

19 循环神经网络

概要

- 循环神经网络
 - 实现 RNN 语言模型
 - 截断通过时间反向传播
- 门控循环单元(GRU)
- 长短期记忆网络(LSTM)

循环神经网络




潜变量模型

- 隐含状态 h_t 总结了有关过去所有的相关信息


$$h_t = f(x_1, \dots, x_{t-1}) = f(h_{t-1}, x_{t-1})$$

$$p(h_t | h_{t-1}, x_{t-1}),$$

$$p(x_t | h_t, x_{t-1})$$



循环神经网络



- 隐含状态更新 $\mathbf{h}_t = \phi(\mathbf{W}_{hh}\mathbf{h}_{t-1} + \mathbf{W}_{hx}\mathbf{x}_{t-1} + \mathbf{b}_h)$
- 输出更新 $\mathbf{o}_t = \phi(\mathbf{W}_{ho}\mathbf{h}_t + \mathbf{b}_o)$
- 计算损失

基于循环神经网络的字符级语言模型


➤ 目标

➤ 根据过去的和当前的词元预测下一个词元，因此将原始序列移位一个词元作为标签

➤ Bengio等首先提出使用神经网络进行语言建模

➤ 字符级语言模型

非单词 元化为字符/



困惑度(perplexity)

- 一个好的语言模型

- 能够用高度准确的词元来预测接下来会看到什么

- 衡量一个语言模型的好坏，可以用平均交叉熵

$$\pi = \frac{1}{n} \sum_{i=1}^n -\log p(x_t | x_{t-1}, \dots)$$

- p 是语言模型的预测概率, x_t 是真实词

- 历史原因，NLP使用困惑度 $\exp(\pi)$ 来衡量。困惑度

- 平均每次可能选项

- 最好的理解是“下一个词元的实际选择数的调和平均数”

- 1表示完美, 无穷大为最差情况


梯度裁剪

- ▶ 迭代中计算 T 个时间步上的梯度, 在反向传播过程中产生长度为 $O(T)$ 的矩阵乘法链, 导致数值不稳定
- ▶ 梯度裁剪能有效预防梯度爆炸
 - ▶ 降低 η 的学习率
 - ▶ 一个流行的替代方案: 通过将梯度 \mathbf{g} 投影回给定半径 (例如 θ) 的球来裁剪梯度 \mathbf{g}
 - ▶ 如梯度长度超过 θ , 那么投影回长度 θ


$$\mathbf{g} \leftarrow \min\left(1, \frac{\theta}{\|\mathbf{g}\|}\right) \mathbf{g}$$

更多的应用

one to one




one to many




文本生成

many to one




文本分类

many to many



问答、机器翻译

many to many



Tag生成

总结


- 循环神经网络的输出取决于当下输入和前一时间的隐变量
- 应用到语言模型中时, 循环神经网络根据当前词预测下一次时刻词
- 通常使用困惑度来衡量语言模型的好坏

门控循环单元(GRU)



在一个序列的注意力

- ▶ 并非所有元素都具有同等意义



- ▶ 想只记住相关的元素【特别的元素】

- ▶ 能关注的机制(更新门)【0为与过去无关, 1为只和过去有关】【更新的是候选的内容】

- ▶ 能忘记的机制(重置门)【0忘记, 1记住】【生成候选内容, 不一定会更新】


- ▶ 如何实现?

- ▶ 对应的控制变量

- ▶ 隐状态, 以及候选隐状态!

门控循环单元

- $R_t = \sigma(X_t W_{xr} + H_{t-1} W_{hr} + b_r)$
- $Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z)$
- 重置门：
 - 隐状态权重，控制候选隐状态的生成
- 更新门
 - 输入权重，控制最终隐状态的生成
- 【注】
 - 引入隐状态，则与其相关状态包含
 - 过去隐状态
 - 候选隐状态
 - 过去隐状态
 - 输入




候选隐含状态

- ▶ 候选隐状态 (candidate hidden state) $\tilde{\mathbf{H}}_t \in \mathbb{R}^{n \times h}$

$$\tilde{\mathbf{H}}_t = \tanh(\mathbf{X}_t \mathbf{W}_{xh} + (\mathbf{R}_t \odot \mathbf{H}_{t-1}) \mathbf{W}_{hh} + \mathbf{b}_h)$$

- ▶ 符号 \odot 是Hadamard积 (按元素乘积) 运算符
- ▶ 合成新的隐状态，作为新的隐含状态的输入分量
- ▶ \mathbf{R}_t 和 \mathbf{H}_{t-1} 作为输入的多层感知机的结果




隐含状态

- \mathbf{H}_{t-1} 和 $\tilde{\mathbf{H}}_t$ 之间进行按元素的凸组合更新隐含状态

$$\mathbf{H}_t = \mathbf{Z}_t \odot \mathbf{H}_{t-1} + (1 - \mathbf{Z}_t) \odot \tilde{\mathbf{H}}_t$$

- 即根据过去状态，以及融合输入信息的候选隐状态来更新
 - 权重通过更新门控制，0为与过去无关，1为只和过去有关



门控循环单元(GRU)总结


$$R_t = \sigma(X_t W_{xr} + H_{t-1} W_{hr} + b_r)$$

$$Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z)$$

➤ $\tilde{H}_t = \tanh(X_t W_{xh} + (R_t \odot H_{t-1}) W_{hh} + b_h)$


$$H_t = Z_t \odot H_{t-1} + (1 - Z_t) \odot \tilde{H}_t$$

$$O_t = H_t W_{ha} + b_a$$




代码 ...

长短期记忆(LSTM)



电门联想

- ▶ 长短期记忆网络引入记忆元(memory cell), 或简称为单元(cell)



长短期记忆(LSTM)

➤ 忘记门

- 重置单元的内容

➤ 输入门

- 决定是否应忽略输入数据

➤ 输出门

- 决定是不是使用隐状态

➤ 机制

- 隐状态


- 记忆和候选记忆【可理解为没有归一化的隐状态，因此这三个变量有交叉】

输入门、遗忘门和输出门

$$I_t = \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i)$$

$$\text{▶ } F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f)$$

$$O_t = \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o)$$




候选记忆元

➤ 候选记忆元 (candidate memory cell) $\tilde{\mathbf{C}}_t \in \mathbb{R}^{n \times h}$ 。函数的值范围为 $(-1,1)$


$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{X}_t \mathbf{W}_{xc} + \mathbf{H}_{t-1} \mathbf{W}_{hc} + \mathbf{b}_c),$$

➤ 其中 $\mathbf{W}_{xc} \in \mathbb{R}^{d \times h}$ 和 $\mathbf{W}_{hc} \in \mathbb{R}^{h \times h}$ 是权重参数, $\mathbf{b}_c \in \mathbb{R}^{1 \times h}$ 是偏置参数。



记忆元


- ▶ 门控循环单元中有机制控制输入和遗忘 (或跳过)。在LSTM中, 输入门 I_t 控制采用多少来自 \tilde{C}_t 的新数据, 而遗忘门 F_t 控制保留多少过去的记忆元 $C_{t-1} \in \mathbb{R}^{n \times h}$ 的内容:



隐状态

► 隐状态 $\mathbf{H}_t \in \mathbb{R}^{n \times h}$

$$\mathbf{H}_t = \mathbf{o}_t \odot \tanh(\mathbf{C}_t)$$



长短期记忆(LSTM)总结

$$I_t = \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i)$$

$$F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f)$$

$$O_t = \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o)$$

$$\tilde{C}_t = \tanh(X_t W_{xc} + H_{t-1} W_{hc} + b_c)$$

$$C_t = F_t \odot C_{t-1} + I_t \odot \tilde{C}_t$$

$$H_t = O_t \odot \tanh(C_t)$$

输出

输入

隐状态


输出

记忆

➤ 过去记忆(遗忘门控制)

➤ 候选记忆(输入门控制)

➤ 过去隐状态, 输入



遗忘门和输入门, 输出门

➤ 生成信息用于参数权重控制

➤ 长短期记忆网络的隐藏层输出包括“隐状态”和“记忆元”。只有隐状态会传递到输出层, 而记忆元完全属于内部信息。