
南京航空航天大學
NANJING UNIVERSITY OF AERONAUTICS AND ASTRONAUTICS

# 自然语言处理

计算机科学与技术学院

# 目录


- 自然语言处理概述
- 词嵌入
  - 独热向量
  - word2vec
    - 跳元模型
    - 连续词袋模型
- 循环神经网络（RNN）
- 长短期记忆网络（LSTM）
- 门控循环单元（GRU）

# 自然语言处理概述

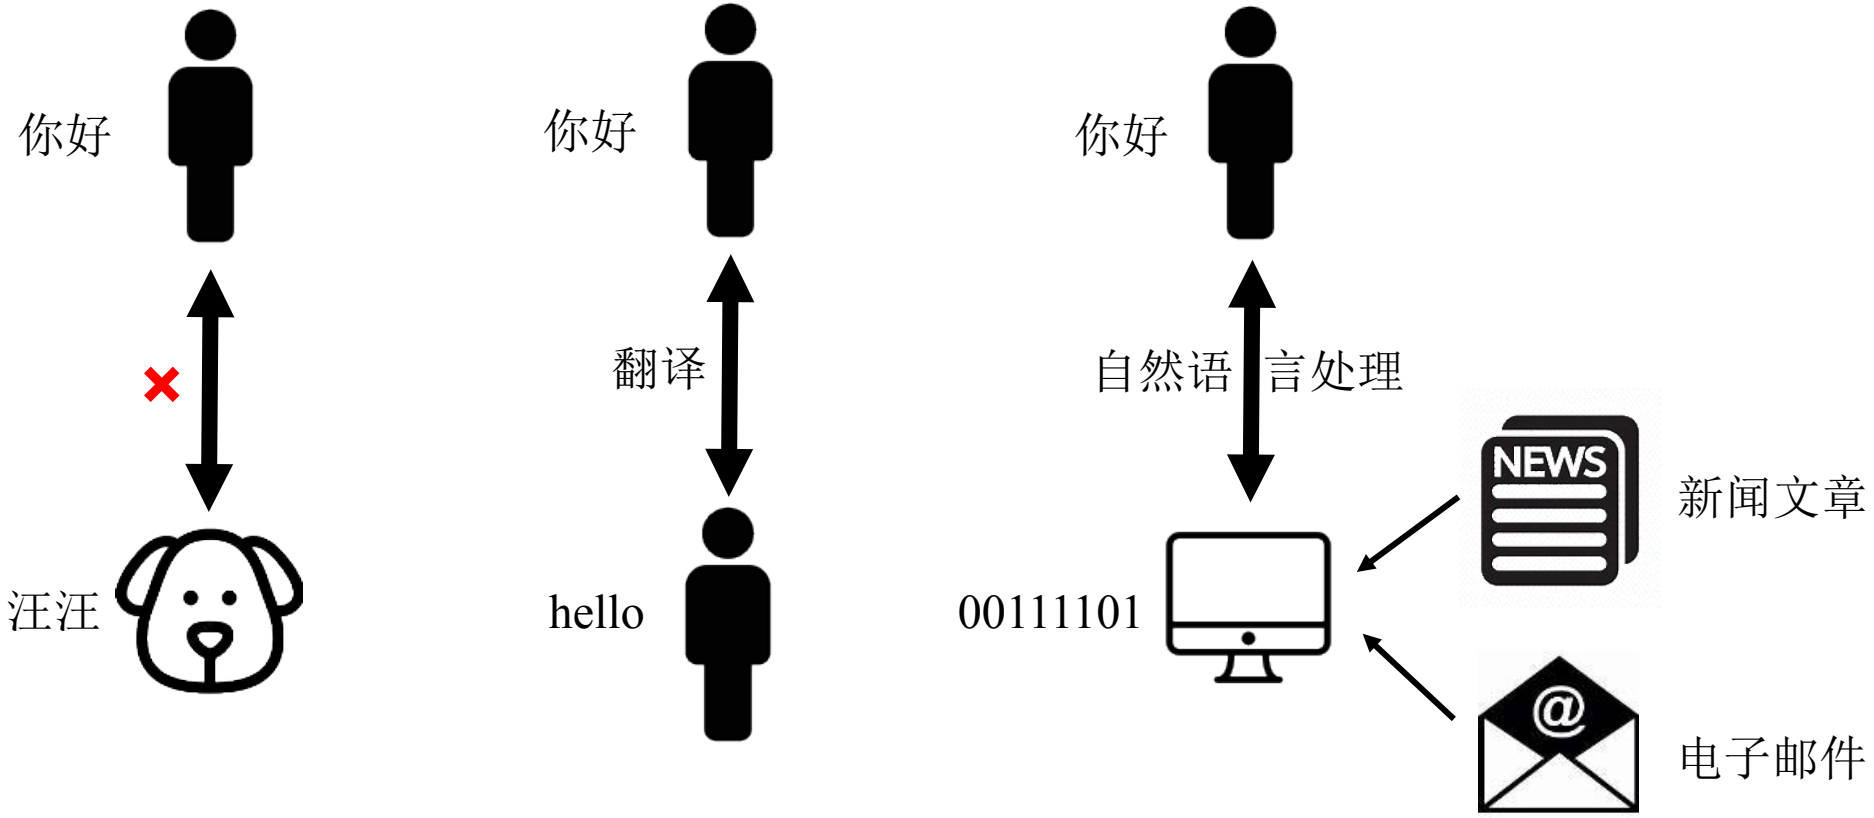


自然语言处理使计算机能够解读、处理和理解人类语言，成为人类和计算机之间沟通的桥梁

# 自然语言处理概述——基本任务

## 自然语言理解

人与计算机交流的第一步就是让计算机理解人类输入给它的信息。这类任务的研究目的是使**计算机能够理解自然语言**，从自然语言中提取有用的信息输出或用于下游任务

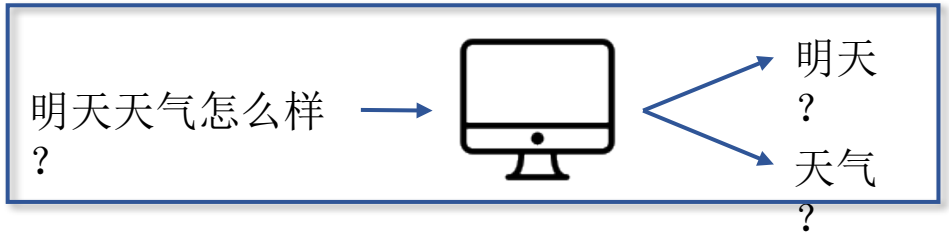


自然语言理解类任务包括：

- 词性标注
- 分词
- 文本分类
- 信息抽取

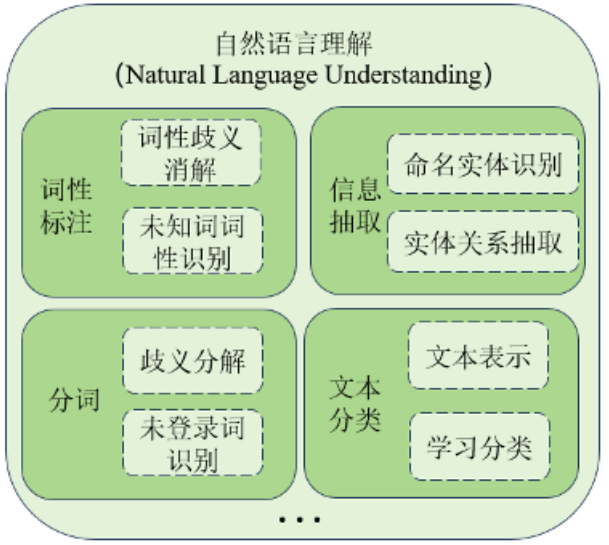


## 自然语言生成

计算机理解人类的输入后，我们还希望计算机能够生成满足人类目的的、可以理解的**自然语言形式的输出**，从而实现真正的交流。

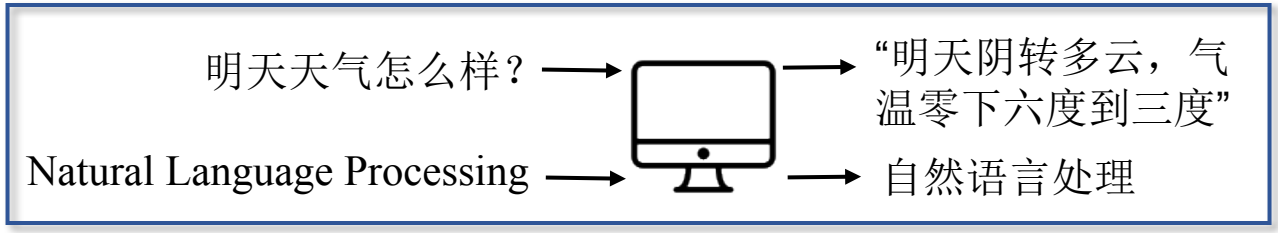


自然语言生成类任务包括：

- 机器翻译
- 问答系统
- 自动摘要
- 语音识别

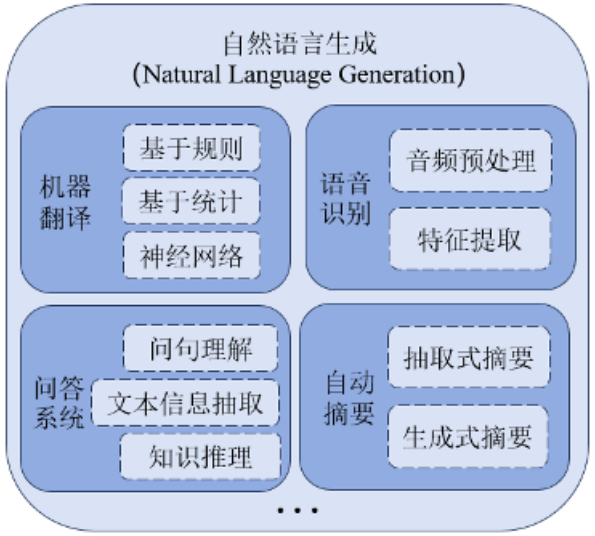

# 自然语言处理概述——发展历程

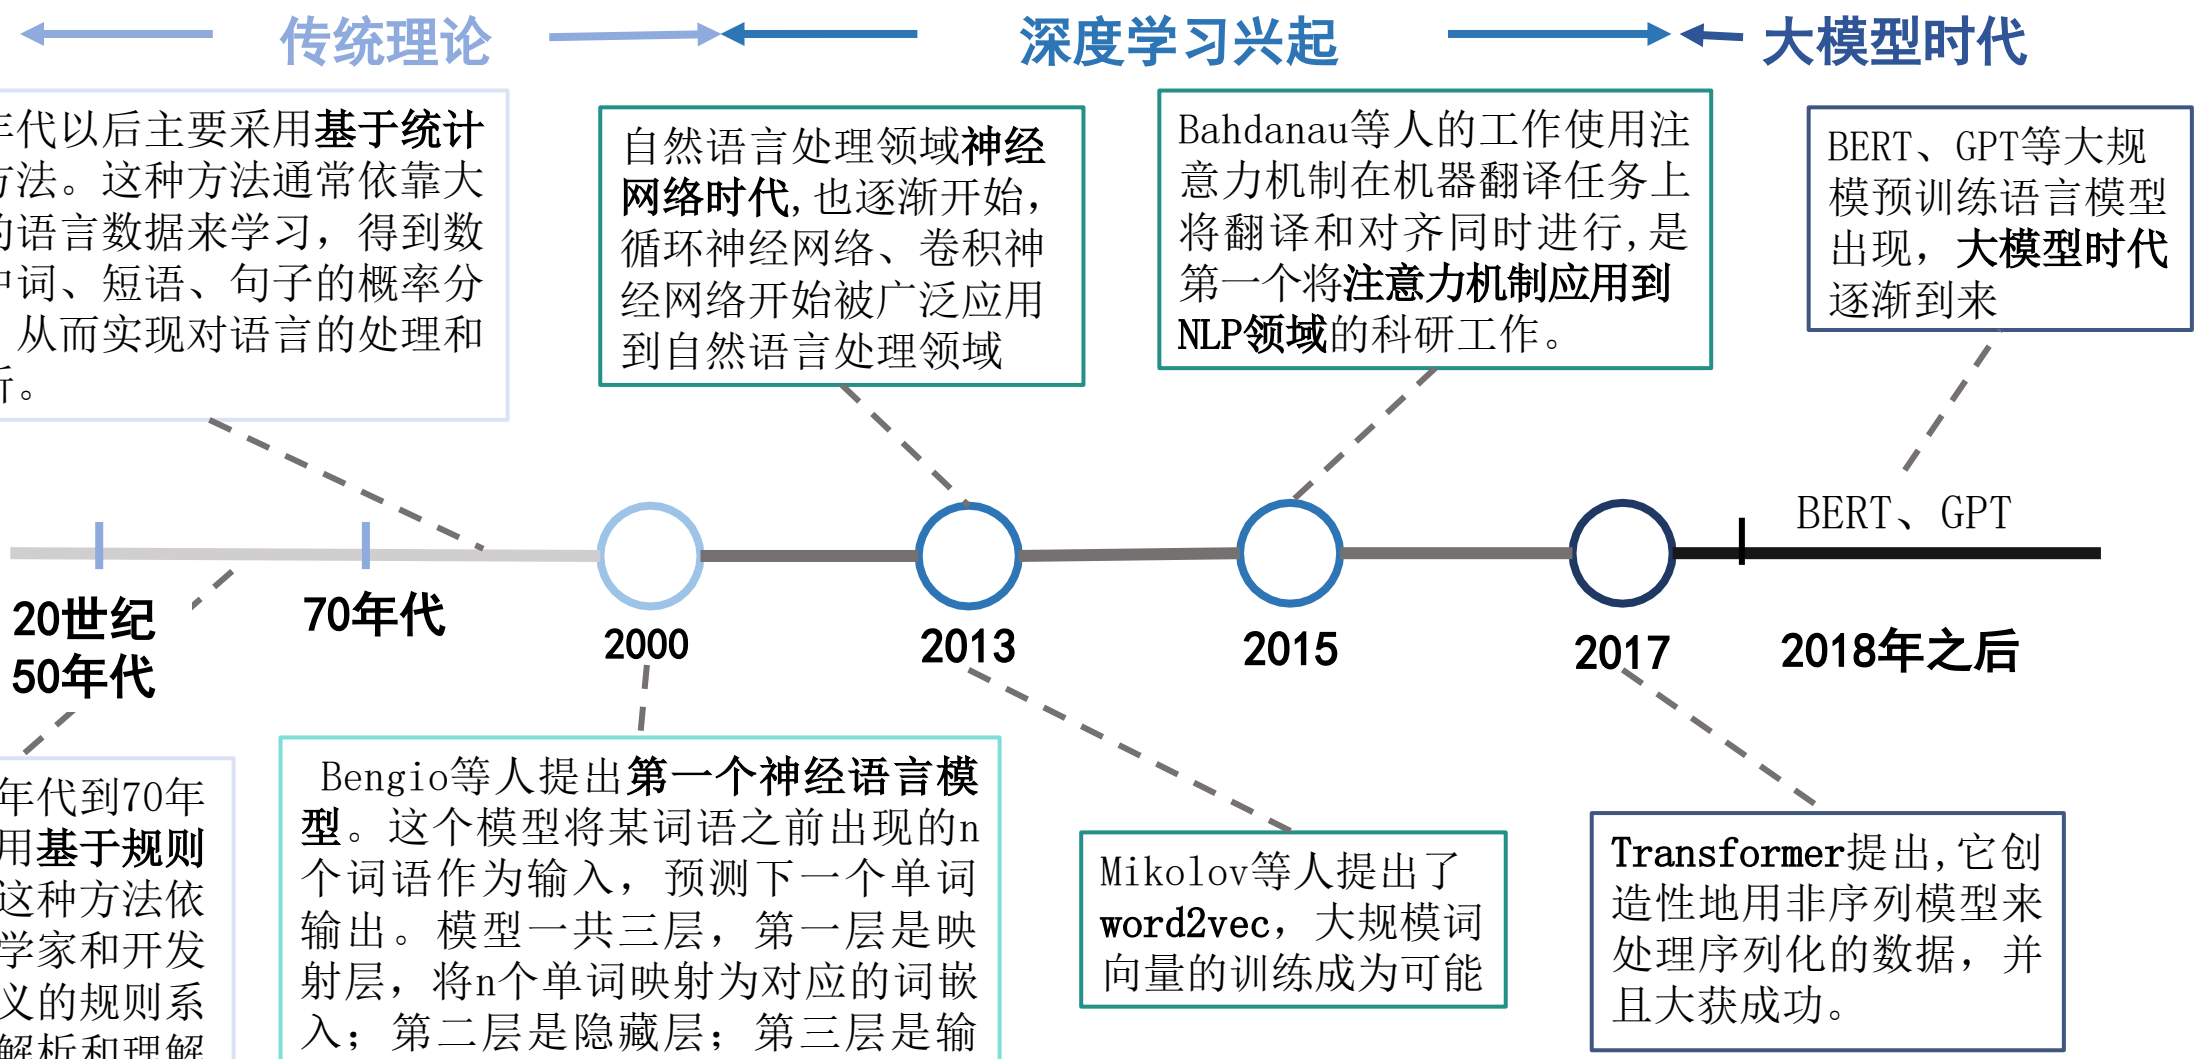

# 自然语言处理概述——应用领域

南京航空航天大学 NANJING UNIVERSITY OF AERONAUTICS AND ASTRONAUTICS

## 1. 翻译软件

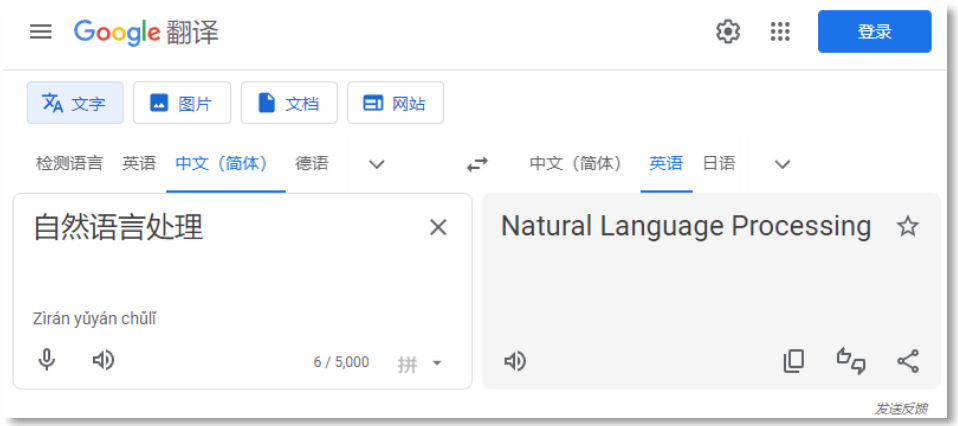


## 2. 聊天机器人


## 3. 语音助手



## 4. 搜索引擎

# 目录

计算机是无法直接读懂非数值的自然语言，只有将其**转化为数值形式**才能被计算机处理 → 词嵌入

完成各种下游任务 → 神经网络模型 → 循环神经网络（RNN）/ 长短期记忆网络（LSTM）/ 门控循环单元（GRU）

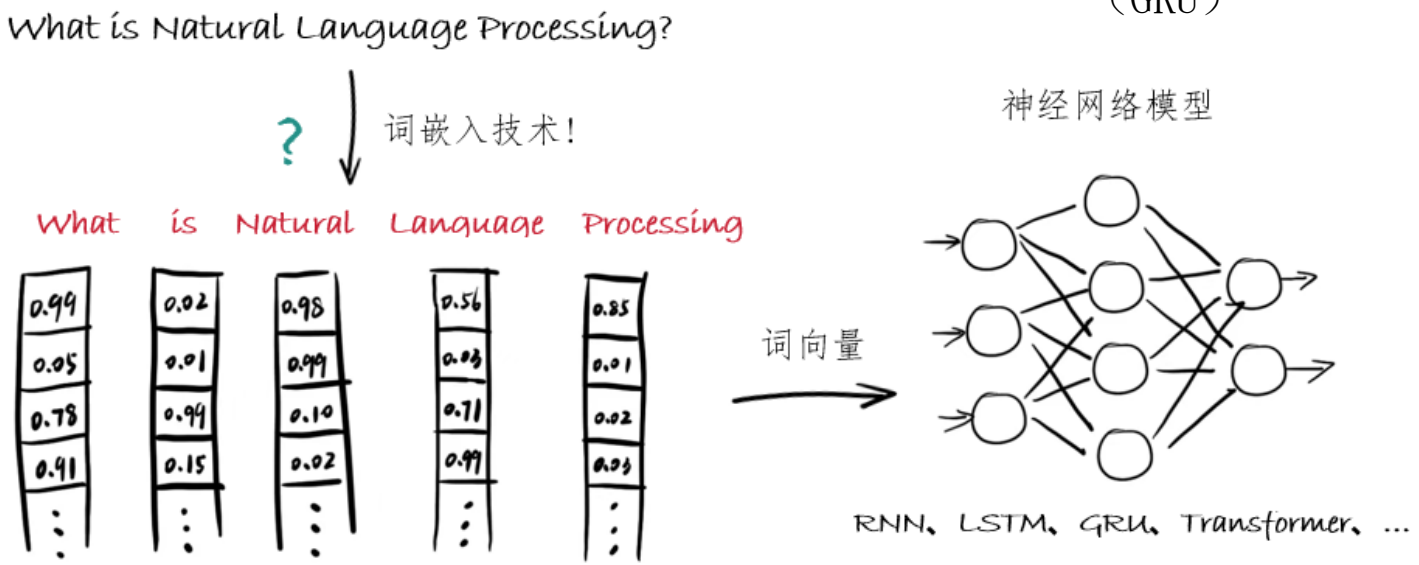



- 自然语言处理概述
- 词嵌入
  - 独热向量
  - word2vec
    - 跳元模型
    - 连续词袋模型
- 循环神经网络（RNN）
- 长短期记忆网络（LSTM）
- 门控循环单元（GRU）

# 词嵌入——独热向量(One-hot Encoding)

文本 $\xrightarrow{?}$ 数值　最简单的方法就是用独热向量表示每个单词

□ 独热向量是指使用 *N* 位 0 或 1 对 *N* 个单词进行编码，其分量和类别数一样多，**类别对应的分量设置为 1**（即 one-hot），其余分量设置为 0。

例如，编码apple、bag、cat、dog、elephant五个单词，用 5 位向量进行编码：

apple = [**1** 0 0 0 0]

bag = [0 **1** 0 0 0]

cat = [0 0 **1** 0 0]

dog = [0 0 0 **1** 0]

elephant = [0 0 0 0 **1**]

$$cos(x,y) = \frac{x^{\top}y}{\|x\|\|y\|} = 0$$

但任意两词之间余弦相似度为0！

独热向量的维度等于词汇表大小，在词汇表较大时会变得非常长

√ **优点：**

- 独热向量容易构建

× **缺点：**

- 独热向量不能编码词之间的相似性
- 特征矩阵非常稀疏，占用空间很大

# 词嵌入——word2vec

我 希望 向量

- **携带上下文信息**，即词与词之间的联系能在词的向量表示中体现。
- 词的表示是稠密的，能用**更少的空间、更低的维数**表示更多的信息。

我 希望 **的效果**

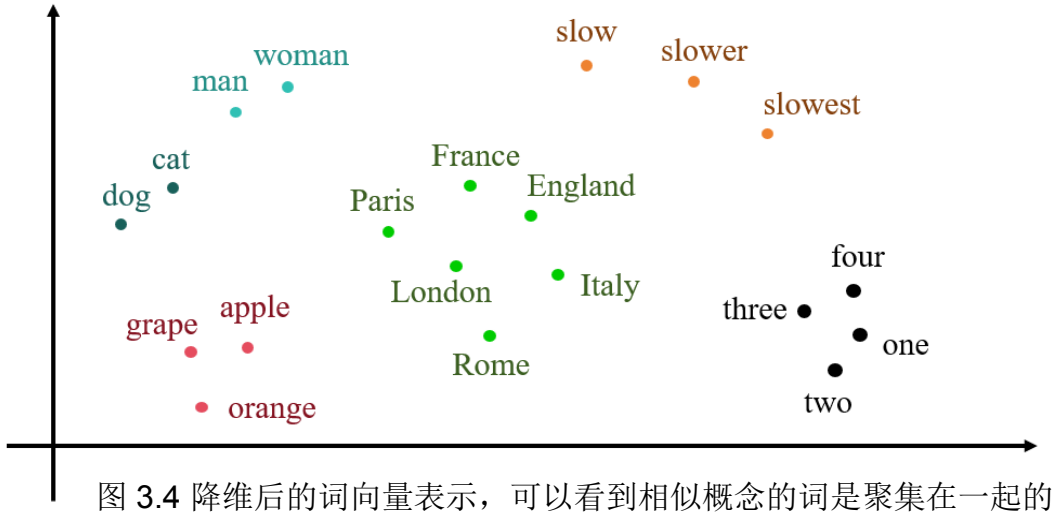


图 3.4 降维后的词向量表示，可以看到相似概念的词是聚集在一起的

实现 ← **word2vec!**

- word2vec是一种词嵌入技术，也可被看作是一个神经网络模型，其参数是词向量，通过**预测上下文**来学习好的词向量。

和独热向量相比，word2vec生成的词向量具有以下优点：

- 训练时利用上下文信息，词向量包含词的语义信息和词与词之间的联系。
- 维度更少，所以占用空间更少、计算成本更低。
- 通用性强，可用于各种下游 NLP 任务。

训练word2vec的常用方法有两种：跳元模型（Skip-Gram）和连续词袋（Continuous Bagsof Words：CBOW）

# 词嵌入——跳元模型

南京航空航天大學 NANJING UNIVERSITY OF AERONAUTICS AND ASTRONAUTICS

- 根据**中心词**预测**上下文词**

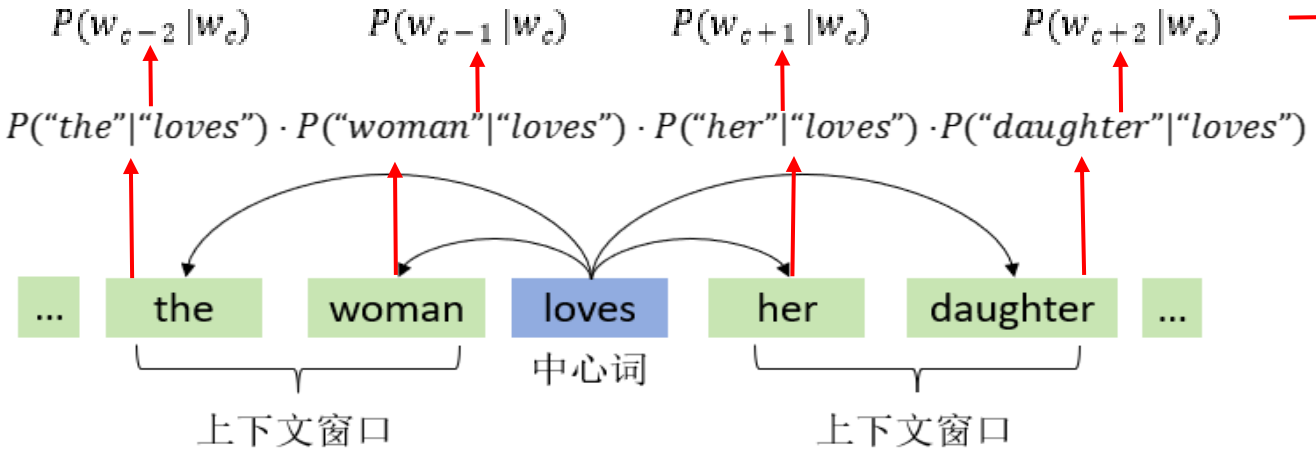


如何计算？

$$P(w_o|w_c) = \frac{exp(u_o{}^T v_c)}{\sum_{i \in V} exp(u_i{}^T v_c)}$$ 就是 *softmax* !

对于每个单词$w_i$我们有两个向量：

- 当它是一个中心词时，用$\boldsymbol{v_i}$表示该词
- 当它是一个上下文词时，用$\boldsymbol{u_i}$表示该词

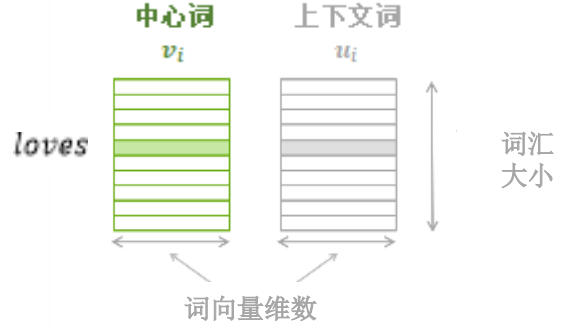


- 目标函数（损失函数）
  - 给定长度为 $T$ 的文本序列，时刻 $t$ 处的词表示为 $w^{(t)}$
  - 上下文窗口大小为 $m$

则，似然函数为在给定任何中心词的情况下生成所有上下文的概率：

$$Likehood = \prod_{t=1}^{T} \prod_{-m \le j \le m, j \ne 0} P(w^{(t+j)}|w^{(t)})$$

- 目标是最大化该似然函数，即最小化损失函数：

$$Loss = -\sum_{t=1}^{T} \sum_{-m \le j \le m, j \ne 0} P(w^{(t+j)}|w^{(t)})$$

# 词嵌入——连续词袋模型

南京航空航天大學 NANJING UNIVERSITY OF AERONAUTICS AND ASTRONAUTICS

- 根据**上下文词**预测**中心词**

$P(w_c|w_{c-2}, w_{c-1}, w_{c+1}, w_{c+2})$ 如何计算 ?

$P(w_c|w_{o_1}, \dots, w_{o_{2m}}) = \frac{exp(\frac{1}{2m}u_c^T(v_{o_1} + \dots + v_{o_{2m}}))}{\sum_{i \in V} exp(\frac{1}{2m}u_i^T(v_{o_1} + \dots + v_{o_{2m}}))}$

$P(\text{“loves”}|\text{“the”}, \text{“woman”}, \text{“her”}, \text{“daughter”})$

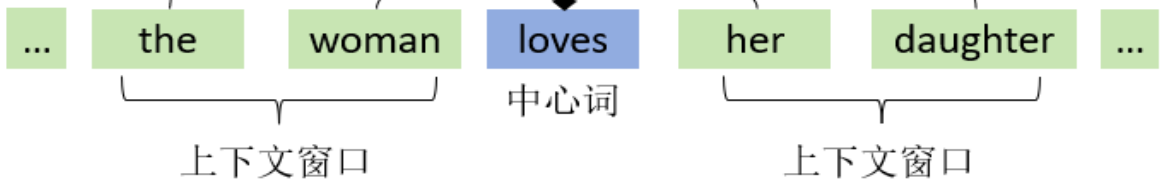


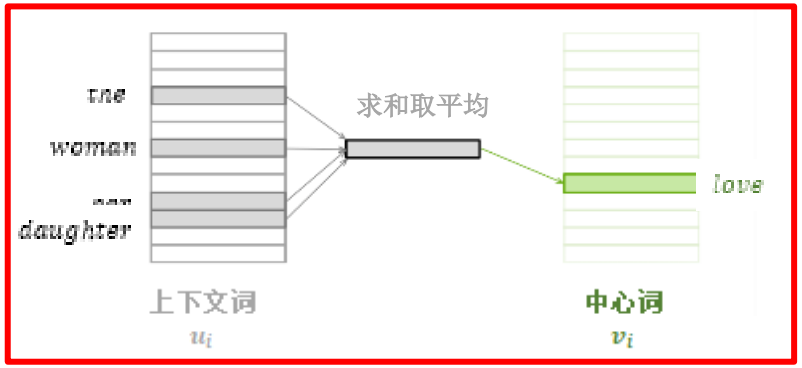


- 目标函数（损失函数）

  - 给定长度为 $T$ 的文本序列，时刻 $t$ 处的词表示为 $w^{(t)}$
  - 上下文窗口大小为 $m$

则，似然函数为在给定上下文词的情况下生成所有中心词的概率： $Likehood = \prod_{t=1}^{T} P(w^{(t)}|w^{(t-m)}, \dots, w^{(t-1)}, w^{(t+1)}, \dots, w^{(t+m)})$

- 目标是最大化该似然函数，即最小化损失函数： $Loss = -\sum_{t=1}^{T} P(w^{(t)}|w^{(t-m)}, \dots, w^{(t-1)}, w^{(t+1)}, \dots, w^{(t+m)})$

# 词嵌入——连续词袋模型举例

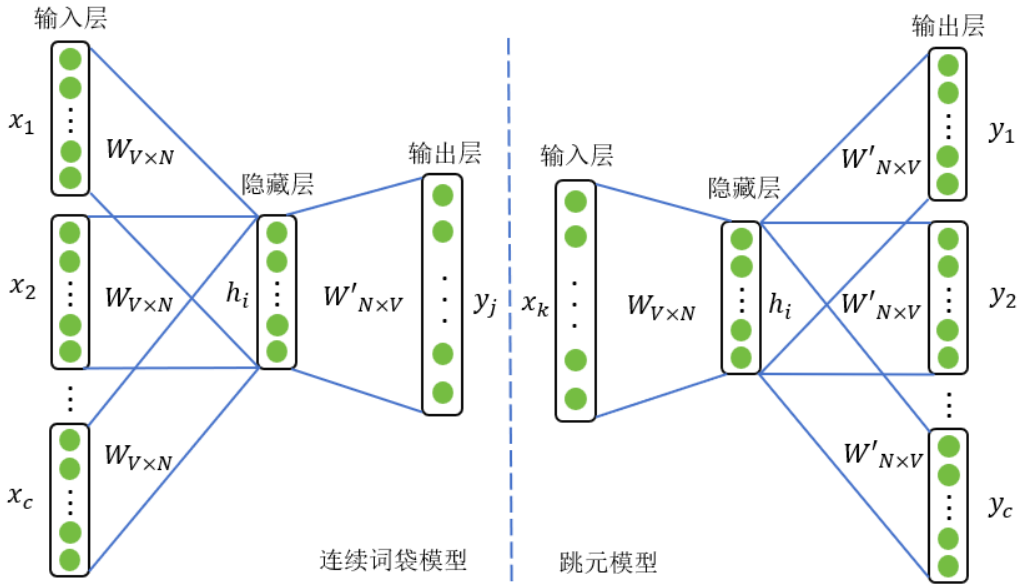


使用单词的独热编码作为输入：

the = [1 0 0 0 0]

woman = [0 1 0 0 0]

loves = [0 0 1 0 0]

her = [0 0 0 1 0]

daughter = [0 0 0 0 1]

假设训练得到的权重矩阵$W_{V\times N}$为：$\begin{bmatrix} 1 & 2 & 3 & 0 & 1 \\ 1 & 2 & 1 & 2 & 2 \\ -1 & 1 & 1 & 1 & 0 \end{bmatrix}$

其中，N=5 表示输入层单词的维数，V=3 表示希望得到的词向量维数

现在将 “the” 输入，即与权重矩阵相乘：$\begin{bmatrix} 1 & 2 & 3 & 0 & 1 \\ 1 & 2 & 1 & 2 & 2 \\ -1 & 1 & 1 & 1 & 0 \end{bmatrix}\begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}$

“the”的词向量

同理，可以得到每个单词的词向量为：$woman = \begin{bmatrix} 2 \\ 2 \\ 1 \end{bmatrix}, her = \begin{bmatrix} 0 \\ 2 \\ 1 \end{bmatrix}, daughter = \begin{bmatrix} 1 \\ 2 \\ 0 \end{bmatrix}$

# 词嵌入——连续词袋模型举例

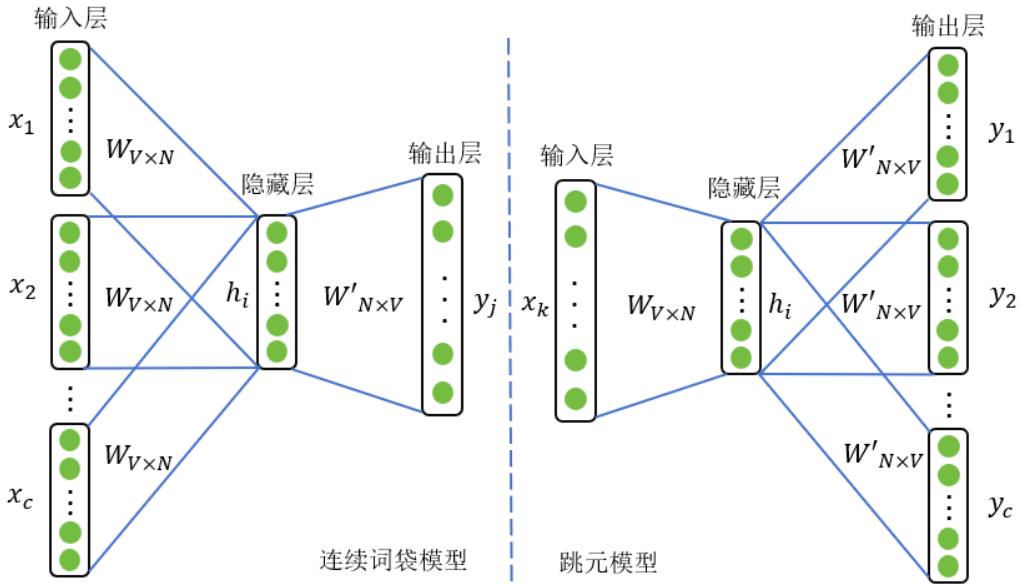


将得到的4个向量相加求平均作为输出层的输入：

$$\frac{1}{4}\left(\begin{bmatrix}1\\1\\-1\end{bmatrix}+\begin{bmatrix}2\\2\\1\end{bmatrix}+\begin{bmatrix}0\\2\\1\end{bmatrix}+\begin{bmatrix}1\\2\\0\end{bmatrix}\right)=\begin{bmatrix}1.00\\1.75\\0.25\end{bmatrix}$$

将该向量与权重矩阵$W'_{N\times V}$（也是网络训练的结果）相乘得到输出向量，最后将 softmax 作用在输出向量上，得到每个词的概率分布:

$$softmax\left(\begin{bmatrix}1&2&-1\\-1&2&-1\\1&2&2\\0&2&0\\1&-1&2\end{bmatrix}\begin{bmatrix}1.00\\1.75\\0.25\end{bmatrix}\right)=softmax\left(\begin{bmatrix}4.250\\2.250\\5.000\\3.000\\-0.250\end{bmatrix}\right)=\begin{bmatrix}0.268\\0.036\\0.567\\0.126\\0.003\end{bmatrix}$$

最后计算损失函数，反向传播，更新网络参数。

！预测目标单词是训练网络的方式，获得网络的中间产物——权重矩阵$W_{V\times N}$才是期望得到的，因为任意一个单词的独热向量乘该矩阵就能得到自己的词向量

# 目录


- 自然语言处理概述
- 词嵌入
  - 独热向量
  - word2vec
    - 跳元模型
    - 连续词袋模型
- 循环神经网络（RNN）
- 长短期记忆网络（LSTM）
- 门控循环单元（GRU）