

---

# 6. 深度学习用于序列处理

---

WU Xiaokun 吴晓堃

xkun.wu [at] gmail

2021/05/17

# 本章内容

处理文本数据。理解循环神经网络。循环神经网络的高级用法。用卷积神经网络处理序列。

**重点：**使用预训练的词嵌入、使用LSTM层和GRU层、使用一维卷积神经网络；

**难点：**分析不同循环神经网络的适用条件、提高循环神经网络的性能和泛化能力。

# 学习目标


- 理解并掌握处理文本数据的两种主要方法：one-hot 编码、词嵌入；
- 理解并掌握简单循环神经网络（RNN）、LSTM 层和 GRU 层的工作原理；
- 理解并掌握提高循环神经网络的性能和泛化能力的三种高级技巧：循环 dropout 降低过拟合、堆叠循环层提高网络的表示能力、双向循环层提高精度并缓解遗忘问题；
- 理解并掌握一维卷积神经网络的使用方法。

# 文本向量化

## 词元 (token)

将文本分解而成的单元（单词、字符或 n-gram）。

```
from keras.preprocessing.text import  
    Tokenizer  
  
samples = ['...', '...', ...]  
  
tokenizer = Tokenizer(num_words=1000)  
tokenizer.fit_on_texts(samples)  
  
one hot encode =
```




# 词元的向量编码

## 两种主要方法

- one-hot 编码：高维稀疏表示，即散列；硬编码得到；
- 词元嵌入：低维密集表示，从数据中学习得到。



one-hot词向量：  
- 稀疏  
- 高维  
- 硬编码




词嵌入：  
- 密集  
- 低维  
- 从数据中学习得到

# 学习词嵌入

## 几何关系表示语义关系

- 距离：与语义关系远近正相关；
- 方向：同类别在相近方向上聚集。



## 从数据中学习词嵌入

```
from keras.layers import  
    Embedding  
  
model.add(Embedding(1000, 64,  
    input_length=maxlen))
```

## 使用预训练的词嵌入


```
model.layers[0].set_weights(  
  
model.layers[0].trainable =  
    False
```

# 循环网络 (RNN)

前馈网络 (feedforward network) 的问题：没有记忆。

## 具有内部环的网络架构


- 循环结构：遍历所有序列元素；
- 存储状态：包含与已查看内容相关的信息。



# RNN的简单表述：循环展开

## 时间步函数


```
output~t~ = np.tanh(np.dot(W, input~t~) + np.dot(U, state~t~) + b)
```





# 长短期记忆 (LSTM)

## 长期记忆

- 解决遗忘问题：深层网络会出现梯度消失 (vanishing gradient) 现象；
- 长期携带信息：跨越多个时间步。



# LSTM：计算新的携带信息



# 向量序列的二分类：LSTM示例

```
from keras import models, layers

model = models.Sequential()
model.add(layers.LSTM(32, return_sequences=True, input_shape=
    (num_timesteps, num_features)))
model.add(layers.LSTM(32, return_sequences=True))
model.add(layers.LSTM(32))
model.add(layers.Dense(num_classes, activation='sigmoid'))
```

# 一维卷积

