`、...

`\w` =任何单词字符  
= `[a-zA-Z0-9_]`  
`+` =匹配 1 次或多次  
`*` =匹配 0 次或多次  
`(...)` 是一个组 (后跟 `+` 或 `*`)

# 自然语言工具包中的分词 (NLTK)

- 缩写:
  - 模式: `([A-Z]\. )+`
  - 接受的字符串: `U.S.A.`
  - 被拒绝的字符串: `UU.SA`、`I`
- 货币和百分比:
  - 模式: `\$?\d+ (\.\d+)? %?`
  - 接受字符串: `$12.40`、`20%`
  - 字符串: `$.4`、`1.4.0`、`1%%`
- 省略:
  - 模式: `\.\.\.`
  - 接受的字符串: `.....`
- 标点符号:
  - 模式: `[ \]\[\.\, ; ' " \? \(\) : -`

`[A-Z]` = 大写字符

`\d` = 数字 = `[0-9]`

在 RE 中, 某些字符 (例如 `^$.?+*()[]`) 具有特殊含义。应该对它们进行转义以匹配它们。

`\.` = “.”

`\$` = “\$”

`+` = 匹配 1 次或多次

`?` = 匹配 0 或 1 次



## 没有空格的语言的分词

---

- 许多语言（如中文、日语、泰语）不使用空格来分隔单词！
- 某些西方语言中的复合名词也是如此
  - 示例：德语：  
`Freundschaftsbezeugungen` （展现友谊）
  - 示例：社交媒体中的标签：  
`#NaturalLanguageProcessing`

# 没有空格的语言的分词

---

- 句子：姚明进入总决赛

- 有很多种分词的方法

- 姚明/进入/总决赛

- 姚/明/进入/总/决赛

- 姚/明/进/入/总/决/赛

} 通常表现为序列标注+监督学习  
(后续的章节讨论)

— 单字符切分

- 歧义性

- 南京市长江大桥

## 子词分词

---

- 分词可以是单词的一部分，也可以是整个单词
  - 使用数据告诉我们如何分词
- 优点
  - 词汇量小得多
  - 避免词汇外 (OOV) 单词
  - 子词有时是有意义的
    - 前缀、后缀、词干……

# 子词分词

---

- 三种常见算法：
  - 字节对编码 (BPE)
  - Unigram 语言建模分词
  - WordPiece
- 都有两个部分：
  - 词元**学习器**采用原始训练语料库并归纳词汇表（一组**词元**）。
  - 一个**分词器**，它采用原始测试句子并根据该词汇对其进行分词

## 字节对编码 (BPE) 词元学习器

---

- 令词汇表为所有单个字符的集合  
= {A, B, C, D, ..., a, b, c, d...}
- 重复:
  - 选择训练语料库中最常相邻的两个符号（例如“A”、“B”）
  - 将新的合并符号“AB”添加到词汇表中
  - 语料库中每个相邻的“A”“B”替换为“AB”。
- 直到 $k$ 次合并已经完成。

# BPE 词元学习器

- 原始语料库:

nan nan nan nan nan nanjing nanjing beijing beijing beijing  
beijing beijing beijing dongbei dongbei dongbei bei bei

- 通常在空格分隔的词元内运行BPE次元学习。
- 首先添加词尾词元“\_”
  - 这样我们可以区分**beijing**和**dongbei**中的**bei**
  - 结果:

语料:

```
5 ['n', 'a', 'n', '_']
```

```
2 ['n', 'a', 'n', 'j', 'i', 'n', 'g', '_']
```

```
6 ['b', 'e', 'i', 'j', 'i', 'n', 'g', '_']
```

```
3 ['d', 'o', 'n', 'g', 'b', 'e', 'i', '_']
```

```
2 ['b', 'e', 'i', '_']
```

```
词表: ['_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o']
```

# BPE 词元分词器

语料:

```
5 ['n', 'a', 'n', '_']
```

```
2 ['n', 'a', 'n', 'j', 'i', 'n', 'g', '_']
```

```
6 ['b', 'e', 'i', 'j', 'i', 'n', 'g', '_']
```

```
3 ['d', 'o', 'n', 'g', 'b', 'e', 'i', '_']
```

```
2 ['b', 'e', 'i', '_']
```

词表: ['\_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o']

## ▶ 合并n g到ng

迭代后的语料为:

```
5 ['n', 'a', 'n', '_']
```

```
2 ['n', 'a', 'n', 'j', 'i', 'ng', '_']
```

```
6 ['b', 'e', 'i', 'j', 'i', 'ng', '_']
```

```
3 ['d', 'o', 'ng', 'b', 'e', 'i', '_']
```

```
2 ['b', 'e', 'i', '_']
```

词表: ['\_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o', 'ng']

# BPE 分词学习器

---

迭代后的语料为:

```
5 ['n', 'a', 'n', '_']
2 ['n', 'a', 'n', 'j', 'i', 'ng', '_']
6 ['b', 'e', 'i', 'j', 'i', 'ng', '_']
3 ['d', 'o', 'ng', 'b', 'e', 'i', '_']
2 ['b', 'e', 'i', '_']
```

词表: ['\_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o', 'ng']

## ▶ 合并b e到be

迭代后的语料为:

```
5 ['n', 'a', 'n', '_']
2 ['n', 'a', 'n', 'j', 'i', 'ng', '_']
6 ['be', 'i', 'j', 'i', 'ng', '_']
3 ['d', 'o', 'ng', 'be', 'i', '_']
2 ['be', 'i', '_']
```

词表: ['\_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o', 'ng', 'be']



# BPE 分词学习器

---

迭代后的语料为:

```
5 ['n', 'a', 'n', '_']
2 ['n', 'a', 'n', 'j', 'i', 'ng', '_']
6 ['be', 'i', 'j', 'i', 'ng', '_']
3 ['d', 'o', 'ng', 'be', 'i', '_']
2 ['be', 'i', '_']
```

词表: ['\_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o', 'ng', 'be']

## ▶ 合并 **be i** 到 **bei**

迭代后的语料为:

```
5 ['n', 'a', 'n', '_']
2 ['n', 'a', 'n', 'j', 'i', 'ng', '_']
6 ['bei', 'j', 'i', 'ng', '_']
3 ['d', 'o', 'ng', 'bei', '_']
2 ['bei', '_']
```

词表: ['\_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o', 'ng', 'be', 'bei']

# BPE 分词学习器

---

- 最后我们可以得到:

迭代后的语料为:

```
5 ['nan', '_']
```

```
2 ['nan', 'jing_']
```

```
6 ['beijing_']
```

```
3 ['d', 'o', 'ng', 'bei', '_']
```

```
2 ['bei', '_']
```

```
词表: ['_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o', 'ng', 'be', 'bei',  
      'ji', 'jing', 'jing_', 'na', 'nan', 'beijing_']
```

# BPE 分词器算法

- 所学词汇：  
['\_', 'a', 'b', 'd', 'e', 'g', 'i', 'j', 'n', 'o',  
'ng', 'be', 'bei', 'ji', 'jing', 'jing\_', 'na',  
'nan', 'beijing\_']
- 在测试数据上，运行从训练数据中学到的每个合并：
  - 按照我们学习的顺序贪婪地进行选择
  - （测试数据的频率不影响我们选择的顺序）
- 所以：将每个 n g 合并到 ng ，然后将 b e 合并到 be ， 等等。
- 结果：
  - 测试集 “beijing\_” 将被分词为完整单词
  - 测试集 “nanjing\_” 将是两个分词：“nan jing\_”

## BPE 分词的特性

---

- 通常包括频繁出现的单词和频繁出现的子词
  - 通常是像`-est`或`-er`这样的语素
- 语素是语言中最小的意义单位
  - `unbreakable`有 3 个语素`un-`、`-break-`和`-able`

# 词规范化

ElitesAI

# 词规范化

---

- 将单词/分词放入标准格式
  - U. S. A还是USA
  - Shanghai还是shanghai
  - Am、 is、 are、 be

# 大小写折叠

- 将所有字母转为小写
- 在某些场景下效果很好
  - 信息检索：用户倾向于使用小写字母
  - 例子：



- 对别的场景不好
  - 示例：US、Fed、General Motors

## 词目还原

---

- 将所有单词表示为它们的词目也就是字典词条形式
  - am、are、is → be
  - cat, cats, cat's, cats' → cat
- 例子
  - Two dogs are chasing three cats  
→ Two dog be chase three cat



# 通过语素分析完成词目还原

---

- 语素：
  - 组成单词的有意义的最小单位
  - 词干 (stem)：核心意义承载单位
  - 词缀 (affix)：附着在词干上的部分，通常具有语法功能
- 语素分析器：
  - 将 *cats* 分成两个语素 *cat* 和 *s*

# 词干提取

---

- 提取词干，**粗暴地砍掉词缀**
  - 词目还原的简单粗暴的替代方案
- 波特词干还原器
  - 基于一系列的重写规则
  - 一些示例规则

ATIONAL → ATE (e.g., relational → relate)

ING → ε if stem contains vowel (e.g., motoring → motor)

SSES → SS (e.g., grasses → grass)

分句

ElitesAI

# 分句

---

- !, ?大多是明确的, 但英文中的句号“.”很暧昧
  - 句子边界
  - 英文缩写Inc. 或Dr.
  - 0.02%或4.3
- 常用算法
  - 首先分词
    - 因此, 句点被分类为单词的一部分或句子边界。
  - 通常可以通过基于此分词的规则来完成分句。
    - 例如: 标点符号、大小写



总结

ElitesAI

# 文本规范化

---

- 分词
  - 正则表达式、BPE
- 词规范化
  - 大小写还原、词目还原、词干提取
- 分句