

10. 词嵌入

WU Xiaokun 吴晓堃

xkun.wu [at] gmail

2022/04/22

“喵说喵要喵”

ເສດ්ຈ ໄກມາຖຸລຄາມເສດ්ຈວ່າ ຈະເສດ්ຈຫຣີ້ມໄມ່ເສດ්ຈ ດໍາເສດ්ຈຈະເສດ්ຈ ເສດ්ຈຈະເສດ්ຈດ້ວຍ
—《四朝代》

- 泰语：针对皇室成员的称谓、动作情态和事物需要使用特殊的“皇语”

皇后娘娘遣 (我) 来请示公主殿下, 公主殿下是否去 (大殿听经), 如果公主殿下打算去 (听经), 皇后娘娘也一同去 (听经)。

“喵说喵要喵”

ເສດ්ຈ ໄກມາຖຸລຄາມເສດ්ຈວ່າ ຈະເສດ්ຈຫຣີ້ມໄມ່ເສດ්ຈ ດໍາເສດ්ຈຈະເສດ්ຈ ເສດ්ຈຈະເສດ්ຈດ້ວຍ
—《四朝代》

- 泰语：针对皇室成员的称谓、动作情态和事物需要使用特殊的“皇语”

皇后娘娘遣 (我) 来请示公主殿下, 公主殿下是否去 (大殿听经), 如果公主殿下打算去 (听经), 皇后娘娘也一同去 (听经)。

如果用“喵”字来替代这个词的话.....

喵让我来问喵, 喵要喵吗? 如果喵要喵的话, 喵也喵。
喵说喵要喵。如果喵也喵, 喵会很高兴。

Word2vec

稀疏表示与信息压缩

TF-IDF和PPMI模型：稀疏向量、矩阵存储

- 元素：计数或计数的函数，大部分是0，无有效信息
 - 0值表示不相关，即同时出现的可能性为0

稀疏表示与信息压缩

TF-IDF和PPMI模型：稀疏向量、矩阵存储

- 元素：计数或计数的函数，大部分是0，无有效信息
 - 0值表示不相关，即同时出现的可能性为0
- 长向量：维数是语料集中的词汇数 $|V|$ ，或文档数
 - 《现代汉语常用词表》2015年版：56008个词语

稀疏表示与信息压缩

TF-IDF和PPMI模型：稀疏向量、矩阵存储

- 元素：计数或计数的函数，大部分是0，无有效信息
 - 0值表示不相关，即同时出现的可能性为0
- 长向量：维数是语料集中的词汇数 $|V|$ ，或文档数
 - 《现代汉语常用词表》2015年版：56008个词语

长向量导致超大矩阵：计算复杂度 $O(|V|^2)$ 平方级增长

- 稀疏表示：链表的变种，利用稀疏性

稀疏表示与信息压缩

TF-IDF和PPMI模型：稀疏向量、矩阵存储

- 元素：计数或计数的函数，大部分是0，无有效信息
 - 0值表示不相关，即同时出现的可能性为0
- 长向量：维数是语料集中的词汇数 $|V|$ ，或文档数
 - 《现代汉语常用词表》2015年版：56008个词语

长向量导致超大矩阵：计算复杂度 $O(|V|^2)$ 平方级增长

- 稀疏表示：链表的变种，利用稀疏性
- 将信息压缩成稠密（的向量）表示
 - 称为词嵌入 **embedding**

词嵌入

词嵌入（向量）的元素：实数值

- 信息压缩通常导致信息丢失： $f : x \mapsto v$
 - 类比JPEG2000（小波变换）：切除高频信号，故多次保存后更模糊

词嵌入

词嵌入（向量）的元素：实数值

- 信息压缩通常导致信息丢失： $f : x \mapsto v$
 - 类比JPEG2000（小波变换）：切除高频信号，故多次保存后更模糊
- 缺点：很难对维度做出解释
 - 压缩相当于编码过程：词义随之消除
 - 例如 Morse 密码：4个“H:”可以压缩成“16.”
 - 但这无法从代码表找到解释

词嵌入

词嵌入（向量）的元素：实数值

- 信息压缩通常导致信息丢失： $f : x \mapsto v$
 - 类比JPEG2000（小波变换）：切除高频信号，故多次保存后更模糊
- 缺点：很难对维度做出解释
 - 压缩相当于编码过程：词义随之消除
 - 例如 Morse 密码：4个“H:”可以压缩成“16.”
 - 但这无法从代码表找到解释
- 对比词向量：特征维度有明确（以文档/词度量的）词义

词嵌入的优点

在所有NLP任务中都比稀疏表示的效能好（原因尚在研究）

- 短向量 = 特征少：参数少，易于训练
 - 参数空间小：过拟合问题相对轻，泛化性好

词嵌入的优点

在所有NLP任务中都比稀疏表示的效能好（原因尚在研究）

- 短向量 = 特征少：参数少，易于训练
 - 参数空间小：过拟合问题相对轻，泛化性好
- 低维度量更有效：避免“维数灾难”，更容易发现词义相似的词
 - 例如：稀疏表示中 car 和 automobile 的维数差异大
 - ⇒ 词义完全无关，与经验不符

常用词嵌入方法

静态嵌入：只计算一次词汇的固定嵌入表示

- NLP 启发的模型
 - word2vec (skipgram, CBOW), GloVe

常用词嵌入方法

静态嵌入：只计算一次词汇的固定嵌入表示

- NLP 启发的模型
 - word2vec (skipgram, CBOW), GloVe
- 矩阵分析、计算：如SVD
 - Latent Semantic Analysis (LSA)

常用词嵌入方法

静态嵌入：只计算一次词汇的固定嵌入表示

- NLP 启发的模型
 - word2vec (skipgram, CBOW), GloVe
- 矩阵分析、计算：如SVD
 - Latent Semantic Analysis (LSA)

动态嵌入：上下文不同， 嵌入也不同

- ELMo、BERT

可在线下载的静态嵌入

[Mikolov 2013] word2vec

- <https://code.google.com/archive/p/word2vec/>
- 非常流行，训练速度快

[Pennington 2014] GloVe

- <http://nlp.stanford.edu/projects/glove/>

word2vec：原理

预测，而不是计数

- 训练一个分类器：“食堂”在“下课”的上下文出现的可能性是多少？
- 对比之前：出现的次数是多少？简单假定统计词频为可能性

word2vec：原理

预测，而不是计数

- 训练一个分类器：“食堂”在“下课”的上下文出现的可能性是多少？
- 对比之前：出现的次数是多少？简单假定统计词频为可能性

但是，我们并不关心分类的结果

- 将分类器学到的权重作为词嵌入，即当作编码器

自监督

词嵌入对机器学习的变革性贡献

- 文本的序列关系：天然可以作为训练数据的监督标注
 - 上下文可以看成隐式标签

他下课后去了食堂
他下课后去了□□

自监督

词嵌入对机器学习的变革性贡献

- 文本的序列关系：天然可以作为训练数据的监督标注
 - 上下文可以看成隐式标签

他下课后去了食堂
他下课后去了□□

这在机器学习分类中称为自监督 **self-supervision** 学习

- 避免了人工标定监督关系的步骤
- [Bengio 2003, Collobert 2011] 使用文本序列本身学习词嵌入

word2vec 是简化方案

word2vec 比基于神经网络的语言模型简单得多

- 任务简化：转化成二分类问题
 - 只需预测词出现的可能性，而非预测选择哪个词

word2vec 是简化方案

word2vec 比基于神经网络的语言模型简单得多

- 任务简化：转化成二分类问题
 - 只需预测词出现的可能性，而非预测选择哪个词
- 架构简化：只需逻辑回归分类器，而非复杂神经网络模型

word2vec 是简化方案

word2vec 比基于神经网络的语言模型简单得多

- 任务简化：转化成二分类问题
 - 只需预测词出现的可能性，而非预测选择哪个词
- 架构简化：只需逻辑回归分类器，而非复杂神经网络模型


我们主要讨论word2vec其中的一个版本

- [Mikolov 2013] **skip-gram with negative sampling (SGNS)**
 - skip-gram也称跳元模型

skip-gram：工作流程

为了预测词 c 是目标词 w 的上下文

1. 将词对 (w, c) 看成一个正例
2. 随机采样词 w' , 并将词对 (w', c) 看成一个负例
3. 使用逻辑回归训练一个分类器
4. 将分类器学到的权重用作词嵌入



skip-gram：示例

考虑如下文本：假定使用大小为 ± 2 的上下文窗口

如	[今	人	方	为	刀]	俎
	c_1	c_2	w	c_3	c_4	

skip-gram：示例

考虑如下文本：假定使用大小为 ± 2 的上下文窗口

如	[今	人	方	为	刀]	俎
	c_1	c_2	w	c_3	c_4	

分类任务的构造： $P(+|w, c)$

- 词对：(方, 今), (方, 祀), (方, 鱼)
- $P(-|w, c) = 1 - P(+|w, c)$

skip-gram：原理

基于相似度的概率值

- 嵌入向量的相似度高：词对共同出现的可能性高

skip-gram：原理

基于相似度的概率值

- 嵌入向量的相似度高：词对共同出现的可能性高
- 向量相似：内积数值大
 - 余弦值是规范化内积：取值 $[-1, 1]$

skip-gram：原理

基于相似度的概率值

- 嵌入向量的相似度高：词对共同出现的可能性高
- 向量相似：内积数值大
 - 余弦值是规范化内积：取值 $[-1, 1]$

因此： $P(+|w, c) \propto \mathbf{c} \cdot \mathbf{w}$

skip-gram：原理

基于相似度的概率值

- 嵌入向量的相似度高：词对共同出现的可能性高
- 向量相似：内积数值大
 - 余弦值是规范化内积：取值 $[-1, 1]$

因此： $P(+|w, c) \propto \mathbf{c} \cdot \mathbf{w}$

- 但是，转化成概率值需要归一化
 - 余弦值也不是概率：如何将数值挤压到 $[0, 1]$ ？

skip-gram：概率构造

回忆：S形曲线恰好有将数值挤压到[0, 1]的性质

$$\sigma(x) = \frac{1}{1 + \exp(-x)}$$

skip-gram：概率构造

回忆：S形曲线恰好有将数值挤压到[0, 1]的性质

$$\sigma(x) = \frac{1}{1 + \exp(-x)}$$

挤压相似度数值：

$$P(+|w, c) = \sigma(\mathbf{c} \cdot \mathbf{w}) = \frac{1}{1 + \exp(-\mathbf{c} \cdot \mathbf{w})}$$

$$P(-|w, c) = 1 - P(+|w, c) = \frac{1}{1 + \exp(\mathbf{c} \cdot \mathbf{w})}$$

skip-gram：多个上下文

skip-gram 假设所有上下文词是相互独立的

$$P(+)|w, c_{1:L}) = \prod_i \sigma(\mathbf{c}_i \cdot \mathbf{w})$$

- 这些词的解耦合可以由分词预处理来保证

他下课后去了食堂

skip-gram：多个上下文

skip-gram 假设所有上下文词是相互独立的

$$P(+)|w, c_{1:L}) = \prod_i \sigma(\mathbf{c}_i \cdot \mathbf{w})$$

- 这些词的解耦合可以由分词预处理来保证

他下课后去了食堂

- 取对数：避免多个小数相乘

$$\log P(+)|w, c_{1:L}) = \sum_i \log \sigma(\mathbf{c}_i \cdot \mathbf{w})$$

skip-gram：小结

skip-gram 构造了一个概率二分类器

- 输入：目标词 w , 上下文 $c_{1:L}$

skip-gram：小结

skip-gram 构造了一个概率二分类器

- 输入：目标词 w , 上下文 $c_{1:L}$

w 在上下文窗口的概率：由向量相似度估计

- 基于假设：相关联的词出现在相同上下文
- 计算前提：需要所有词的嵌入向量

skip-gram：小结

skip-gram 构造了一个概率二分类器

- 输入：目标词 w , 上下文 $c_{1:L}$

w 在上下文窗口的概率：由向量相似度估计

- 基于假设：相关联的词出现在相同上下文
- 计算前提：需要所有词的嵌入向量

那么，如何学到这些词嵌入？


词嵌入集合

词嵌入的列表：即分类器的参数集合

- $f : x \mapsto v$

skip-gram 对每个词存储两个词嵌入

- 同一个词、两种表示
 - 分别用作目标、上下文




词嵌入集合

词嵌入的列表：即分类器的参数集合

- $f : x \mapsto v$

skip-gram 对每个词存储两个词嵌入

- 同一个词、两种表示
 - 分别用作目标、上下文



下面讨论如何学到这些词嵌入（训练分类器的真正目的）

Word2vec：学习词嵌入

skip-gram：负例

如	[今	人	方	为	刀]	俎
	c_1	c_2	w	c_3	c_4	

- 对每个正例：根据词频采样 k 个负例

skip-gram：负例

如	[今	人	方	为	刀]	俎
	c_1	c_2	w	c_3	c_4	

- 对每个正例：根据词频采样 k 个负例

正例 +

w	c_{pos}
方	今
方	人
方	为
方	刀

负例 -: $k = 2$

w	c_{neg}	w	c_{neg}
方	鱼	方	俎
方	攻	方	仁
方	饥	方	商
方	美	方	谋

- 这也是名称的来历：**Skip-Gram with Negative Sampling (SGNS)**

skip-gram：学习目标

初始状态：随机嵌入向量

学习过程逐渐达成两个目标，即目标损失函数的依据

- 最大化正例词对的相似度
- 最小化负例词对的相似度

skip-gram：训练模型

损失函数

$$\begin{aligned} L_{CE} &= -\log \left[P(+|w, c_{pos}) \prod_{i=1}^k P(-|w, c_{neg}^i) \right] \\ &= - \left[\log P(+|w, c_{pos}) + \sum_{i=1}^k \log P(-|w, c_{neg}^i) \right] \\ &= - \left[\log P(+|w, c_{pos}) + \sum_{i=1}^k \log(1 - P(+|w, c_{neg}^i)) \right] \\ &= - \left[\log \sigma(c_{pos} \cdot w) + \sum_{i=1}^k \log \sigma(-c_{neg}^i \cdot w) \right] \end{aligned}$$

优化器：随机梯度下降

skip-gram：损失函数求导

$$L_{CE} = - \left[\log \sigma(c_{pos} \cdot w) + \sum_{i=1}^k \log \sigma(-c_{neg} \cdot w) \right]$$

$$\frac{\partial L_{CE}}{\partial c_{pos}} = [\sigma(c_{pos} \cdot w) - 1]w$$

$$\frac{\partial L_{CE}}{\partial c_{neg}} = [\sigma(c_{neg} \cdot w)]w$$

$$\frac{\partial L_{CE}}{\partial w} = [\sigma(c_{pos} \cdot w) - 1]c_{pos} + \sum_{i=1}^k [\sigma(c_{neg}^i \cdot w)]c_{neg}^i$$

最终词嵌入

回顾：skip-gram 对每个词存储两个词嵌入

- 分别是目标词嵌入 w_i 、上下文词嵌入 c_i

最终词嵌入

回顾：skip-gram 对每个词存储两个词嵌入

- 分别是目标词嵌入 \mathbf{w}_i 、上下文词嵌入 \mathbf{c}_i

通常使用两者之和： $\mathbf{w}_i + \mathbf{c}_i$

- 也有算法只使用目标词嵌入 \mathbf{w}_i

实验：Penn Tree Bank (PTB)

实验：skip-gram

word2vec (skip-gram) 训练：小结

1. 随机初始化词嵌入
2. 根据嵌入向量间相似度训练二分类器
 - 将上下文窗口中出现的词对作为正例
 - 对每个正例：根据词频采样 k 个负例
 - 训练过程：最大化正例相似度，最小化负例相似度
 - 抛弃掉分类器代码，只保留词嵌入：类比“微调网络”


其他静态嵌入

连续词袋

[Mikolov 2013] 连续词袋 CBOW模型类似于skip-gram

skip-gram


- 假设中心词生成上下文



- $P(\text{今}, \text{人}, \text{为}, \text{刀} | \text{方}) = P(\text{今} | \text{方})P(\text{人} | \text{方})P(\text{为} | \text{方})P(\text{刀} | \text{方})$

CBOW

- 假设上下文生成中心词




- $P(\text{方} | \text{今}, \text{人}, \text{为}, \text{刀})$

连续词袋

[Mikolov 2013] 连续词袋 CBOW模型类似于skip-gram

skip-gram


- 假设中心词生成上下文



- $P(\text{今}, \text{人}, \text{为}, \text{刀} | \text{方}) = P(\text{今} | \text{方})P(\text{人} | \text{方})P(\text{为} | \text{方})P(\text{刀} | \text{方})$

CBOW

- 假设上下文生成中心词



- $P(\text{方} | \text{今}, \text{人}, \text{为}, \text{刀})$

两者训练流程相同，仅公式计算有区别

全局向量的词嵌入

[Pennington 2014] 全局向量的词嵌入 **GloVe**: 预先提取语料集的全局统计信息

- 以 w_i 为中心词的上下文可能有多个
- 重数 x_{ij} : 上下文中的词 w_j 与 w_i 共现的全局计数

全局向量的词嵌入

[Pennington 2014] 全局向量的词嵌入 **GloVe**: 预先提取语料集的全局统计信息

- 以 w_i 为中心词的上下文可能有多个
- 重数 x_{ij} : 上下文中的词 w_j 与 w_i 共现的全局计数

(带全局语料统计的) skip-gram损失函数: $-\sum_{ij} x_{ij} \log P(w_j|w_i)$

全局向量的词嵌入

[Pennington 2014] 全局向量的词嵌入 **GloVe**: 预先提取语料集的全局统计信息

- 以 w_i 为中心词的上下文可能有多个
- 重数 x_{ij} : 上下文中的词 w_j 与 w_i 共现的全局计数

(带全局语料统计的) skip-gram损失函数: $-\sum_{ij} x_{ij} \log P(w_j|w_i)$

GloVe损失函数:

$$\sum_{ij} h(x_{ij}) (w_j \cdot w_i + b_i + c_j - \log x_{ij})^2$$

- 平方损失
- 中心词偏置 b_i 和上下文词偏置 c_i
- 权重函数 $h(x_{ij})$: $h(x)$ 在 $[0, 1]$ 递增

fastText模型

[Bojanowski 2017] fastText模型是一种子词嵌入方法

- 子词是基于单字符的N元语法
 - 可以被认为是子词级skip-gram

fastText模型

[Bojanowski 2017] fastText模型是一种子词嵌入方法

- 子词是基于单字符的N元语法
 - 可以被认为是子词级skip-gram

例如单词“where”

“<wh”、“whe”、“her”、“ere”、“re>”、“<where>”

fastText模型

[Bojanowski 2017] fastText模型是一种子词嵌入方法

- 子词是基于单字符的N元语法
 - 可以被认为是子词级skip-gram

例如单词“where”

“<wh”、“whe”、“her”、“ere”、“re>”、“<where>”

开源：<https://fasttext.cc>

- 解决测试集中未知词<unk>的问题
- 解决词变形很多、在文本中罕见的问题

词嵌入的语义属性

上下文窗口

窗口大小决定上下文词汇，进而决定语言模型的词汇分布

- 小窗口 $C = \pm 2$: 在同一类别中，语义相近、词类相同的词
 - “刘备”: “关羽”、“诸葛亮”
 - [Levy 2014] Hogwarts: Sunnydale, Evernight

上下文窗口

窗口大小决定上下文词汇，进而决定语言模型的词汇分布

- 小窗口 $C = \pm 2$: 在同一类别中，语义相近、词类相同的词
 - “刘备”: “关羽”、“诸葛亮”
 - [Levy 2014] Hogwarts: Sunnydale, Evernight
- 大窗口 $C = \pm 5$: 主题相关，但语义并不相似的词
 - “刘备”: “皇叔”、“蜀汉”
 - Hogwarts: Dumbledore, Malfoy, half-blood

两类关联关系

[Schütze 1993] 区别两类共生关系：关联度

- 一阶共生：也称横组合 **syntagmatic** 关联，经常成对出现的词
 - 写：文章，作业

两类关联关系

[Schütze 1993] 区别两类共生关系：关联度

- 一阶共生：也称横组合 **syntagmatic** 关联，经常成对出现的词
 - 写：文章，作业
- 二阶共生：也称纵聚合 **paradigmatic** 关联，有相似的共同邻居
 - 写：发表，批改

类比相似度

[Rumelhart 1973] 平行四边形 **parallelogram** 模型：词义的类比

- 认知、发展心理学：语言是词义理解的外在表现，例如“费曼学习法”

apple:tree::grape:?


类比相似度

[Rumelhart 1973] 平行四边形 **parallelogram** 模型：词义的类比

- 认知、发展心理学：语言是词义理解的外在表现，例如“费曼学习法”

apple:tree::grape:?

- 可用（向量）平行四边形法则找出目标词汇（的大概位置）



平行四边形法则

平行四边形法则可以用于类比问题

- [Turney 2005, Mikolov 2013] 对稀疏、稠密词嵌入都有效

王:男::后:?

中国:北京::法国:?

平行四边形法则

平行四边形法则可以用于类比问题


- [Turney 2005, Mikolov 2013] 对稀疏、稠密词嵌入都有效



王：男 :: 后 : ?

中国 : 北京 :: 法国 : ?

$a : b :: a' : b^*$ 问题的一般公式：求解优化问题

$$\hat{b}^* = \arg \min_x \Delta(x, b - a + a')$$





补充说明

$a : b :: a' : ? :$ 经常会返回输入的三个词，或它们的变形

- 解决方法：词形还原，并去除

补充说明

$a : b :: a' : ?$: 经常会返回输入的三个词，或它们的变形

- 解决方法：词形还原，并去除

通常对高频词比较有效，此外两种有效的特例：

- 向量间距离短：维数灾难导致距离度量失效
 - 维数还不能太低（否则不足以区分语义）
- 特殊类比：国家首都、词类明确

补充说明

$a : b :: a' : ?$: 经常会返回输入的三个词，或它们的变形

- 解决方法：词形还原，并去除

通常对高频词比较有效，此外两种有效的特例：



- 向量间距离短：维数灾难导致距离度量失效
 - 维数还不能太低（否则不足以区分语义）
- 特殊类比：国家首都、词类明确

[Peterson 2020] 人类对类比的认知过程（因果推断）仍然是开放研究

应用：语义演化

[Hamilton 2016] 对不同时代的历史文档训练词嵌入

- ~30 million books, 1850-1990, Google Books data



应用：偏见、歧视问题

[Bolukbasi 2016] 学到的词嵌入带有训练文本中的偏见

Q: 父亲:医生::母亲:?

A: 护士

应用：偏见、歧视问题

[Bolukbasi 2016] 学到的词嵌入带有训练文本中的偏见

Q: 父亲:医生::母亲:?

A: 护士

[Crawford 2017, Blodgett 2020] 错配问题 **allocational harm**

- 例如：招聘系统对性别的歧视性过滤，保险公司对人群的歧视性保费

应用：偏见、歧视问题

[Bolukbasi 2016] 学到的词嵌入带有训练文本中的偏见

Q: 父亲:医生::母亲:?

A: 护士

[Crawford 2017, Blodgett 2020] 错配问题 **allocational harm**

- 例如：招聘系统对性别的歧视性过滤，保险公司对人群的歧视性保费

[Zhao 2017, Jia 2020] 词嵌入会强化偏见

- 嵌入空间中相似的向量会聚合

历史、文化偏见

古代中国对外国人的观点：

俗无礼义，人性犷暴。形貌鄙陋，衣服毡褐。眼多碧绿，异于诸国。--《大唐西域记》

人皆高鼻深目，如回回状，身穿锁衫披裘，以皮为裤，又以皮囊其阴物，露出于外。头目常看书，取而视之，乃佛经也。--《静虚斋惜阴录》，明朝



历史、文化偏见

古代中国对外国人的观点：

俗无礼义，人性犷暴。形貌鄙陋，衣服毡褐。眼多碧绿，异于诸国。 -- 《大唐西域记》

人皆高鼻深目，如回回状，身穿锁衫披裘，以皮为裤，又以皮囊其阴物，露出于外。头目常看书，取而视之，乃佛经也。 -- 《静虚斋惜阴录》，明朝



近、现中国对外国人的观点：

为了把我自己打扮得像个西洋人.....把自己装点成《老爷杂志》上的外国贵族模样.....穿着最讲究的英国料子西服.....手提“文明棍”，戴着德国蔡司厂出品的眼镜.....身边还跟着两条或三条德国猎犬和奇装异服的一妻一妾。 -- 《我的前半生》

“德先生”和“赛先生”，“民主”和“科学”--新文化运动



历史、文化偏见

古代中国对外国人的观点：

俗无礼义，人性犷暴。形貌鄙陋，衣服毡褐。眼多碧绿，异于诸国。 -- 《大唐西域记》

人皆高鼻深目，如回回状，身穿锁衫披裘，以皮为裤，又以皮囊其阴物，露出于外。头目常看书，取而视之，乃佛经也。 -- 《静虚斋惜阴录》，明朝



近、现中国对外国人的观点：

为了把我自己打扮得像个西洋人.....把自己装点成《老爷杂志》上的外国贵族模样.....穿着最讲究的英国料子西服.....手提“文明棍”，戴着德国蔡司厂出品的眼镜.....身边还跟着两条或三条德国猎犬和奇装异服的一妻一妾。 -- 《我的前半生》

“德先生”和“赛先生”，“民主”和“科学”--新文化运动



实验：词的相似性、类比任务

Review

本章内容

词嵌入 word2vec。跳元模型 skip-gram。其他静态嵌入。BPE 子词嵌入。词嵌入的语义属性。

重点：word2vec; skip-gram; 连续词袋 CBOW; 全局向量的词嵌入 GloVe; BPE 子词嵌入；词嵌入的语义属性。

难点：词嵌入表示的特点、优缺点。

学习目标

- 理解词嵌入表示的特点（稠密），及其优缺点（效能高，丢失信息、词义）
- 理解 word2vec 的原理（训练二分类模型当作编码器）、skip-gram 的工作流程
- 理解 CBOW、GloVe 静态嵌入算法
- 理解 BPE 子词嵌入算法，及其优点（有效解决未知词问题）
- 理解使用词嵌入做类比推断的原理（平行四边形法则），并能举例说明几个语义分析应用

问题

简述词嵌入表示的特点，及其优缺点。

简述 word2vec 的原理、skip-gram 的工作流程。

简述 CBOW、GloVe 静态嵌入算法

简述 BPE 子词嵌入算法

简述使用词嵌入做类比推断的原理，并举例说明几个语义分析应用。