



人工智能与深度学习

5-1 循环神经网络 I

王中雷

经济学院、王亚南经济研究院、邹至庄经济研究院

厦门大学

(第一版)

内容摘要

1. 研究动机

2. 符号

3. 循环神经网络 (Recurrent neural networks)

研究动机

1. 自然语言处理（Natural Language Processing, NLP）中的常见问题

- 机器翻译
- 情感分析
- 对话生成或问答，例如 ChatGPT（Chat Generative Pre-trained Transformer）

2. 例如，寻找下面句子中的目的地（本章以英文句子为例）

- I arrive in **Beijing** from Xiamen
- I leave Beijing for **Xiamen**

3. 问题

- 如何将一个句子转化为可用于计算的特征？
- 适合自然语言处理的模型是什么？

研究动机

1. 在自然语言处理的问题中，我们通常采取如下步骤

- 词元化 (Tokenization) (为了提取特征)
- 词嵌入 (Embedding)
- 建模 (为了分析)

词元化

1. 对于英语，可以利用空格进行初步切分
2. 例如，当我们考虑 “I arrive in Beijing from Xiamen.”
3. 我们可以将其分解成七个词元

I / arrive / in / Beijing / from / Xiamen / .

4. 基于词典（vocabulary）的词元化的难点

- 例如名字等，有些词汇并不会出现在词典里
- 对处理标点符号 “.,;:?! ” 等，没有明确的结论
- 对于同一个词源的不同（英语等）单词，需要不同的词元化
 - ▷ 例如，“walk, walks, walked”...

词元化

1. 可能的解决方案：寻找一个词典，能够包括如下信息

- 常见单词
- 词表中还可以包含常见的子词片段，使低频词或未登录词能够由多个子词组合表示

2. 得到词元后，我们给每个词元，分配一个词向量

（由数字组成的具有固定长度的列向量）

独热编码

1. 在处理实际问题时，一个词典的大小约为 $N(\approx 30,000)$
2. 独热编码可被用于，为字典中的每个词元进行赋值
 - 每个词元对应的向量长度为 N
 - 该向量除了一个位置为 1 外，其他元素均为 0
 - 1 的位置代表该词元在字典中的位置

备注

1. 缺点

- **高维且稀疏**：独热编码维度等于词表大小，存储和直接计算效率较低
- 由于词向量维度高，容易产生**过拟合**
- **不能用来对“关系”进行建模**，例如“Man-Woman”
- **对字典中的微小变化较为敏感**：若重新排序或重新编号词表，已有词元的编码会随之改变
-

词嵌入

1. 我们希望得到一种新的为词元赋值词向量的方式—词嵌入 (Word embedding)

- 词向量的维度通常远小于字典的规模
- 反映词元之间的逻辑关系

2. 一些可行的解决方案

- Word2Vec: CBOW、Skip-gram
- GloVe
- BERT
-

词嵌入

1. 词嵌入是自然语言处理中的重要表示方法

- 词嵌入是基于模型学到的结果
- 基于优秀的词嵌入，OpenAI 的 GPT 可以产生更加连贯，并且符合人们行文逻辑的回复

2. 在本章中，我们不讨论产生词嵌入的算法，请自行学习相关内容

3. 在接下来的分析中，我们假设我们对每个词元有一个词嵌入

模型

1. 任务：寻找下列句子中的目的地

I arrive in **Beijing** from Xiamen

词嵌入：

$\mathbf{x}^{<1>}$

$\mathbf{x}^{<2>}$

$\mathbf{x}^{<3>}$

$\mathbf{x}^{<4>}$

$\mathbf{x}^{<5>}$

$\mathbf{x}^{<6>}$

标签：

$y^{<1>} = 0$

$y^{<2>} = 0$

$y^{<3>} = 0$

$y^{<4>} = \mathbf{1}$

$y^{<5>} = 0$

$y^{<6>} = 0$

2. 什么样的模型适合自然语言处理呢？

模型

1. 为什么不能用全连接神经网络或者卷积神经网络?

- 以上两个模型在处理序列类型数据时，都存在一定的缺陷
 - ▷ 全连接神经网络：通常要求固定长度输入且缺少位置间的参数共享
 - ▷ 卷积神经网络：对长距离顺序依赖的建模通常需要更大的感受野或更复杂的结构

2. 目标模型应当满足

- 能够处理变长序列
- 能够在每一步保留上下文信息
- 能够根据任务需要，调整输出形式

循环神经网络 (Recurrent Neural Network)

1. 一个类似的模型，早在 1980 年代就被提出
2. 我们以寻找句子中的目的地为例，进行讲解
 - 本质上讲，这是针对一个句子中的每个词元的二分类问题
3. 我们有一个由多个（长度不尽相同的）句子组成的训练集
4. 后续我们将讨论其他自然语言处理中的任务

循环神经网络 (Recurrent Neural Network)

1. 假设我们有一个句子

I arrive in **Beijing** from Xiamen

词嵌入:

$\mathbf{x}^{<1>}$

$\mathbf{x}^{<2>}$

$\mathbf{x}^{<3>}$

$\mathbf{x}^{<4>}$

$\mathbf{x}^{<5>}$

$\mathbf{x}^{<6>}$

标签:

$y^{<1>} = 0$

$y^{<2>} = 0$

$y^{<3>} = 0$

$y^{<4>} = \mathbf{1}$

$y^{<5>} = 0$

$y^{<6>} = 0$

2. 我们需要对该句中的每个词元是目的地的概率 $\{\hat{y}^{<i>} : i = 1, \dots, 6\}$ 进行估计

模型模块


1. 初始化 $\mathbf{a}^{<0>} = 0$

2. 基于当前模型参数 $\{\mathbf{W}_{ax}, \mathbf{W}_{aa}, \mathbf{b}_a, \mathbf{W}_{ya}, \mathbf{b}_y\}$, 我们计算

$$\begin{aligned}\mathbf{a}^{<i>} &= \sigma_{ax}(\mathbf{W}_{ax} \cdot \mathbf{x}^{<i>} + \mathbf{W}_{aa} \cdot \mathbf{a}^{<i-1>} + \mathbf{b}_a) \quad (i = 1, \dots, 6), \\ \hat{y}^{<i>} &= \sigma_{ya}(\mathbf{W}_{ya} \cdot \mathbf{a}^{<i>} + \mathbf{b}_y) \quad (i = 1, \dots, 6)\end{aligned}$$


模型模块

$$\hat{y}^{<i>} = \sigma_{ya}(\mathbf{W}_{ya} \cdot \mathbf{a}^{<i>} + b_y) \quad (i = 1, \dots, 6)$$



$$\mathbf{a}^{<i>} = \sigma_{ax}(\mathbf{W}_{ax} \cdot \mathbf{x}^{<i>} + \mathbf{W}_{aa} \cdot \mathbf{a}^{<i-1>} + b_a) \quad (i = 1, \dots, 6)$$

流程图



备注

1. 由于我们考虑的是二分类问题，代价函数是交叉熵
2. 基于上一页的前向传播过程，我们可以得到对应的后向传播
 - 提示：我们需要将包含模型参数信息的导数都加起来

其他例子

1. 情感分析（多对一）

- 特征：一个类似于 “I like this movie very much” 的句子
- 标签：一个类似于 “5” 这样，衡量情感的得分指标

2. 机器翻译（多对多）


- 特征：一个句子
- 标签：翻译后的句子

3. 文本生成（多对多、自回归生成）

- 特征：类似于 “I like ” 的句子的开头部分
- 标签：基于词补全的句子成分


情感分析

1. 特征：一个类似于 “I like this movie very much” 的句子
2. 标签：一个类似于 “5” 这样，衡量情感的得分指标




机器翻译

1. 特征：类似于 “I like this movie very much” 的一句话
2. 标签：翻译后的句子，即 “我非常喜欢这部电影”



文本生成

1. 特征：类似于 “I like ” 的句子的开头部分
2. 标签：基于词补全的句子成分



备注

1. Bengio et al. (1994) 指出，循环神经网络模型往往难以通过梯度训练学习长期依赖，原因在于梯度可能消失（概率高）或者爆炸（概率低但后果严重）
2. 长期依赖对应的梯度信号会随序列长度显著衰减，从而容易被短期依赖的影响掩盖 (Chung et al., 2014)

课程总结

1. 自然语言文本通常可以表示为序列数据
2. 高维稀疏的向量表示，不适合作为最终建模工具
3. 循环神经网络能够处理序列数据
4. 循环神经网络的缺点是什么？