

第17章 问答系统算法

《人工智能算法》

清华大学出版社

2022年7月

提纲

- ◆ 引例
- ◆ 问答系统的基本思想
- ◆ 循环神经网络
- ◆ 长短期记忆网络
- ◆ 基于LSTM的问答系统构建
- ◆ 总结

引例 (1)

◆ 典型的问答系统场景

客户 我当前使用的是多少的套餐？

q_1

客服 您当前使用的是七十八套餐，包含20GB流量和300分钟通话时间。

客户 我每个月使用多少流量？

q_2

客服 平均每个月使用25GB流量。

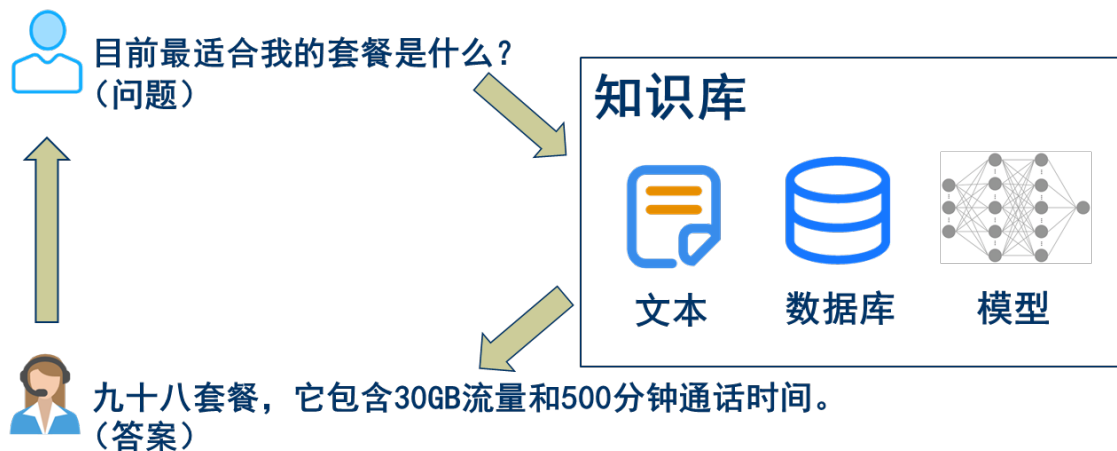
客户 目前最适合我的套餐是什么？

q_3

客服 九十八套餐，它包含30GB流量和500分钟通话时间。

引例 (2)

- ◆ q_1 和 q_2 可直接查询知识库获得答案
- ◆ q_3 需利用问答系统求解
 - (1) 提取 q_1 和 q_2 的上下文语义信息。
 - (2) 识别实体“七十八套餐”。
 - (3) 链接知识库，确定与该实体对应的子集，生成候选答案集矩阵。
 - (4) 计算候选答案中与问题相似度最高的实体。

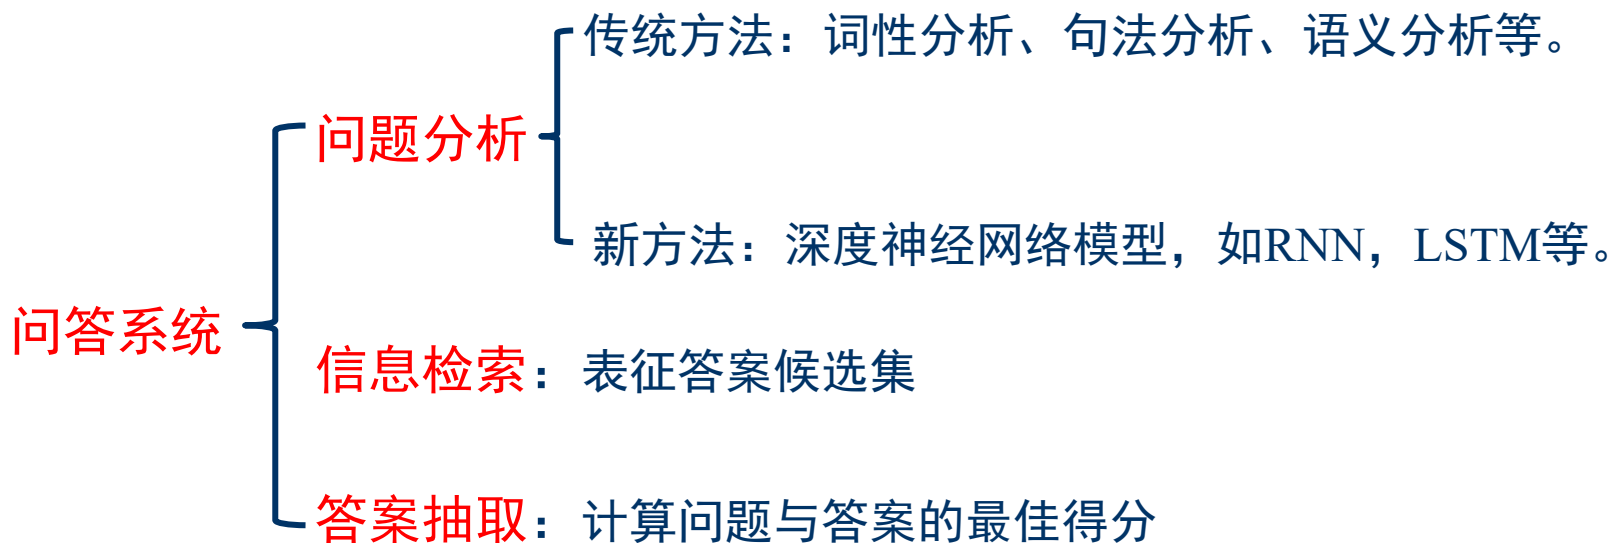


提纲

- ◆ 引例
- ◆ 问答系统的基本思想
- ◆ 循环神经网络
- ◆ 长短期记忆网络
- ◆ 基于LSTM的问答系统构建
- ◆ 总结

问答系统的基本思想

- ◆ **问答系统**（Question Answering System）是信息检索系统的一种高级形式，它通过理解用户意图和问题语义而获取相关的知识，通过推理计算得到答案并返回给用户。
- ◆ 问答系统主要由**问题分析**、**信息检索**和**答案抽取**三部分组成。




提纲

- ◆ 引例
- ◆ 问答系统的基本思想
- ◆ 循环神经网络
- ◆ 长短期记忆网络
- ◆ 基于LSTM的问答系统构建
- ◆ 总结

循环神经网络 (1)

◆ 循环神经网络 (Recurrent Neural Network, RNN)

RNN可对时序信息进行建模，包括输入层、输出层和隐藏层。



循环神经网络 (2)

◆ 模型结构

- (1) **输入层**：输入RNN的序列， \mathbf{X}_t 表示序列中时间步 t 的输入。
- (2) **隐藏层**：读取**当前时间步**的输入 \mathbf{X}_t 和**上一时间步**的隐藏变量 \mathbf{H}_{t-1} ，通过激活函数得到**当前时间步**的隐藏变量 \mathbf{H}_t ：

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

- (3) **输出层**：将 \mathbf{H}_t 经过权重参数和偏置参数计算得到输出 \mathbf{O}_t ：

$$\mathbf{O}_t = \mathbf{H}_t \mathbf{W}_{hq} + \mathbf{b}_q$$

循环神经网络 (3)

◆ 模型训练

RNN在训练时使用反向传播算法，设RNN的激活函数为 $\phi(x) = x$ ，用交叉熵（Cross-Entropy）损失函数定义时间步 t ($1 \leq t \leq T$) 的损失：

$$L(\mathbf{O}_t, \mathbf{y}_t) = -\mathbf{y}_t \log \mathbf{O}_t$$

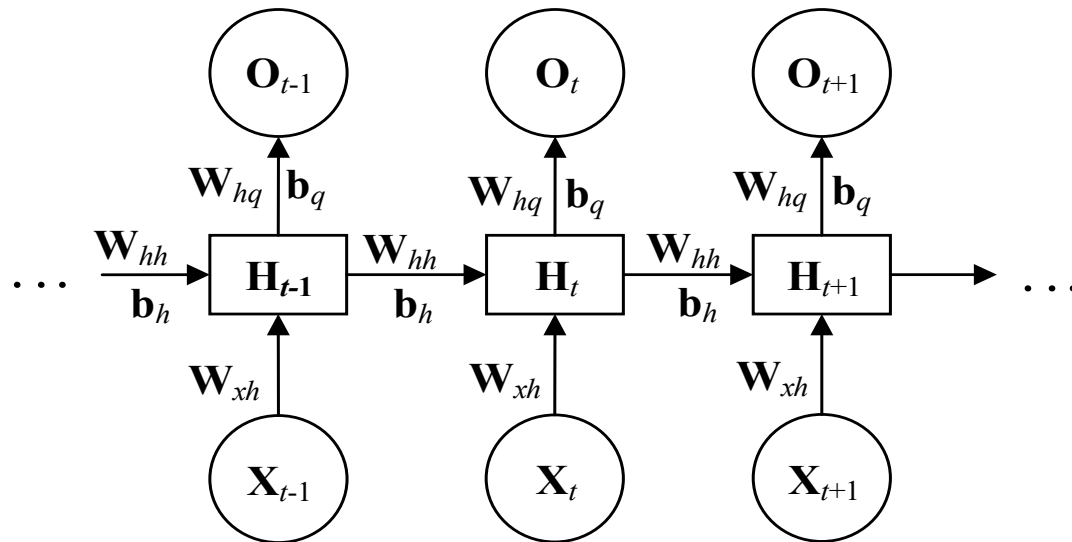
当时间步数为 T 时，模型的损失函数定义如下：

$$L = \frac{1}{T} \sum_{t=1}^T L(\mathbf{O}_t, \mathbf{y}_t)$$

循环神经网络 (4)

◆ 模型训练

RNN在训练过程中的参数包括 W_{xh} 、 W_{hh} 、 W_{hq} 、 b_h 和 b_q ，其变量和参数在训练时的依赖关系：



循环神经网络 (5)

◆ 模型训练

(1) 计算各时间步输出层变量 O_t 的梯度: $\frac{\partial L}{\partial \mathbf{O}_t} = \frac{\partial L(\mathbf{O}_t, \mathbf{y}_t)}{T \cdot \partial \mathbf{O}_t}$

(2) 计算隐藏变量 \mathbf{H}_t 的梯度

$$\frac{\partial L}{\partial \mathbf{H}_t} = \mathbf{W}_{hh}^{trans} \frac{\partial L}{\partial \mathbf{H}_{t+1}} + \mathbf{W}_{hq}^{trans} \frac{\partial L}{\partial \mathbf{O}_t} = \sum_{i=t}^{T-1} (\mathbf{W}_{hh}^{trans})^{T-i} \mathbf{W}_{hq}^{trans} \frac{\partial L}{\partial \mathbf{O}_{T+t-i}}$$

(3) 计算参数 \mathbf{W}_{hq} 和 \mathbf{b}_q 的梯度: $\frac{\partial L}{\partial \mathbf{W}_{hq}} = \sum_{t=1}^T \frac{\partial L}{\partial \mathbf{O}_t} \mathbf{H}_t^{trans}$, $\frac{\partial L}{\partial \mathbf{b}_q} = \sum_{t=1}^T \frac{\partial L}{\partial \mathbf{O}_t}$

(4) 计算参数 \mathbf{W}_{xh} 、 \mathbf{W}_{hh} 和 \mathbf{b}_h 的梯度:

损失 L 通过 $\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_T$ 依赖于参数 \mathbf{W}_{xh} 、 \mathbf{W}_{hh} 和 \mathbf{b}_h , 根据链式求导法则, 有:

$$\frac{\partial L}{\partial \mathbf{W}_{xh}} = \sum_{t=1}^T \frac{\partial L}{\partial \mathbf{H}_t} \mathbf{X}_t^{trans}, \quad \frac{\partial L}{\partial \mathbf{W}_{hh}} = \sum_{t=1}^T \frac{\partial L}{\partial \mathbf{H}_t} \mathbf{H}_{t-1}^{trans}, \quad \frac{\partial L}{\partial \mathbf{b}_h} = \sum_{t=1}^T \frac{\partial L}{\partial \mathbf{H}_t}$$

(5) 权重更新: 使用梯度下降法, 以目标的负梯度方向对参数进行更新:

$$\mathbf{W}_{hq} \leftarrow \mathbf{W}_{hq} - \eta \frac{\partial L}{\partial \mathbf{W}_{hq}}, \quad \mathbf{W}_{xh} \leftarrow \mathbf{W}_{xh} - \eta \frac{\partial L}{\partial \mathbf{W}_{xh}}, \quad \mathbf{W}_{hh} \leftarrow \mathbf{W}_{hh} - \eta \frac{\partial L}{\partial \mathbf{W}_{hh}}$$

$$\mathbf{b}_h \leftarrow \mathbf{b}_h - \eta \frac{\partial L}{\partial \mathbf{b}_h}, \quad \mathbf{b}_q \leftarrow \mathbf{b}_q - \eta \frac{\partial L}{\partial \mathbf{b}_q}$$

循环神经网络 (6)

◆ 训练算法

随机初始化网络的权重参数 W_{xh} 、 W_{hh} 和 W_{hq} ，使其均服从正态分布，初始化 $i=1$

While $i \leq n_{RNN}$ Do

For each $(X_t, y_t) \in D$ Do

由 $H_t = \varphi(X_t W_{xh} + H_{t-1} W_{hh} + b_h)$ 计算时间步 t 的隐藏变量 H_t

由 $O_t = H_t W_{hq} + b_q$ 计算时间步 t 的输出 O_t

由 $L(O_t, y_t) = -y_t \log O_t$ 计算时间步 t 的损失函数 $l(O_t, y_t)$

由 $L = \frac{1}{T} \sum_{t=1}^T L(O_t, y_t)$ 计算损失函数 $Loss$

由 $\frac{\partial L}{\partial O_t} = \frac{\partial L(O_t, y_t)}{T \cdot \partial O_t}$ 计算时间步 t 变量 O_t 的梯度 $\partial Loss / \partial O_t$

由 $\frac{\partial L}{\partial H_t} = W_{hh}^{trans} \frac{\partial L}{\partial H_{t+1}} + W_{hq}^{trans} \frac{\partial L}{\partial O_t} = \sum_{i=t}^{trans} (W_{hh}^{trans})^{T-i} W_{hq}^{trans} \frac{\partial L}{\partial O_{T+t-i}}$ 计算时间步 t 变量 H_t 的梯度 $\partial L / \partial H_t$

End For

由 $\frac{\partial L}{\partial W_{hq}} = \sum_{t=1}^T \frac{\partial L}{\partial O_t} H_t^{trans}$ 计算第 i 次迭代参数 W_{hq} 的梯度

由 $\frac{\partial L}{\partial b_q} = \sum_{t=1}^T \frac{\partial L}{\partial O_t}$ 计算第 i 次迭代参数 b_q 的梯度

由 $\frac{\partial L}{\partial W_{xh}} = \sum_{t=1}^T \frac{\partial L}{\partial H_t} X_t^{trans}$ 计算第 i 次迭代参数 W_{xh} 的梯度

由 $\frac{\partial L}{\partial W_{hh}} = \sum_{t=1}^T \frac{\partial L}{\partial H_t} H_{t-1}^{trans}$ 计算第 i 次迭代参数 W_{hh} 的梯度

由 $\frac{\partial L}{\partial b_h} = \sum_{t=1}^T \frac{\partial L}{\partial H_t}$ 计算第 i 次迭代参数 b_h 的梯度

由梯度 $\partial L / \partial W_{xh}$ 、 $\partial L / \partial W_{hh}$ 、 $\partial L / \partial W_{hq}$ 、 $\partial L / \partial b_h$ 和 $\partial L / \partial b_q$ ，更新参数 W_{hq} 、 W_{xh} 、 W_{hh} 、 b_h 和 b_q

End While

Return W_{xh} 、 W_{hh} 、 W_{hq} 、 b_h 和 b_q

时间复杂度：

$O(n_{RNN} T d^2 h)$

提纲

- ◆ 引例
- ◆ 问答系统的基本思想
- ◆ 循环神经网络
- ◆ 长短期记忆网络
- ◆ 基于LSTM的问答系统构建
- ◆ 总结

长短期记忆网络 (1)

- ◆ **长短期记忆网络 (Long Short-Term Memory, LSTM)**
- ✓ 当需处理长文档的提取问题与答案的表征时，传统的RNN具有“梯度爆炸”或“梯度消失”的局限性。
- ✓ LSTM运用门控机制，可很好地处理长序列之间的依赖关系。

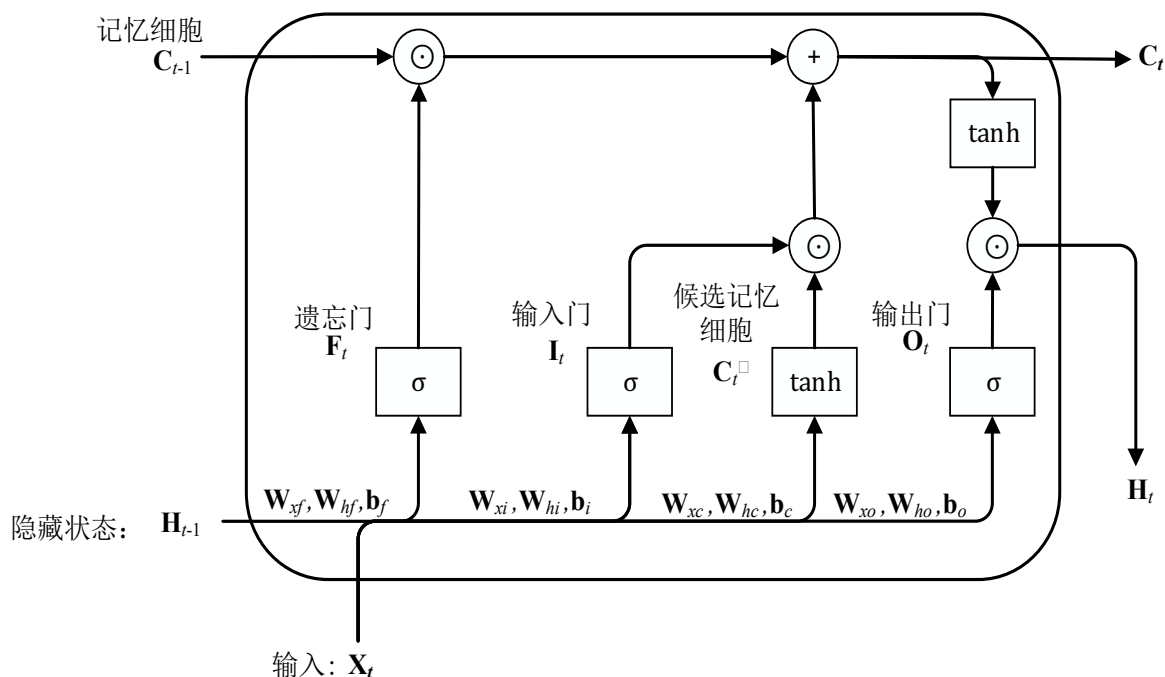
传统的RNN存在什么问题



长短期记忆网络 (2)

◆ 模型结构

LSTM引入遗忘门（Forget Gate）、输入门（Input Gate）、记忆细胞和输出门（Output Gate），记录额外信息，避免RNN梯度消失和梯度爆炸问题。



长短期记忆网络 (3)

◆ 模型结构

(1) **遗忘门**: LSTM根据遗忘门决定丢弃的信息。

读取时间步 $t-1$ 的输出 \mathbf{H}_{t-1} 和时间步 t 的输入 \mathbf{X}_t ，通过Sigmoid函数（记为 σ ）来计算遗忘门 \mathbf{F}_t ：

$$\mathbf{F}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xf} + \mathbf{H}_{t-1} \mathbf{W}_{hf} + \mathbf{b}_f)$$

(2) **输入门**: 通过 σ 决定值的更新。

$$\mathbf{I}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xi} + \mathbf{H}_{t-1} \mathbf{W}_{hi} + \mathbf{b}_i)$$

长短期记忆网络 (4)

◆ 模型结构

(3) 记忆细胞：由tanh函数创建新的候选值 \mathbf{C}_t' ，并将 \mathbf{C}_{t-1} 更新为 \mathbf{C}_t ：

$$\mathbf{C}_t' = \tanh(\mathbf{X}_t \mathbf{W}_{xc} + \mathbf{H}_{t-1} \mathbf{W}_{hc} + \mathbf{b}_c)$$

$$\mathbf{C}_t = \mathbf{F}_t \odot \mathbf{C}_{t-1} + \mathbf{I}_t \odot \mathbf{C}_t'$$

(4) 输出门：通过 σ 函数得到初始输出 \mathbf{O}_t ，通过tanh函数计算时间步 t 的隐藏变量 \mathbf{H}_t ：

$$\mathbf{O}_t = \sigma(\mathbf{X}_t \mathbf{W}_{xo} + \mathbf{H}_{t-1} \mathbf{W}_{ho} + \mathbf{b}_o)$$

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

长短期记忆网络 (5)

◆ 模型训练

(1) 计算 t 时刻的误差项 δ_t ，时间步 t 的隐藏变量为 \mathbf{H}_t ：

$$\delta_t = \frac{\partial L}{\partial \mathbf{H}_t}$$

为便于描述梯度计算方法，定义 $net_{f,t}$ 、 $net_{i,t}$ 、 $net_{c,t}$ 和 $net_{o,t}$ ：

$$net_{f,t} = X_t W_{xf} + H_{t-1} W_{hf} + b_f$$

$$net_{i,t} = X_t W_{xi} + H_{t-1} W_{hi} + b_i$$

$$net_{c,t} = X_t W_{xc} + H_{t-1} W_{hc} + b_c$$

$$net_{o,t} = X_t W_{xo} + H_{t-1} W_{ho} + b_o$$

长短期记忆网络 (6)

◆ 模型训练

(2) 计算梯度 $\partial L/\partial \mathbf{net}_{f,t}$ 、 $\partial L/\partial \mathbf{net}_{i,t}$ 、 $\partial L/\partial \mathbf{net}_{c,t}$ 和 $\partial L/\partial \mathbf{net}_{o,t}$:

$$\frac{\partial L}{\partial \mathbf{net}_{f,t}} = \delta_t^{trans} \odot \mathbf{O}_t \odot (\mathbf{1} - \tanh(\mathbf{C}_t)^2) \odot \mathbf{C}_{t-1} \odot \mathbf{F}_t(\mathbf{1} - \mathbf{F}_t)$$

$$\frac{\partial L}{\partial \mathbf{net}_{i,t}} = \delta_t^{trans} \odot \mathbf{O}_t \odot (\mathbf{1} - \tanh(\mathbf{C}_t)^2) \odot \mathbf{C}'_t \odot \mathbf{I}_t(\mathbf{1} - \mathbf{I}_t)$$

$$\frac{\partial L}{\partial \mathbf{net}_{c,t}} = \delta_t^{trans} \odot \mathbf{O}_t \odot (\mathbf{1} - \tanh(\mathbf{C}_t)^2) \odot \mathbf{I}_t(\mathbf{1} - (\mathbf{C}'_t)^2)$$

$$\frac{\partial L}{\partial \mathbf{net}_{o,t}} = \delta_t^{trans} \odot \tanh(\mathbf{C}_t) \odot \mathbf{O}_t(\mathbf{1} - \mathbf{O}_t)$$

长短期记忆网络 (7)

◆ 模型训练

(3) 将各个时间步的梯度进行累加，得到 \mathbf{W}_{hf} 、 \mathbf{W}_{hi} 、 \mathbf{W}_{hc} 和 \mathbf{W}_{ho} 的梯度：

$$\frac{\partial L}{\partial \mathbf{W}_{hf}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{f,t}} \mathbf{H}_{t-1}^{\text{trans}}, \quad \frac{\partial L}{\partial \mathbf{W}_{hi}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{i,t}} \mathbf{H}_{t-1}^{\text{trans}}$$
$$\frac{\partial L}{\partial \mathbf{W}_{hc}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{c,t}} \mathbf{H}_{t-1}^{\text{trans}}, \quad \frac{\partial L}{\partial \mathbf{W}_{ho}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{o,t}} \mathbf{H}_{t-1}^{\text{trans}}$$

(4) 将各时刻的梯度进行累加，得到 \mathbf{b}_f 、 \mathbf{b}_i 、 \mathbf{b}_c 和 \mathbf{b}_o 的梯度：

$$\frac{\partial L}{\partial \mathbf{b}_f} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{f,t}}, \quad \frac{\partial L}{\partial \mathbf{b}_i} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{i,t}}$$
$$\frac{\partial L}{\partial \mathbf{b}_c} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{c,t}}, \quad \frac{\partial L}{\partial \mathbf{b}_o} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{o,t}}$$

(5) 计算 \mathbf{W}_{xf} 、 \mathbf{W}_{xi} 、 \mathbf{W}_{xc} 和 \mathbf{W}_{xo} 的梯度：

$$\frac{\partial L}{\partial \mathbf{W}_{xf}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{f,t}} \mathbf{X}_t^{\text{trans}}, \quad \frac{\partial L}{\partial \mathbf{W}_{xi}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{i,t}} \mathbf{X}_t^{\text{trans}}$$
$$\frac{\partial L}{\partial \mathbf{W}_{xc}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{c,t}} \mathbf{X}_t^{\text{trans}}, \quad \frac{\partial L}{\partial \mathbf{W}_{xo}} = \sum_{t=1}^T \frac{\partial L}{\partial \text{net}_{o,t}} \mathbf{X}_t^{\text{trans}}$$

长短期记忆网络 (8)

◆ 模型训练

(6) 使用梯度下降法, 给定学习率 $\eta(0 < \eta < 1)$, 以目标的负梯度方向调整参数, 更新权重矩阵和偏置:

$$\mathbf{W}_{hf} \leftarrow \mathbf{W}_{hf} - \eta \frac{\partial L}{\partial \mathbf{W}_{hf}}$$

$$\mathbf{W}_{hi} \leftarrow \mathbf{W}_{hi} - \eta \frac{\partial L}{\partial \mathbf{W}_{hi}}$$

$$\mathbf{W}_{hc} \leftarrow \mathbf{W}_{hc} - \eta \frac{\partial L}{\partial \mathbf{W}_{hc}}$$

$$\mathbf{W}_{ho} \leftarrow \mathbf{W}_{ho} - \eta \frac{\partial L}{\partial \mathbf{W}_{ho}}$$

$$\mathbf{W}_{xf} \leftarrow \mathbf{W}_{xf} - \eta \frac{\partial L}{\partial \mathbf{W}_{xf}}$$

$$\mathbf{W}_{xi} \leftarrow \mathbf{W}_{xi} - \eta \frac{\partial L}{\partial \mathbf{W}_{xi}}$$

$$\mathbf{W}_{xc} \leftarrow \mathbf{W}_{xc} - \eta \frac{\partial L}{\partial \mathbf{W}_{xc}}$$

$$\mathbf{W}_{xo} \leftarrow \mathbf{W}_{xo} - \eta \frac{\partial L}{\partial \mathbf{W}_{xo}}$$

$$\mathbf{b}_f \leftarrow \mathbf{b}_f - \eta \frac{\partial L}{\partial \mathbf{b}_f}$$

$$\mathbf{b}_i \leftarrow \mathbf{b}_i - \eta \frac{\partial L}{\partial \mathbf{b}_i}$$

$$\mathbf{b}_c \leftarrow \mathbf{b}_c - \eta \frac{\partial L}{\partial \mathbf{b}_c}$$

$$\mathbf{b}_o \leftarrow \mathbf{b}_o - \eta \frac{\partial L}{\partial \mathbf{b}_o}$$

长短期记忆网络 (9)

◆ LSTM训练算法

随机初始化网络的权重参数 W_{hf} 、 W_{hi} 、 W_{hc} 、 W_{ho} 、 W_{xf} 、 W_{xi} 、 W_{xc} 、 W_{xo} 、 b_f 、 b_i 、 b_c 和 b_o ，使其均服从正态分布，初始化 $i=1$

While $i \leq n_{LSTM}$ Do

For each $(X_t, y_t) \in D$ Do

由 $F_t = \sigma(X_t W_{xf} + H_{t-1} W_{hf} + b_f)$ 计算时间步 t 的遗忘门 F_t

由 $I_t = \sigma(X_t W_{xi} + H_{t-1} W_{hi} + b_i)$ 计算时间步 t 的输入门 I_t

由 $C_t' = \tanh(X_t W_{xc} + H_{t-1} W_{hc} + b_c)$ 计算时间步 t 的候选记忆细胞 C_t'

由 $C_t = F_t \odot C_{t-1} + I_t \odot C_t'$ 计算时间步 t 的记忆细胞 C_t

由 $O_t = \sigma(X_t W_{xo} + H_{t-1} W_{ho} + b_o)$ 计算时间步 t 的输出 O_t

由 $H_t = O_t \odot \tanh(C_t)$ 计算时间步 t 的隐藏变量 H_t

计算时间步 t 的损失函数 $L(O_t, y_t)$ 与损失函数 L

由 $\delta_t = \frac{\partial L}{\partial H_t}$ 计算时间步 t 的隐藏变量误差项 δ_t

计算时间步 t 的梯度 $\partial L / \partial net_{f,t}$ 、 $\partial L / \partial net_{i,t}$ 、 $\partial L / \partial net_{c,t}$ 和 $\partial L / \partial net_{o,t}$

End For

计算第 i 次迭代时权重矩阵 W_{hf} 、 W_{hi} 、 W_{hc} 、 W_{ho} 、 W_{xf} 、 W_{xi} 、 W_{xc} 、 W_{xo} 和偏置 b_f 、 b_i 、 b_c 、 b_o 的梯度

更新权重矩阵 W_{hf} 、 W_{hi} 、 W_{hc} 、 W_{ho} 、 W_{xf} 、 W_{xi} 、 W_{xc} 和 W_{xo}

更新偏置 b_f 、 b_i 、 b_c 和 b_o

End While

Return W_{hf} 、 W_{hi} 、 W_{hc} 、 W_{ho} 、 W_{xf} 、 W_{xi} 、 W_{xc} 、 W_{xo} 、 b_f 、 b_i 、 b_c 、 b_o

时间复杂度：

$O(n_{LSTM} T d^2 h^5)$

长短期记忆网络 (10)

- ◆ 例：问答对 q = “世界最高峰”、 a = “珠穆朗玛峰”，LSTM提取文本序列特征的过程如下：

(1) 转为词向量，记 $\mathbf{q}' = (\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_5)$ ， $\mathbf{a}' = (\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_5)$ 。



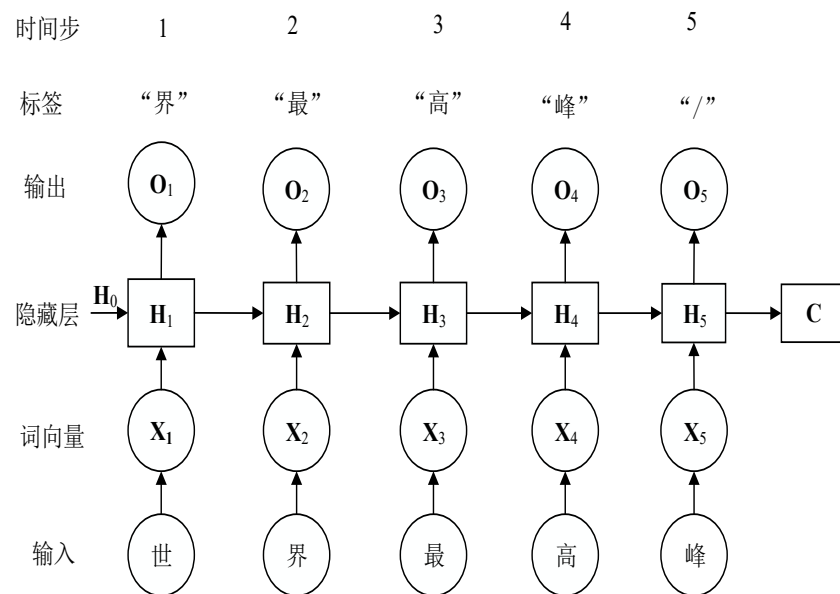
(2) 将 $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_5$ 输入LSTM，得到词典 E 中词的概率分布。



(3) 计算背景向量 $\mathbf{C} = \mathbf{H}_5$ ，包含序列“世，界，最，高，峰”的信息。



(4) 重复 (2) ~ (3) 步，得到 \mathbf{C}' ，即“珠，穆，朗，玛，峰”的信息。



提纲

- ◆ 引例
- ◆ 问答系统的基本思想
- ◆ 循环神经网络
- ◆ 长短期记忆网络
- ◆ 基于LSTM的问答系统构建
- ◆ 总结

基于LSTM的问答系统构建 (1)

◆ 基于LSTM构建问答系统的总体思路

(1) 分析问题：链接知识库生成候选答案集。



(2) 利用LSTM表征问题和答案。



(3) 训练模型，使得问题与正确答案的表征向量相似度得分最高。

如何利用LSTM构建问答系统



基于LSTM的问答系统构建 (2)

◆ 基于LSTM的问答系统构建算法

- 输入:

$D_{qa} = \{(q_i, a_i)\}_{i=1}^N$: 训练数据集, q : 用户提出的问题, G : 知识图谱

- 输出:

a : 问答系统的答案

- 步骤:

1. 由 $\arg \max_{\theta_1, \theta_2} \frac{1}{N} \sum_{i=1}^N \log(\sum_{y \in V(G)} P_{\theta_1}(y|q_i) P_{\theta_2}(a_i|y, q_i))$ 学习参数 θ_1 和 θ_2

2. 由 $P_{\theta_1}(y|q) = \text{Softmax}(W_y' M_q) = \frac{\exp(W_y' M_q)}{\sum_{y' \in V(G)} \exp(W_{y'}' M_q)}$ 计算 G 中实体是 q 对应主题实体的概率, 选取概率最大的实体 y_{tp} 为主题实体

3. 对 y_{tp} 邻域2跳以内的所有实体 $A_y = \{a_1, a_2, \dots, a_m\}$ 进行拓扑排序, 得到一个有序节点的子图, 进而构造推理子图 G_y

4. 由 $(G_{y \rightarrow a}) = \frac{1}{\#Parent(a)} \sum_{a_j \in Parent(a), (a_j, r, a) \text{ or } (a, r, a_j) \in G_y} \tau(V \times [g(G_{y \rightarrow a}), \vec{e}_r])$ 计算 y_{tp} 的推理子图 G_y 中任一实体的向量表示, 记为 $g(G_{y \rightarrow y_{tp}})$

5. $a \leftarrow \operatorname{argmax}_a (P_{\theta_2}(a|y, q))$ // 计算 G_y 中的每个实体是答案的概率, 选取概率最大时的实体作为答案

6. Return a

基于LSTM的问答系统构建 (3)

◆ 基于LSTM构建问答系统的主要步骤

(1) 通过训练集 $D_{qa} = \{(q_i, a_i)\}_{i=1}^N$ ，学习参数 θ_1 和 θ_2 ：

$$\arg \max_{\theta_1, \theta_2} \frac{1}{N} \sum_{i=1}^N \log(\sum_{y \in V(G)} P_{\theta_1}(y|q_i) P_{\theta_2}(a_i|y, q_i))$$

(2) 在已有知识图谱中寻找问题对应的主题实体：

① 利用LSTM学习问题 q 的表征，将 q 映射到 d 维实值向量空间 \mathbb{R}^d ，记为 $\mathbf{M}_q \in \mathbb{R}^d$ 。

② 利用TransE算法将知识图谱 G 中的每个实体映射到低维向量空间，记为 \mathbf{M}_G 。

③ 使用以下方法计算 G 中实体作为问题 q 主题实体的概率：

$$P_{\theta_1}(y|q) = \text{Softmax}(\mathbf{W}'_y \mathbf{M}_q) = \frac{\exp(\mathbf{W}'_y \mathbf{M}_q)}{\sum_{y' \in V(G)} \exp(\mathbf{W}'_{y'} \mathbf{M}_q)}$$

④ 当 $P_{\theta_1}(y|q)$ 概率最大时，则对应实体为 G 中对应主题实体，即 $\arg \max_y (P_{\theta_1}(y|q))$ 。

基于LSTM的问答系统构建 (4)

◆ 基于LSTM构建问答系统的主要步骤

(3) 利用主题实体构造推理子图:

设 y_{tp} 为主题实体, 对 G 中 y_{tp} 邻域内的所有实体 $A_y = \{a_1, a_2, \dots, a_m\}$ 进行拓扑排序, 得到 G_y , 即为针对 y_{tp} 的推理子图。

(4) 计算从主题实体对应的推理子图向量表示:

对于推理子图中的任一实体 a , 基于 a 的父节点向量表示来计算 a 的推理子图的向量表示:

$$(G_{y \rightarrow a}) = \frac{1}{\#Parent(a)} \sum_{a_j \in Parent(a), (a_j, r, a) \text{ or } (a, r, a_j) \in G_y} \tau(\mathbf{V} \times [\mathbf{g}(G_{y \rightarrow a}), \bar{\mathbf{e}}_r])$$

唯一递归返回条件:

$$y = a \text{ 时, } \mathbf{g}(G_{y \rightarrow a}) = \bar{\mathbf{0}}$$

基于LSTM的问答系统构建 (5)

◆ 基于LSTM构建问答系统的主要步骤

(5) 计算推理子图中每个实体作为答案的概率:

$$P_{\theta_2}(a|y, q) = \text{Softmax}\left(\mathbf{M}_q' \mathbf{g}(G_{y \rightarrow a})\right) = \frac{\exp(\mathbf{M}_q' \mathbf{g}(G_{y \rightarrow a}))}{\sum_{a' \in V(G_y)} \exp(\mathbf{M}_q' \mathbf{g}(G_{y \rightarrow a'}))}$$

当 $P_{\theta_2}(a|y, q)$ 达到最大值时, 对应实体 a 即为问题 q 的答案 $\text{argmax}_a P_{\theta_2}(a|y, q)$ 。

基于LSTM的问答系统构建 (5)

◆ 基于LSTM的问答系统构建示例

设长序列复杂问题 q 为“在遥远的东方有个国家叫做中国，美丽富饶、山川壮丽，其最高的山峰叫什么？”。执行过程：

(1) 使用LSTM对问题编码，得到问题的编码矩阵。



(2) 计算 G 中每个实体为 q 的主题实体的概率。

若 y 表示“中国”时， $P_{\theta_1}(y|q) = 0.9273$ ，且此时概率最大，则问题 q 的主题实体为“中国”。



(3) 从主题实体“中国”开始，在 G 中选取邻域2跳以内的所有实体进行拓扑排序，得到如图所示的推理子图（不包含图中实体旁的数字）。

基于LSTM的问答系统构建 (7)

(4) 由实体“中国”对应的推理子图中任一实体的向量表示，计算推理子图中的实体为最终答案的概率。



(5) 计算推理子图中每个实体是问题 q 所对应答案的概率，**最大值对应实体**为问题的最终答案。

实体“珠穆朗玛峰”对应的 $P_{\theta_2}(a|y, q)$ 最大，则问题最终答案为“珠穆朗玛峰”。

提纲

- ◆ 引例
- ◆ 问答系统的基本思想
- ◆ 循环神经网络
- ◆ 长短期记忆网络
- ◆ 基于LSTM的问答系统构建
- ◆ 总结

总结

- ◆ 问答系统任务的主要思想
- ◆ 问答系统任务的特殊性
 - 与检索系统性质的区别
 - 主要的输入数据源
- ◆ 面向问答系统的深度学习算法的特点
 - 深度学习在问答系统中起到的关键性作用
- ◆ 基于LSTM的问答系统构建
 - 基于LSTM构建问答系统的算法及主要步骤
 - 基于LSTM算法构建问答系统的优势



结语

谢谢！