


# BI-LSTM-CRF

## 网络结构图



## 线性CRF

设  $X = [x_1, x_2, \dots, x_n]$ ,  $Y = [y_1, y_2, \dots, y_n]$  均为线性链表示的随机变量序列，若在给定随机变量序列  $X$  的条件下，随机变量序列  $Y$  的条件概率分布  $P(Y|X)$  构成条件随机场，即满足马尔可夫性：

- $P(y_i|X, y_1, \dots, y_{i-1}, y_{i+1}, \dots, y_n) = P(y_i|X, y_{i-1}, y_{i+1}), i = 1, 2, \dots, n$  (在  $i = 1$  和  $n$  的时候只考虑单边)

## 发射分数和转移分数

令  $X$  为输入变量， $Y$  代表相应的标签序列

其中，每个输入  $x_i$  均对应着一个标签  $y_i$ ，这一步对应的为**发射分数**，指示了当前的输入应该对应什么样的标签。在每个标签  $y_i$  之间也存在着连线，它表示的是当前位置的标签  $y_i$  向下一个位置标签  $y_{i+1}$  的一种转移。

## 发射分数




图3 发射分数的矩阵计算解释

给定文本序列  $x = [x_1, x_2, x_3, \dots, x_n]$  映射为对应词向量之后，得到一个  $(n \times embedding\_shape)$  的词向量矩阵 **embs**

随后将 **embs** 传入 BiLSTM，每个词的位置都会产生一个上下文向量，所有的向量组合后会得到向量矩阵 **context\_vector**，其中每行代表对应单词经过 BiLSTM 后的上下文向量。

- **上下文向量**：可以指导当前位置应该输出的标签信息。
  - 问题：一般输出向量的维度并不等于标签的数量，不能直接用来指示输出什么标签。
    - 一般的做法是在后边加一层线性层，将**上下文向量**的维度映射为标签的数量，最终指导标签的输出。
  - $y = XW + b, X \in \mathbb{R}^{n \times \text{context\_size}}, W \in \mathbb{R}^{\text{context\_size} \times \text{tag\_size}}$

## 转移分数

转移分数表示一个标签向另一个标签转移的分数，分数越高，转移概率就越大。

|                | B-Person | I-Person | B-Organization | I-Organization | O    |
|----------------|----------|----------|----------------|----------------|------|
| B-Person       | 0.37     | 0.49     | 0.35           | 0.38           | 0.64 |
| I-Person       | 0.93     | 0.71     | 0.07           | 0.01           | 0.11 |
| B-Organization | 0.25     | 0.54     | 0.16           | 0.69           | 0.83 |
| I-Organization | 0.02     | 0.08     | 0.86           | 0.95           | 0.02 |
| O              | 0.65     | 0.66     | 0.78           | 0.83           | 0.91 |

图4 转移分数矩阵图

为CRF中一个可学习的参数矩阵，可以显示的建模标签之间的转移关系。

## 损失函数

每个 $x_i$ 都对应了一个发射分数向量，向量的维度即为标签数量。

期待解码为标签序列 $y = [y_0, y_1, y_2, \dots, y_n]$ ，形式化为对应的条件概率公式如下：

$$(y|x) = P(y_0, y_1, \dots, y_n | x_0, x_1, \dots, x_n)$$

假设标签数量为 $k$ ，序列长度为 $n$ ，一共有 $N = k^n$ 条路径。

记 $S_i$ 为第 $i$ 条路径的分数，则某一特定标签序列出现的概率为

$$P(S_i) = \frac{e^{S_i}}{\sum_j^N e^{S_j}}$$

若有GT的路径，期待CRF解码出这一条序列，则出现的概率记为

$$P(S_{\text{GT}}) = \frac{e^{S_{\text{GT}}}}{\sum_j^N e^{S_j}}$$

为了方便求解，将损失放入log空间进行求解，因为log函数本身**单调递增**，不影响迭代优化损失函数

$$\begin{aligned}
 \text{loss} &= -\log \frac{e^{S_{\text{GT}}}}{\sum_j^N e^{S_j}} \\
 &= -\left( \log(e^{S_{\text{GT}}}) - \log\left(\sum_j^N e^{S_j}\right) \right) \\
 &= \log\left(\sum_j^N e^{S_j}\right) - \log(e^{S_{\text{GT}}}) \\
 &= \log(e^{S_1} + e^{S_2} + \dots + e^{S_N}) - S_{\text{GT}}
 \end{aligned}$$

**损失函数包含两部分，单条真实路径分数 $S_{\text{GT}}$ ，归一化项，所有路径分数的 $\log\_sum\_exp$**

## 全部路径的分数计算(前向算法)

全部路径的和, 需要计算  $N = k^n$  条路径, 指数级别的计算复杂度不可被接受。

**动态规划DP: 将所有的路径的和 拆解为 路径上 每个位置的和 进行计算**

计算目标:  $\log(e^{S_1} + e^{S_2} + \dots + e^{S_N})$

记变量

- $\text{emmission}_i = [x_{i0} \ x_{i1} \ \dots \ x_{ik}]$  为  $i$  位置对于  $k$  个标签的发射分数
- $\text{trans} = \begin{bmatrix} t_{00} & t_{01} & \dots & t_{0k} \\ t_{10} & t_{11} & \dots & t_{1k} \\ \vdots & \vdots & \ddots & \vdots \\ t_{k0} & t_{k1} & \dots & t_{kk} \end{bmatrix}$  为转移矩阵,  $t_{ij}$  代表由  $\text{Tag } j \rightarrow \text{Tag } i$  的分数
- $\text{dp}_i = [s_{i0} \ s_{i1} \ \dots \ s_{ik}]$ ,  $s_{ij}$  代表在第  $i$  次迭代计算到  $i$  位置时, 以  $j$  标签结尾的路径分数之和。

## 迭代过程

### 1. 截止 $x_0$ 位置

- $\text{emmission}_0 = [x_{00} \ x_{01} \ \dots \ x_{0k}]$
- $\text{dp}_0 = [x_{00} \ x_{01} \ \dots \ x_{0k}]$  (因为是序列的开始部分)
- 则截止  $x_0$ , 将  $x_0$  标签的分数累计作为所有路径的分数为:
  - $\text{Total}_0 = \log(e^{x_{00}} + e^{x_{01}} + \dots + e^{x_{0k}})$

### 2. 截止 $x_1$ 位置 将emission和dp向量expand为矩阵, 使用矩阵的方法去计算各个位置的累计值

$$\text{emission}_1 = \begin{bmatrix} x_{10} & x_{10} & \dots & x_{10} \\ x_{11} & x_{11} & \dots & x_{11} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1k} & x_{1k} & \dots & x_{1k} \end{bmatrix}_{k \times k} \quad (\text{列扩展})$$

$$\text{dp}_0 = \begin{bmatrix} x_{00} & x_{01} & \dots & x_{0k} \\ x_{00} & x_{01} & \dots & x_{0k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{00} & x_{01} & \dots & x_{0k} \end{bmatrix}_{k \times k} \quad (\text{行扩展})$$

◦ 计算过程:

$$\begin{aligned} \text{scores} &= \text{dp}_0 + \text{trans} + \text{emission}_1 \\ &= \begin{bmatrix} x_{00} & x_{01} & \dots & x_{0k} \\ x_{00} & x_{01} & \dots & x_{0k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{00} & x_{01} & \dots & x_{0k} \end{bmatrix} + \begin{bmatrix} t_{00} & t_{01} & \dots & t_{0k} \\ t_{10} & t_{11} & \dots & t_{1k} \\ \vdots & \vdots & \ddots & \vdots \\ t_{k0} & t_{k1} & \dots & t_{kk} \end{bmatrix} + \begin{bmatrix} x_{10} & x_{10} & \dots & x_{10} \\ x_{11} & x_{11} & \dots & x_{11} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1k} & x_{1k} & \dots & x_{1k} \end{bmatrix} \\ &= \begin{bmatrix} x_{00} + t_{00} + x_{10} & x_{01} + t_{01} + x_{10} & \dots & x_{0k} + t_{0k} + x_{10} \\ x_{00} + t_{10} + x_{11} & x_{01} + t_{11} + x_{11} & \dots & x_{0k} + t_{1k} + x_{11} \\ \vdots & \vdots & \ddots & \vdots \\ x_{00} + t_{k0} + x_{1k} & x_{01} + t_{k1} + x_{1k} & \dots & x_{0k} + t_{kk} + x_{1k} \end{bmatrix} \end{aligned}$$

◦ 如  $x_{0k} + t_{1k} + x_{11}$  就是  $x_{0k}$  (0时刻以Tag k结尾), 通过  $t_{1k}$  ( $k \rightarrow 1$ ) 转移到  $x_{11}$  (1时刻以Tag 1结尾)

◦ 最后可以得到路径累计分数

$$\begin{aligned} \text{dp}_1 &= [\log(e^{\text{score}_{00}} + \dots + e^{\text{score}_{0k}}) \ \dots \ \log(e^{\text{score}_{k0}} + \dots + e^{\text{score}_{kk}})] \\ &= [\log(e^{x_{00} + t_{00} + x_{10}} + \dots + e^{x_{0k} + t_{0k} + x_{10}}) \ \dots \ \log(e^{x_{00} + t_{k0} + x_{1k}} + \dots + e^{x_{0k} + t_{kk} + x_{1k}})] \end{aligned}$$

◦ 则截止  $x_1$  所有的路径和:

$$\begin{aligned}
\text{total}_1 &= \log(e^{\text{dp}_1[0]} + \dots + e^{\text{dp}_1[k]}) \\
&= \log(e^{\log(e^{x_{00}+t_{00}+x_{10}} + \dots + e^{x_{0k}+t_{0k}+x_{10}})} + \dots + e^{\log(e^{x_{00}+t_{k0}+x_{1k}} + \dots + e^{x_{0k}+t_{kk}+x_{1k}})}) \\
&= \log((e^{x_{00}+t_{00}+x_{10}} + \dots + e^{x_{0k}+t_{0k}+x_{10}}) + \dots + (e^{x_{00}+t_{k0}+x_{1k}} + \dots + e^{x_{0k}+t_{kk}+x_{1k}}))
\end{aligned}$$

3. 以此递推即可，时间复杂度 $O(nk^2)$ （转移 $k^2$ ，链长为 $n$ ）

## 维特比解码

训练的要素：CRF损失函数，单条路径分数的计算，全部路径分数（归一化因子）已经齐全了，可以进行BiLSTM+CRF的训练。

最终Inference的时候，需要有从全部路径中查询最优路径的过程，使用Viterbi算法。

记变量：

- $\text{emmission}_i = [x_{i0} \ x_{i1} \ \dots \ x_{ik}]$  为 $i$ 位置对于 $k$ 个标签的发射分数
- $\text{trans} = \begin{bmatrix} t_{00} & t_{01} & \dots & t_{0k} \\ t_{10} & t_{11} & \dots & t_{1k} \\ \vdots & \vdots & \ddots & \vdots \\ t_{k0} & t_{k1} & \dots & t_{kk} \end{bmatrix}$  为转移矩阵， $t_{ij}$ 代表由Tag  $j \rightarrow$  Tag  $i$ 的分数
- $\text{dp}_i = [s_{i0} \ s_{i1} \ \dots \ s_{ik}]$ ， $s_{ij}$ 代表在第 $i$ 次迭代计算到 $i$ 位置时，以 $j$ 标签结尾的路径中，得分最高的路径的具体得分。
- $\text{beta}_i = [p_{i0} \ p_{i1} \ \dots \ p_{ik}]$ ， $p_{ij}$ 代表在第 $i$ 次迭代计算到 $i$ 位置时，以 $j$ 标签结尾的路径中，得分最高的路径在前一个位置 $i-1$ 处的标签索引。

## 迭代过程

### 1. 截止 $x_0$ 位置

- $\text{emmission}_0 = [x_{00} \ x_{01} \ \dots \ x_{0k}]$
- $\text{dp}_0 = [x_{00} \ x_{01} \ \dots \ x_{0k}]$ （因为是序列的开始部分）
- $\text{beta}_0 = [-1, -1, \dots, -1]$ （因为起始边前面没有任何路径，用 $-1$ 来初始化）

### 2. 截止 $x_1$ 位置 矩阵扩展的位置很类似于前向算法，不再写一遍了

- 计算过程：

$$\begin{aligned}
\text{scores} &= \text{dp}_0 + \text{trans} + \text{emmission}_1 \\
&= \begin{bmatrix} x_{00} & x_{01} & \dots & x_{0k} \\ x_{00} & x_{01} & \dots & x_{0k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{00} & x_{01} & \dots & x_{0k} \end{bmatrix} + \begin{bmatrix} t_{00} & t_{01} & \dots & t_{0k} \\ t_{10} & t_{11} & \dots & t_{1k} \\ \vdots & \vdots & \ddots & \vdots \\ t_{k0} & t_{k1} & \dots & t_{kk} \end{bmatrix} + \begin{bmatrix} x_{10} & x_{10} & \dots & x_{10} \\ x_{11} & x_{11} & \dots & x_{11} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1k} & x_{1k} & \dots & x_{1k} \end{bmatrix} \\
&= \begin{bmatrix} x_{00} + t_{00} + x_{10} & x_{01} + t_{01} + x_{10} & \dots & x_{0k} + t_{0k} + x_{10} \\ x_{00} + t_{10} + x_{11} & x_{01} + t_{11} + x_{11} & \dots & x_{0k} + t_{1k} + x_{11} \\ \vdots & \vdots & \ddots & \vdots \\ x_{00} + t_{k0} + x_{1k} & x_{01} + t_{k1} + x_{1k} & \dots & x_{0k} + t_{kk} + x_{1k} \end{bmatrix}
\end{aligned}$$

- 得到路径最大分数：

$$\begin{aligned}
\text{dp}_1 &= [\max(\text{score}_{00}, \dots, \text{score}_{0k}) \ \dots \ \max(\text{score}_{k0}, \dots, \text{score}_{kk})] \\
&= [\max(x_{00} + t_{00} + x_{10}, \dots, x_{0k} + t_{0k} + x_{10}) \ \dots \ \max(x_{00} + t_{k0} + x_{1k}, \dots, x_{0k} + t_{kk} + x_{1k})]
\end{aligned}$$

- 根据max中的计算结果，可以填写记录 $\text{beta}_1$ 的值

3. 以此递推即可，时间复杂度 $O(nk^2)$ （转移 $k^2$ ，链长为 $n$ ），最终结果应该可以从 $\text{beta}$ 矩阵中回溯。