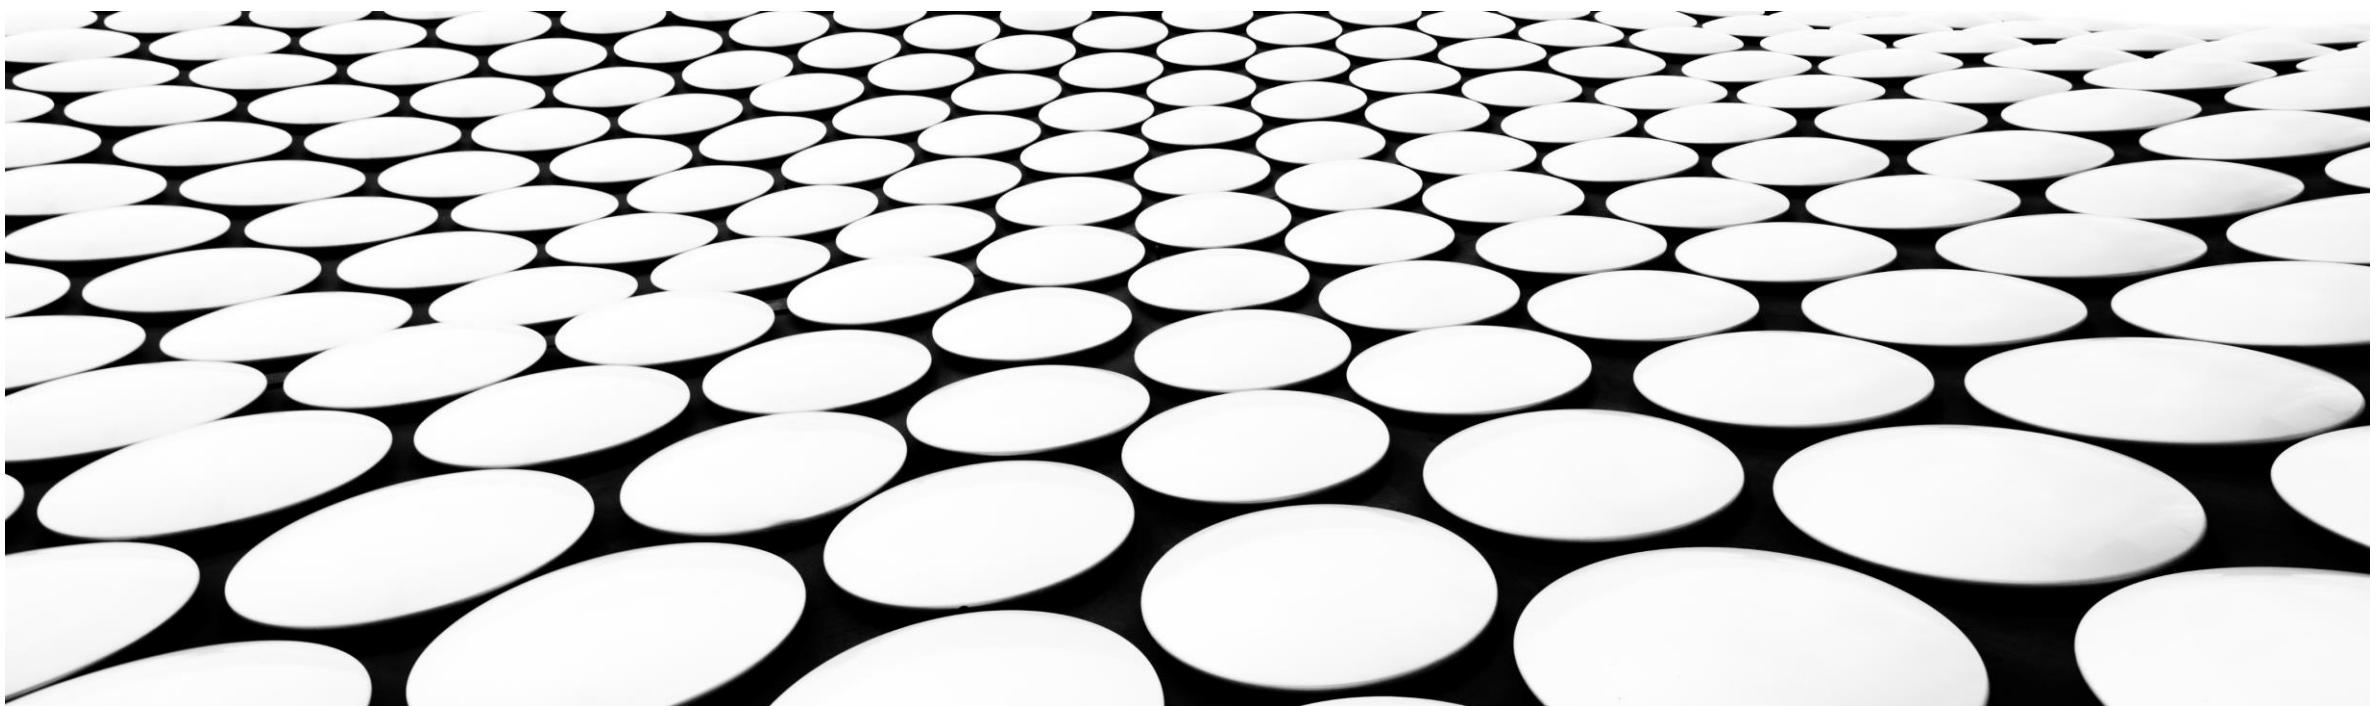

深度学习

邱怡轩



今天的主题

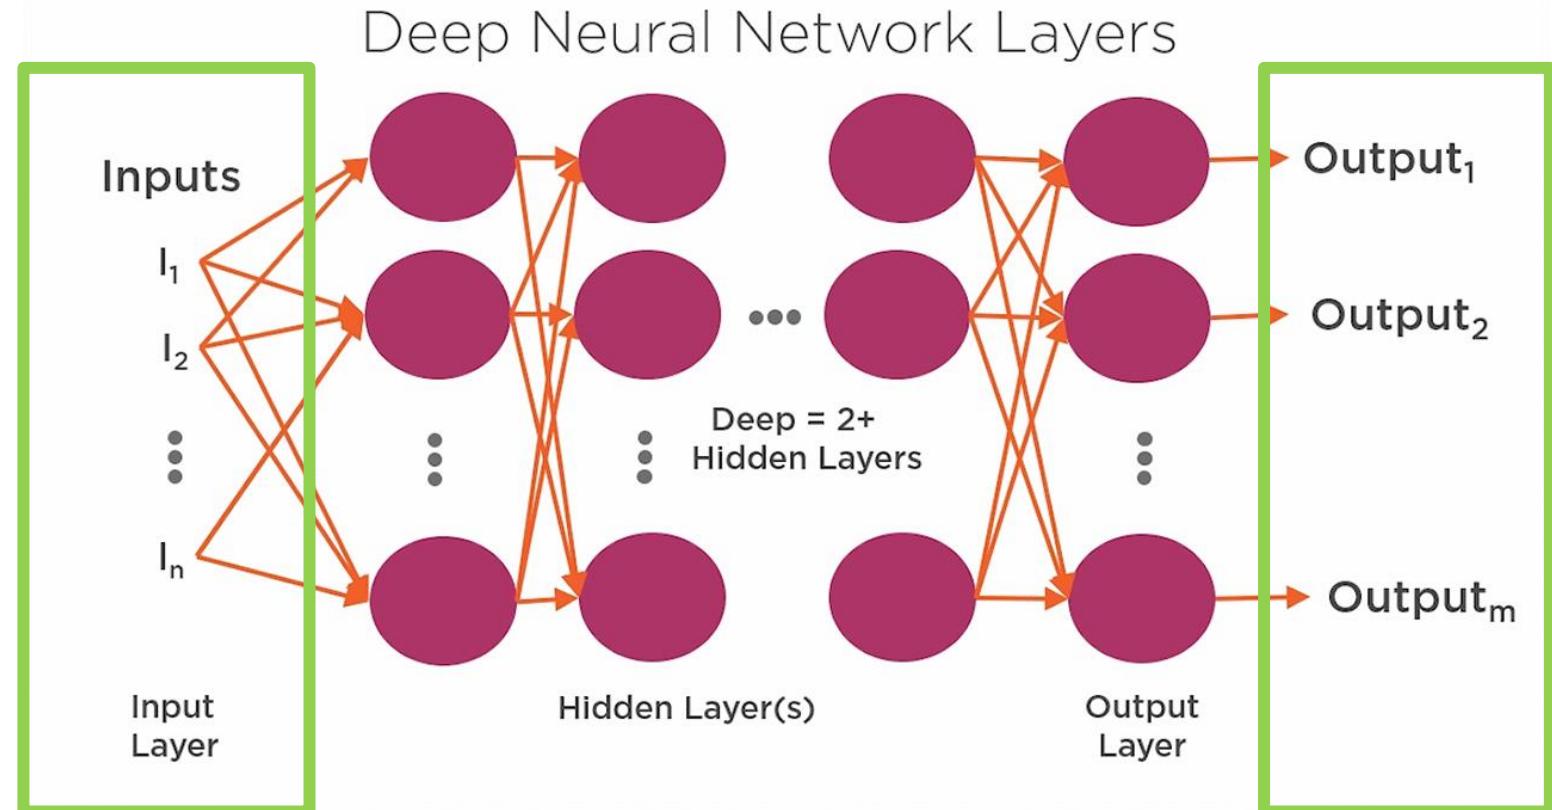
- 循环神经网络



循环神经网络

FNN/CNN

- 定长输入 => 定长输出



n 维输入

m 维输出

FNN/CNN

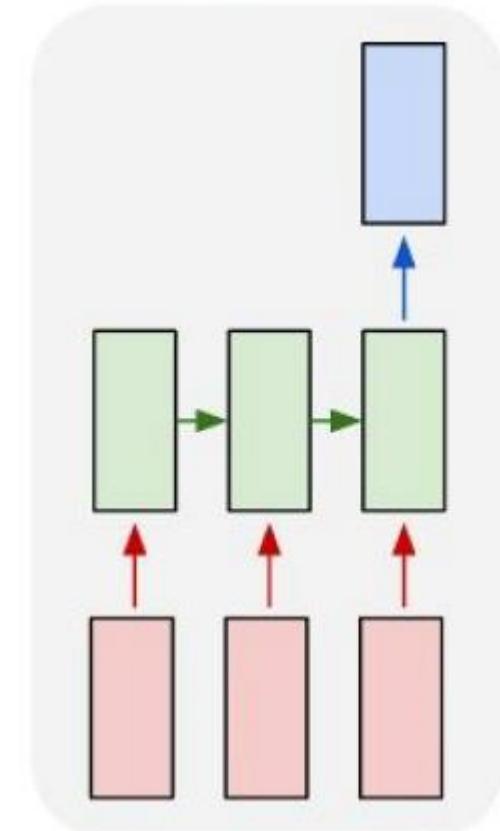
- 定长输入 => 定长输出
- 28×28 个像素 => 10 个类别
- 如果输入长度不确定怎么办？

FNN/CNN

- 如果输入长度不确定怎么办?
- 例：用名字预测性别
 - (张三, 男)
 - (李清照, 女)
 - (工藤新一, 男)
 - (克里斯蒂娜, 女)
 - (柯尔莫哥洛夫, 男)

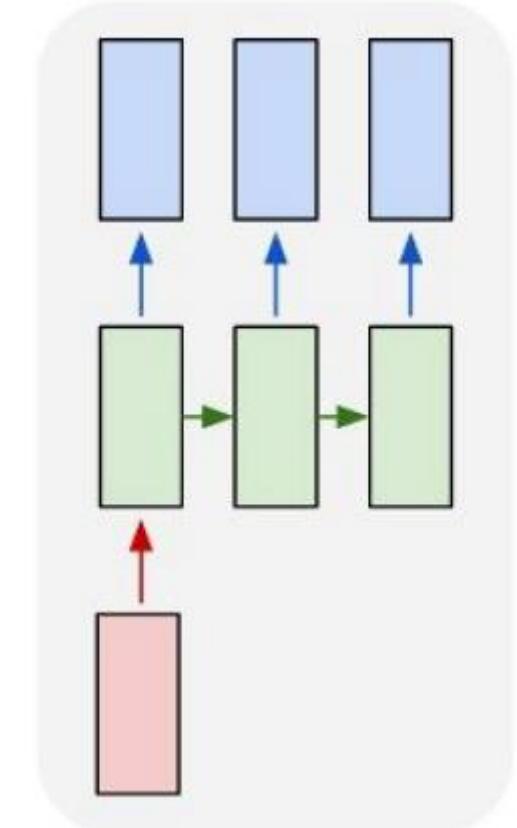
序列数据

- 可以把名字看成是由单个字符组成的序列
- 名字 => 性别
- 不定长序列 => 定长类别



序列数据

- 序列数据可以衍生出许多类型的问题
- 定长数据=> 不定长序列
- 例：图片描述



序列数据

■ 例：图片描述



A cat sitting on a suitcase on the floor



A cat is sitting on a tree branch



A dog is running in the grass with a frisbee



Two people walking on the beach with surfboards



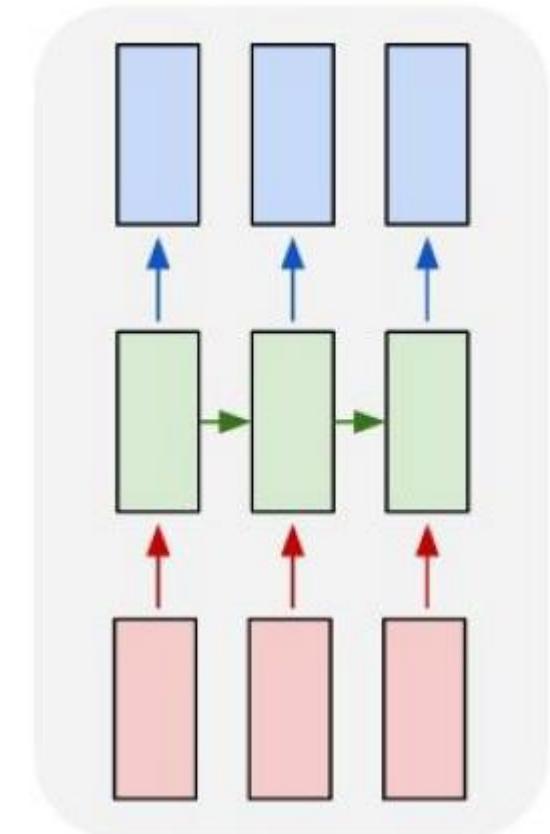
A tennis player in action on the court



Two giraffes standing in a grassy field

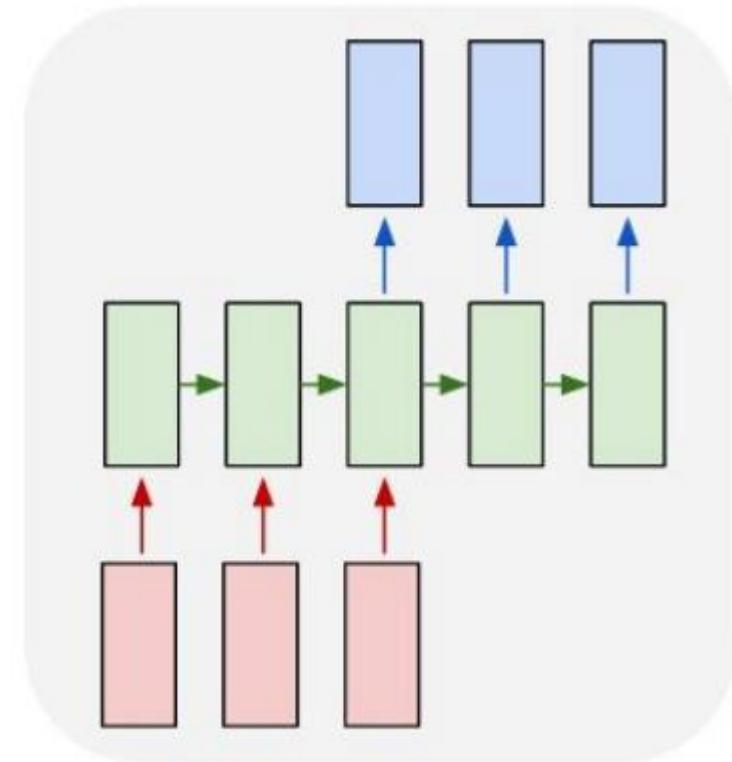
序列数据

- 序列数据可以衍生出许多类型的问题
- 不定长序列 => 不定长序列
- 输入输出一一对应
- 例：影片逐帧分类



序列数据

- 序列数据可以衍生出许多类型的问题
- 不定长序列 => 不定长序列
- 输入输出无对应关系
- 例：机器翻译



序列数据

■ 例：机器翻译



The screenshot shows the DeepL Translator interface. At the top, there is a navigation bar with the DeepL logo, 'DeepL Translator', 'DeepL Pro', 'Download for Windows', 'Login', and a menu icon. Below the navigation bar are two buttons: 'Translate text' (highlighted in light blue) and 'Translate .docx & .pptx files'. The main area shows a translation from English to Chinese. The English text is: 'Across the Great Wall we can reach every corner in the world.' The Chinese translation is: '穿过长城，我们可以到达世界的每个角落。' There are dropdown menus for selecting the source language ('English (detected)') and the target language ('Chinese'). Below the text boxes are several interactive icons: a speaker icon, a thumbs up icon, a thumbs down icon, a share icon, and a copy icon.

DeepL Translator DeepL Pro Download for Windows Login

Translate text Translate .docx & .pptx files

Translate from English (detected) ▾ Into Chinese ▾ Glossary

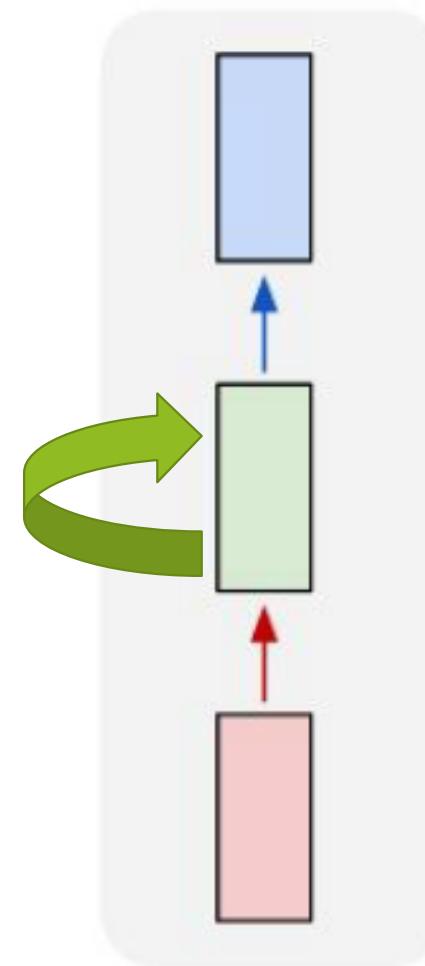
Across the Great Wall we can reach every corner in the world. 穿过长城，我们可以到达世界的每个角落。

循环神经网络

循环神经网络

- Recurrent Neural Networks (RNN)
- 核心是对序列数据进行建模

RNN 结构

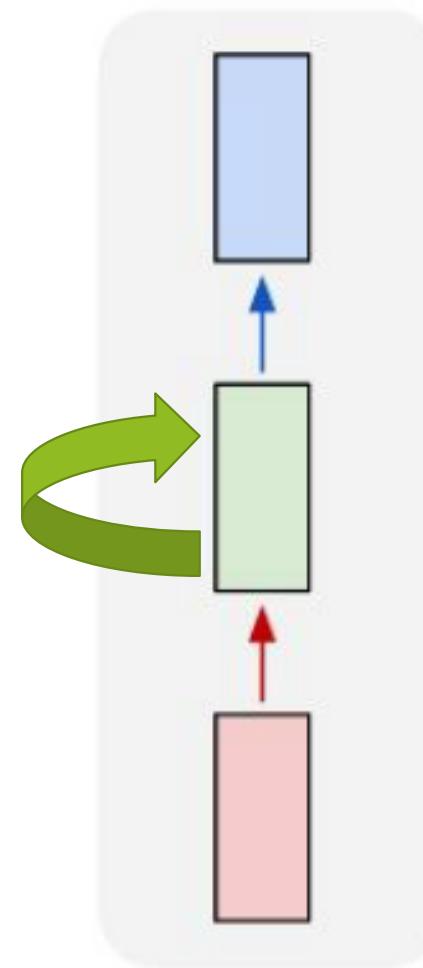


输出序列 $y(t)$

隐藏状态序列 $h(t)$

输入序列 $x(t)$

RNN 结构



$y(t)$ 是 $h(t)$ 的函数

$h(t)$ 是 $x(t)$ 和 $h(t-1)$ 的函数

输入序列 $x(t)$

RNN 结构

新状态

旧状态

$$h_t = f_W(h_{t-1}, x_t)$$

由参数 W 决定的函数

RNN 结构

新状态

$$h_t$$

旧状态

$$f_W$$
$$(h_{t-1}, x_t)$$

由参数 W
决定的函数

当前输入变量

参数 W 不随时间变化!

回顾

- “序列数据” 好像听着有些耳熟？
- 经典统计模型中有哪些方法刻画序列数据？

回顾

- 时间序列分析中的向量自回归模型 (VAR)

$$y_t = \underline{c + Ay_{t-1}} + \boxed{\varepsilon_t} \text{ 误差项}$$

线性变换

- 如果令 $h_t = E[Y_t]$, 则 $h_t = c + Ah_{t-1}$
- 假设 c 还和其他的序列 x_t 相关, 如 $c = Bx_t$
- 那么可以写成 $h_t = Bx_t + Ah_{t-1}$

回顾

- 时间序列分析中的向量自回归模型 (VAR)

$$y_t = \underline{c + Ay_{t-1}} + \boxed{\varepsilon_t} \text{ 误差项}$$

线性变换

- 如果令 $h_t = E[Y_t]$, 则 $h_t = c + Ah_{t-1}$
- 假设 c 还和其他的序列 x_t 相关, 如 $c = Bx_t$
- 那么可以写成 $h_t = Bx_t + Ah_{t-1}$

是 $h_t = f_W(h_{t-1}, x_t)$ 的特例!

回顾

- 时间序列分析中的向量自回归模型 (VAR)

$$y_t = \underline{c + Ay_{t-1}} + \boxed{\varepsilon_t} \text{ 误差项}$$

线性变换

- 如果我们使用非线性变换呢?

回顾

- 时间序列分析中的向量自回归模型 (VAR)

$$y_t = \underline{c + Ay_{t-1}} + \boxed{\varepsilon_t}$$

误差项
线性变换

- 如果我们使用非线性变换呢?
- 线性回归模型 => 前馈神经网络
- 线性自回归模型 => RNN

常见 RNN

新状态

旧状态

$$h_t = f_W(h_{t-1}, x_t)$$

由参数 W
决定的函数

当前输入变量

- $h_t = \tanh(W_{hh}h_{t-1} + W_{xh}x_t)$
- $y_t = W_{hy}h_t$

所有的 W 参数都不随时间变化!

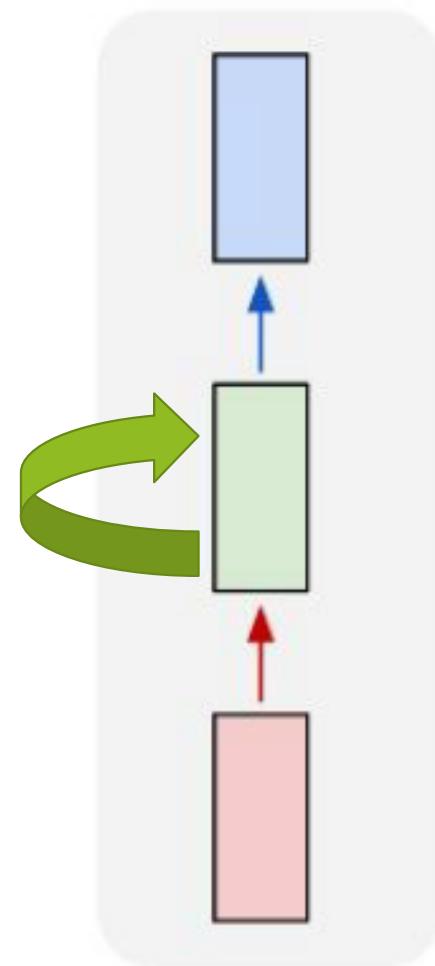
基本原理

- RNN 的基本假定是序列中前后的数据是“相关”的
 - 上海财_?_
 - 上海市财_?_
- 隐藏状态 $h(t)$ 起到了“记忆”的作用
 - 汇总了当前以及过去的信息
- $h(t)$ 的变化模式是稳定的
 - 参数 W 不随时间变化



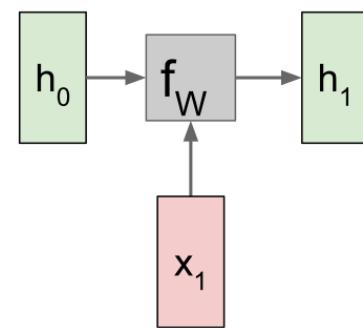
直观理解

理解 RNN

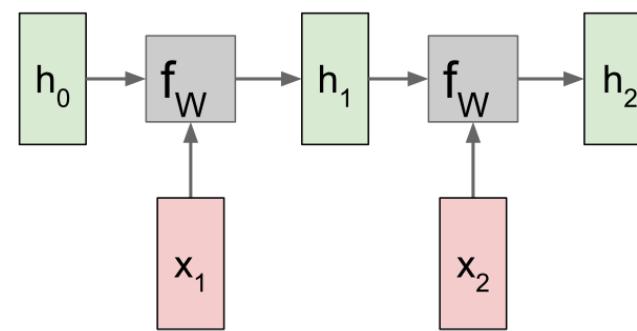


- 这张图其实隐藏了很多细节
- 我们可以把循环展开
- 从而更好地理解 RNN 的建模过程

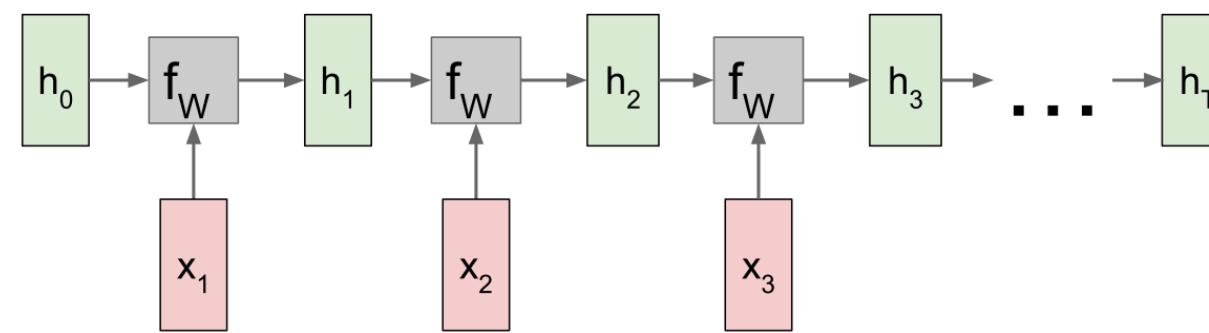
理解 RNN



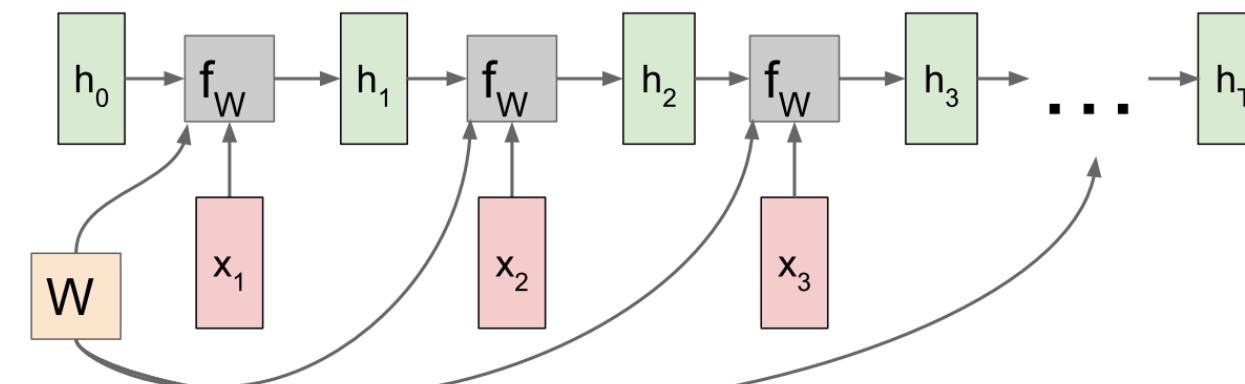
理解 RNN



理解 RNN

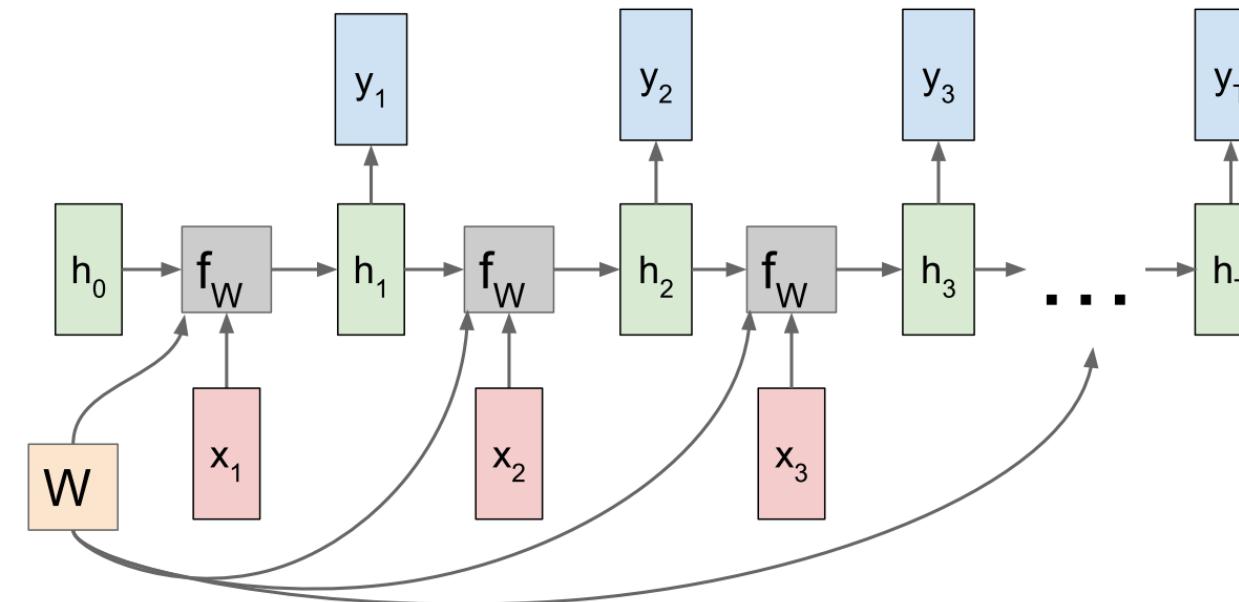


理解 RNN

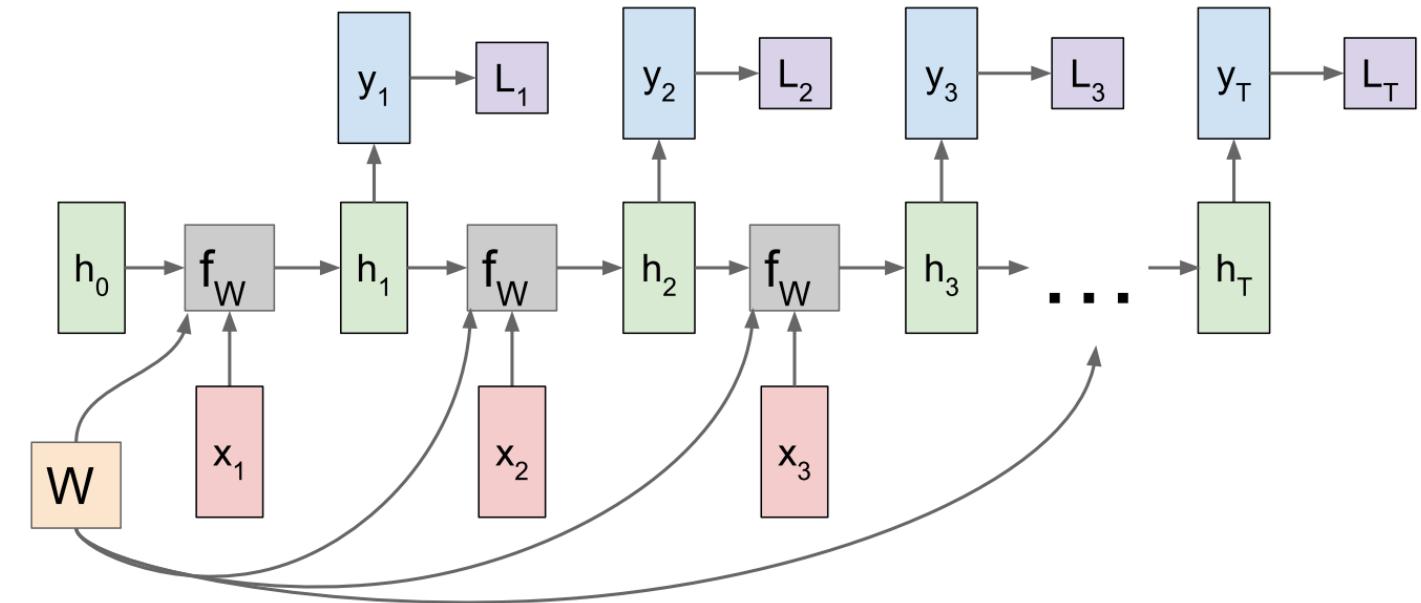


权重共用

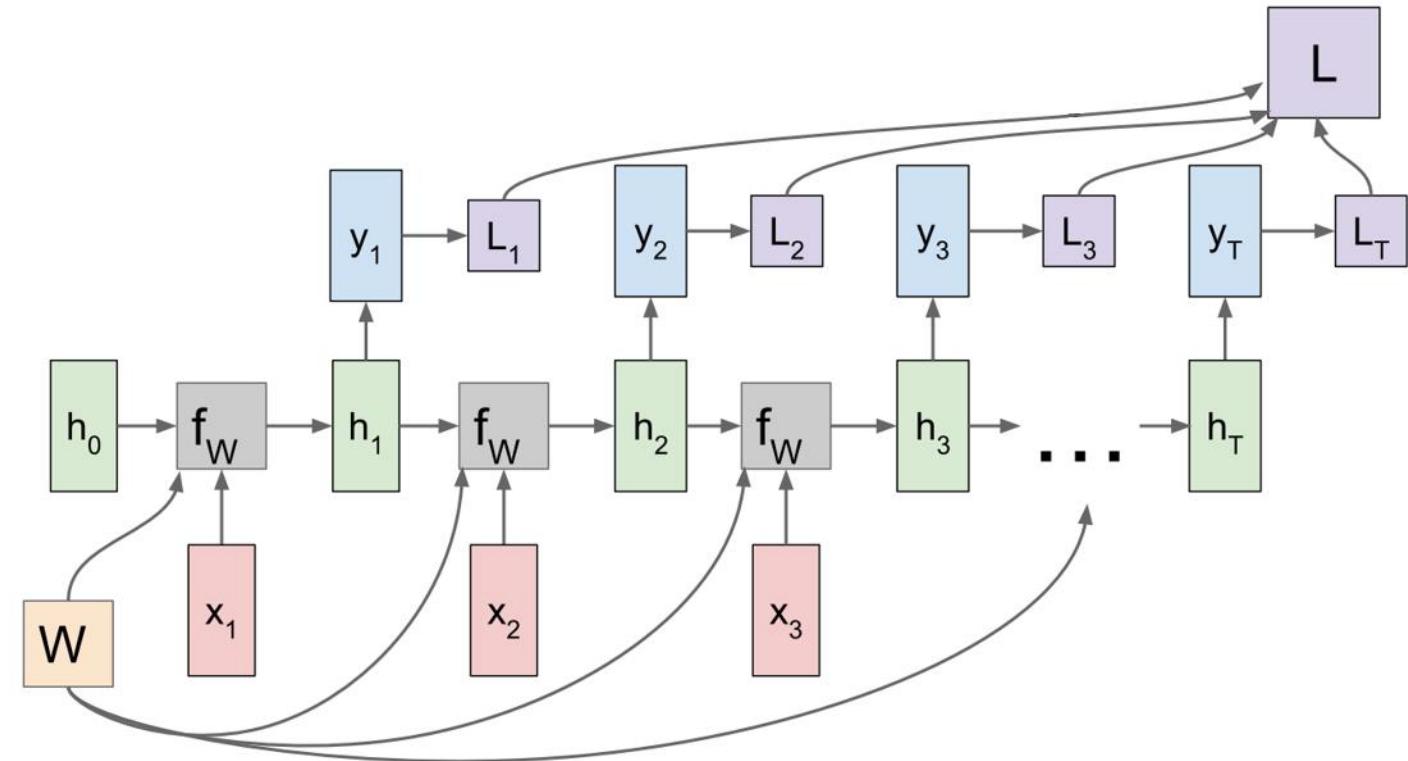
理解 RNN



理解 RNN



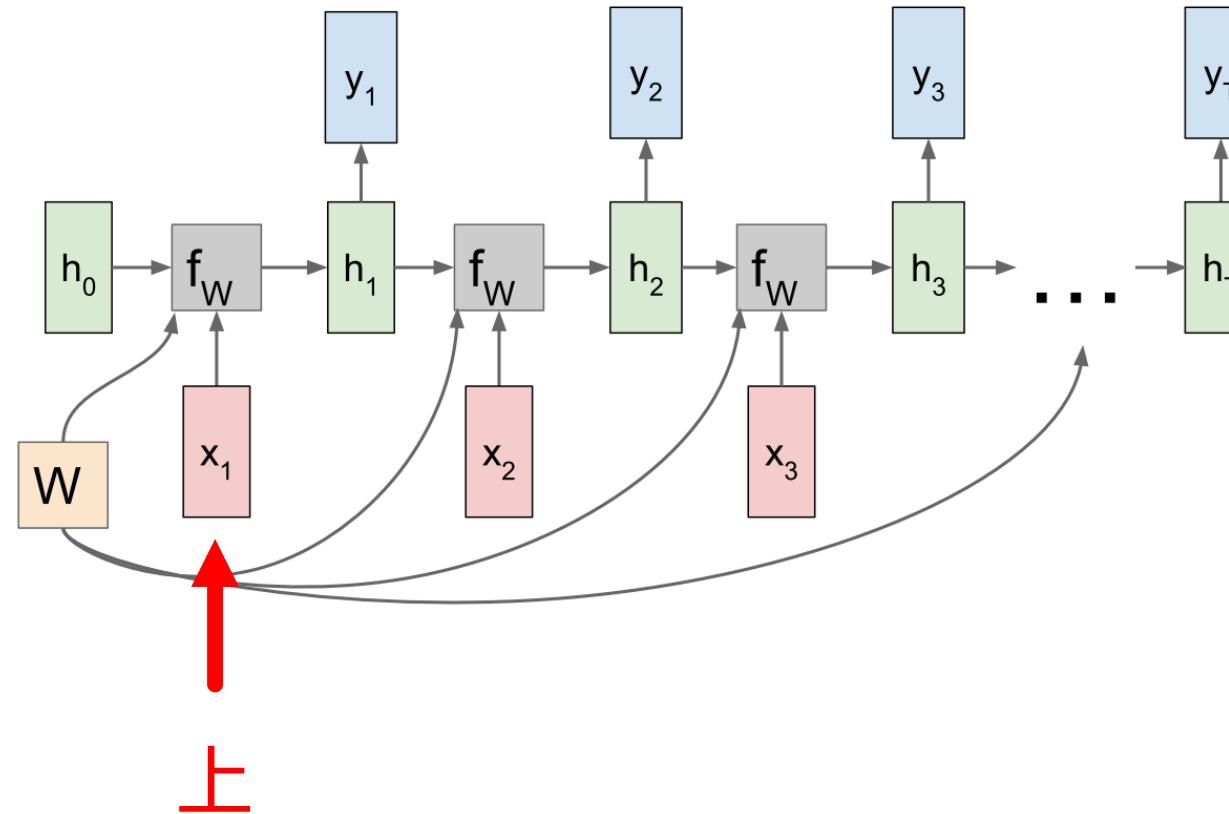
理解 RNN



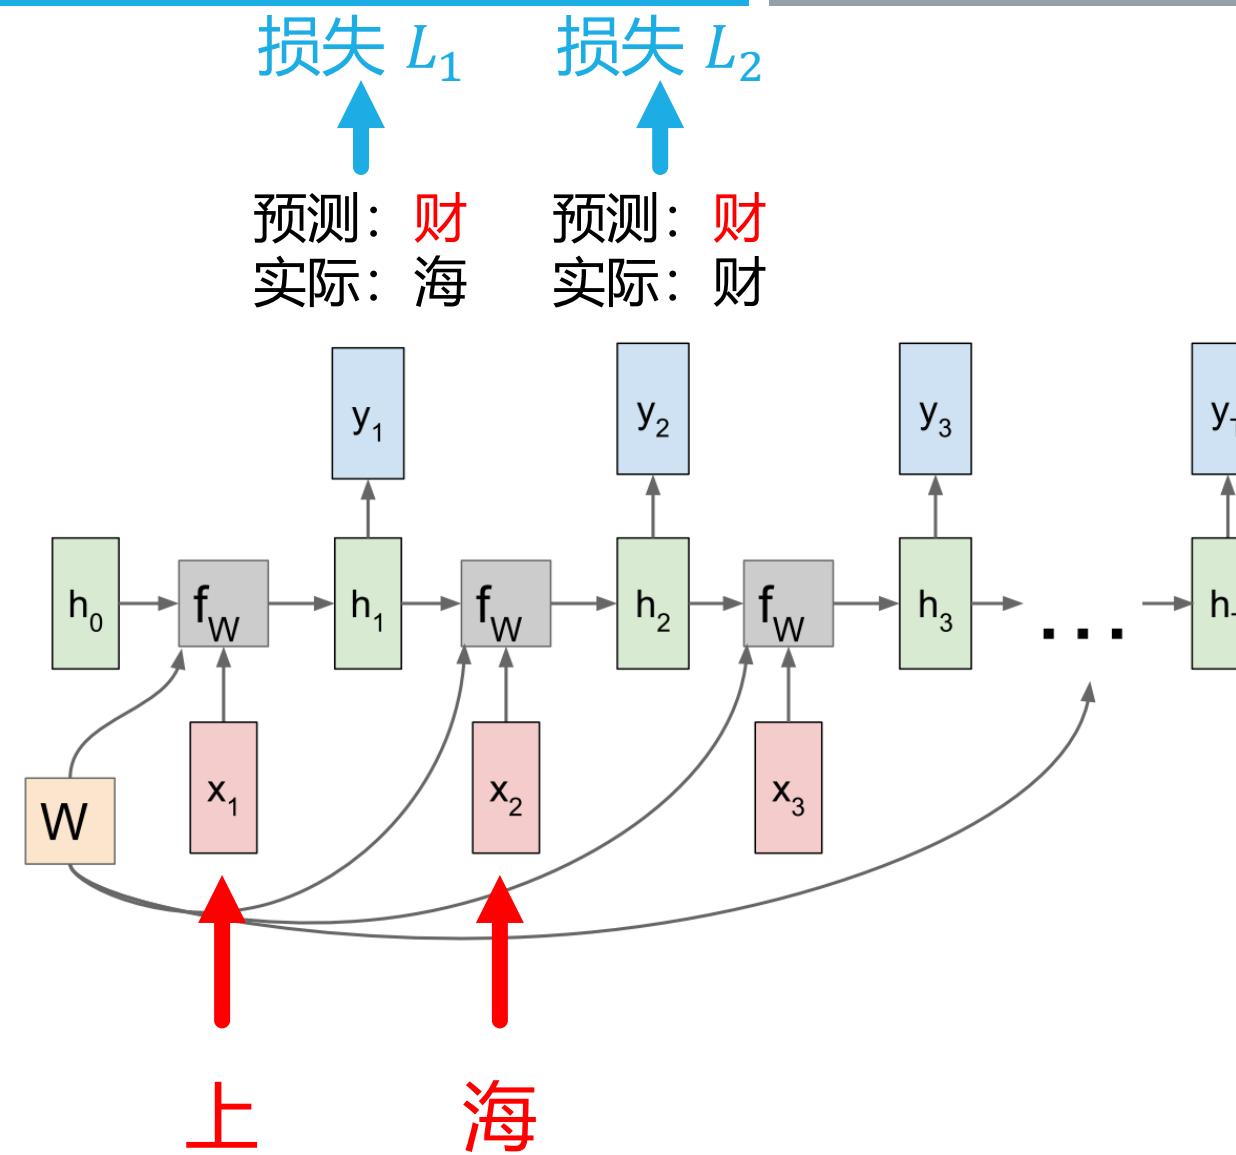
理解 RNN

损失 L_1

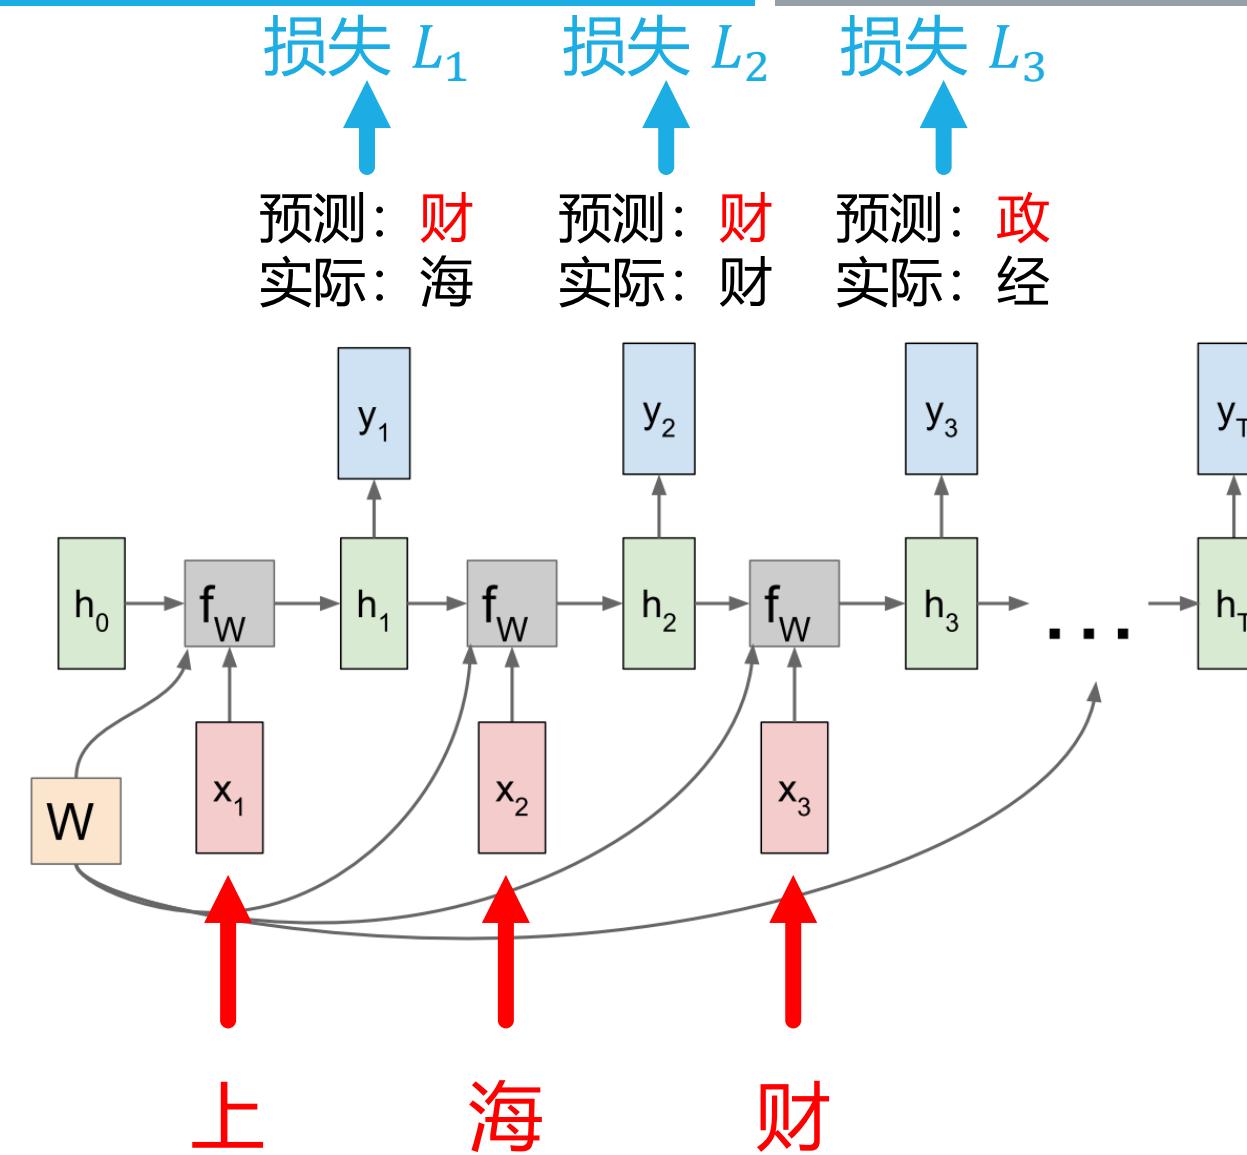
预测: 财
实际: 海



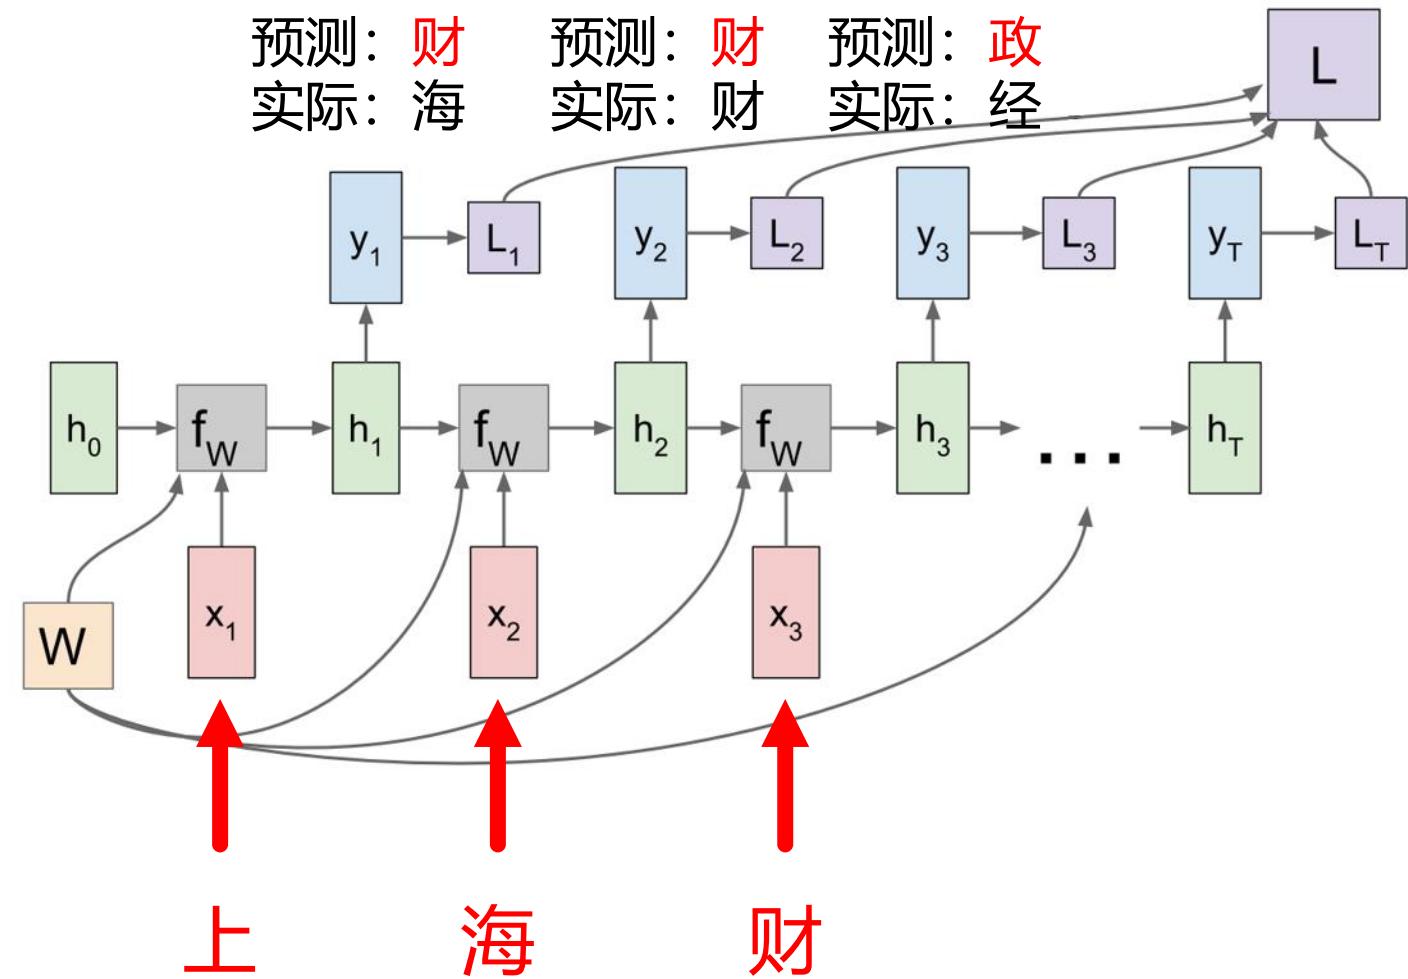
理解 RNN



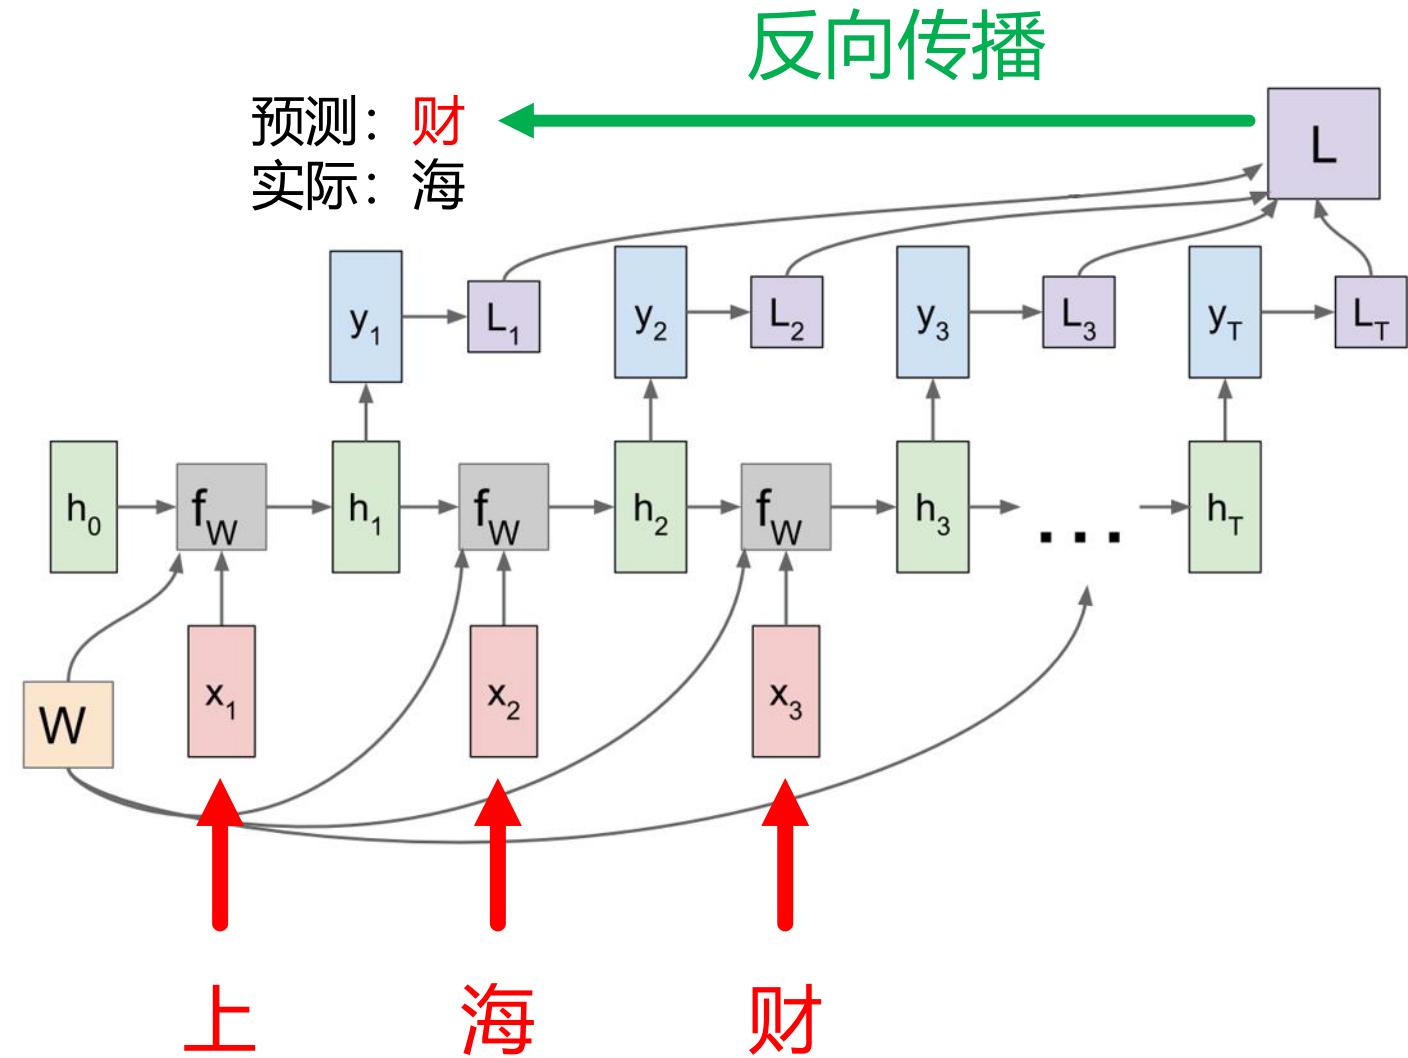
理解 RNN



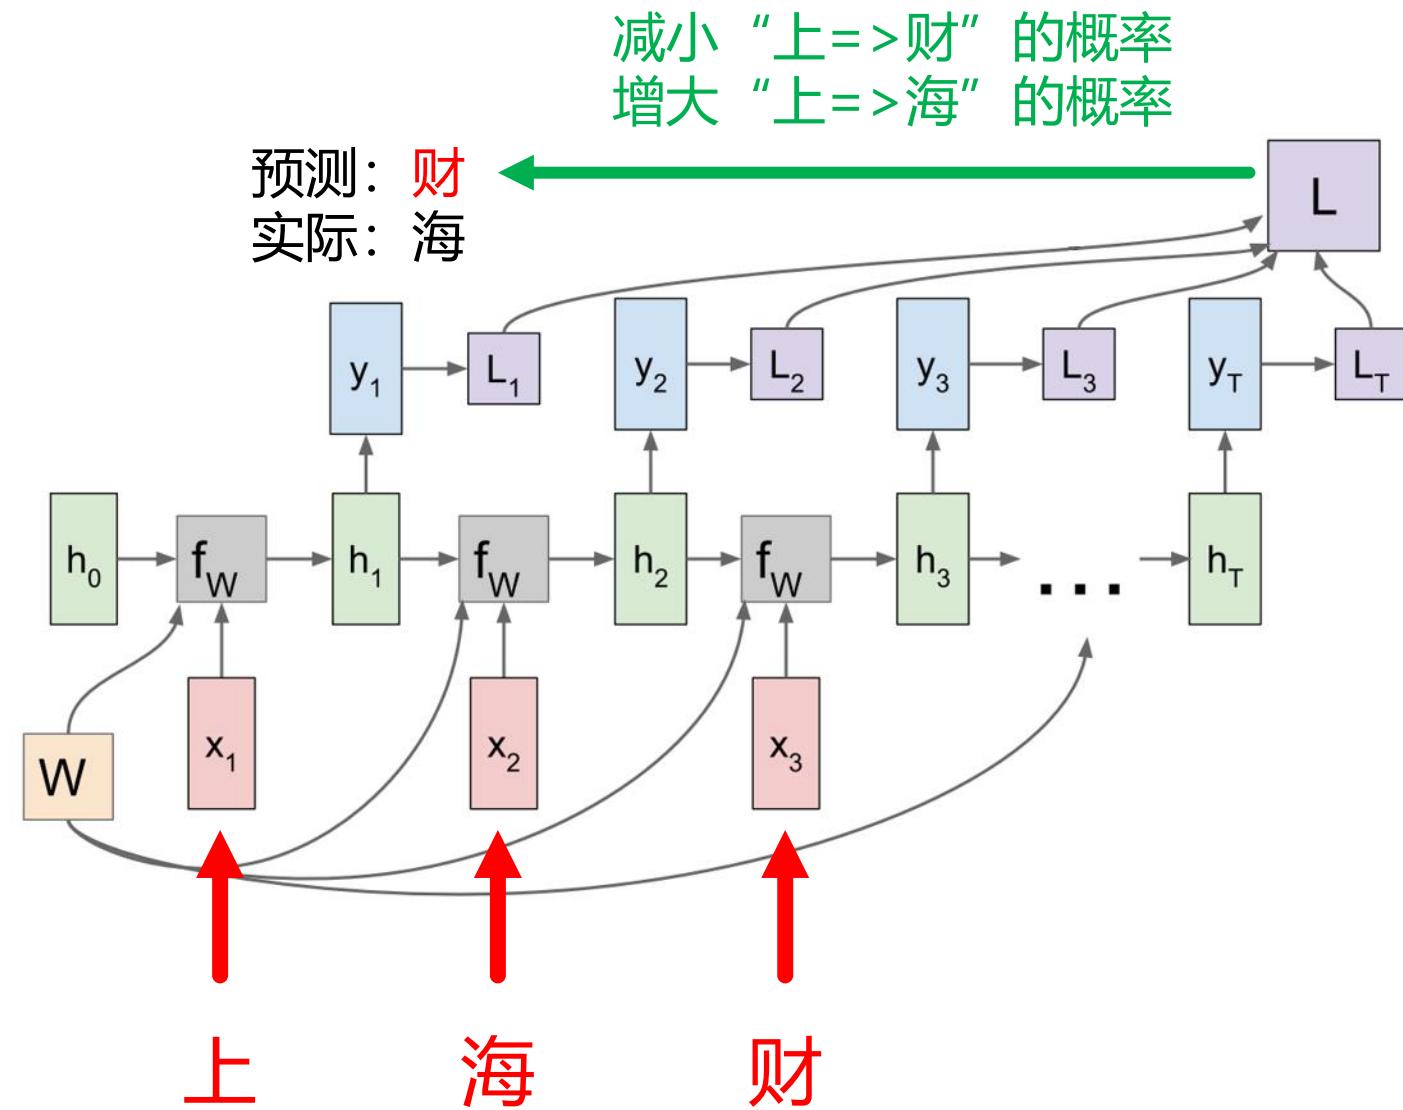
理解 RNN



理解 RNN

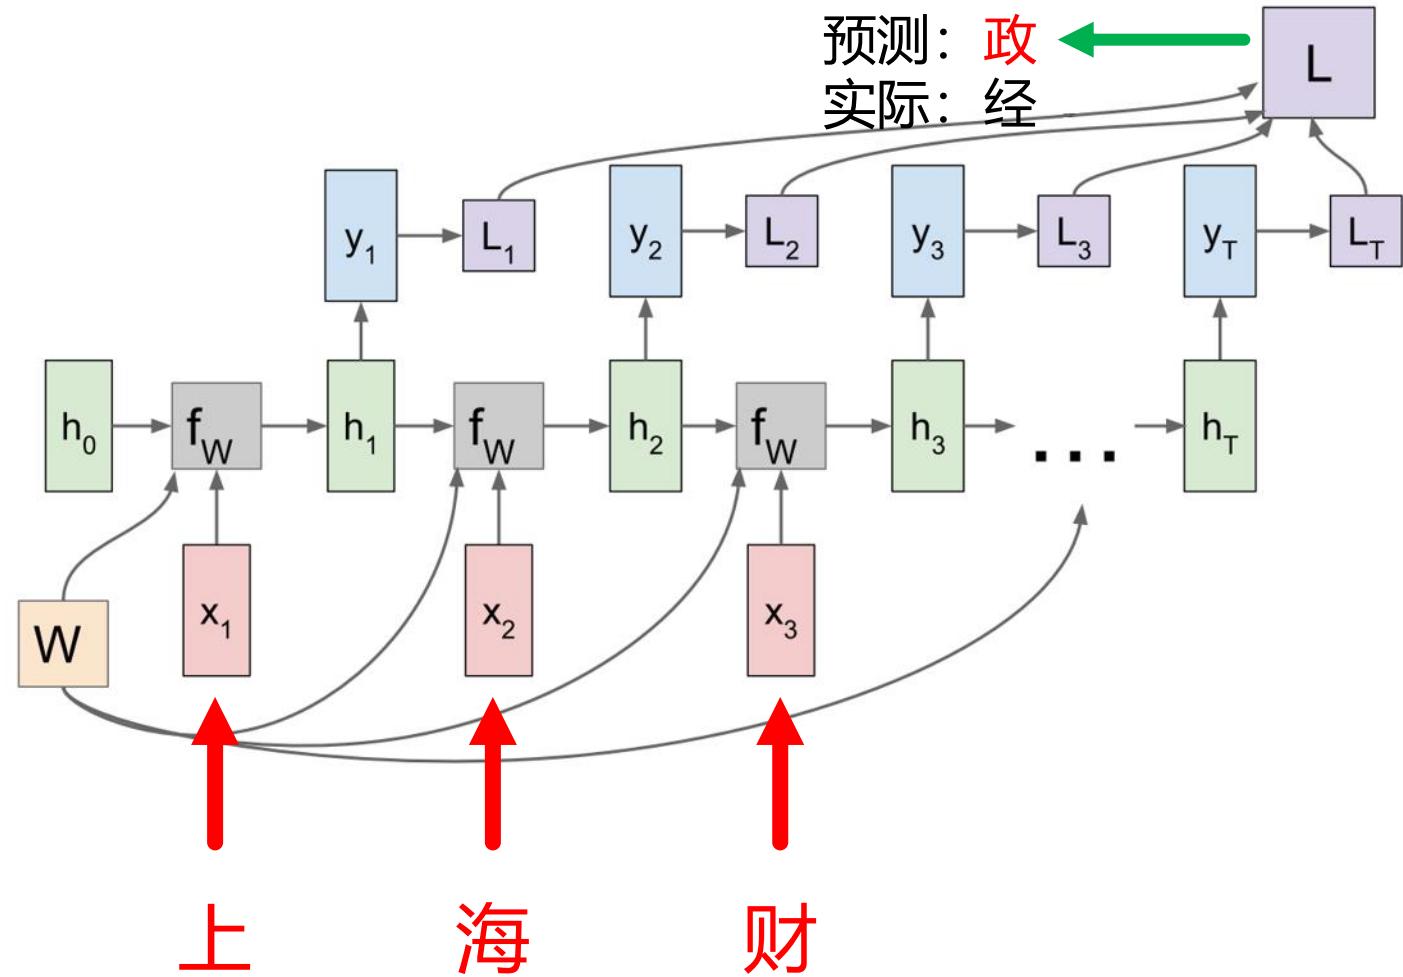


理解 RNN



理解 RNN

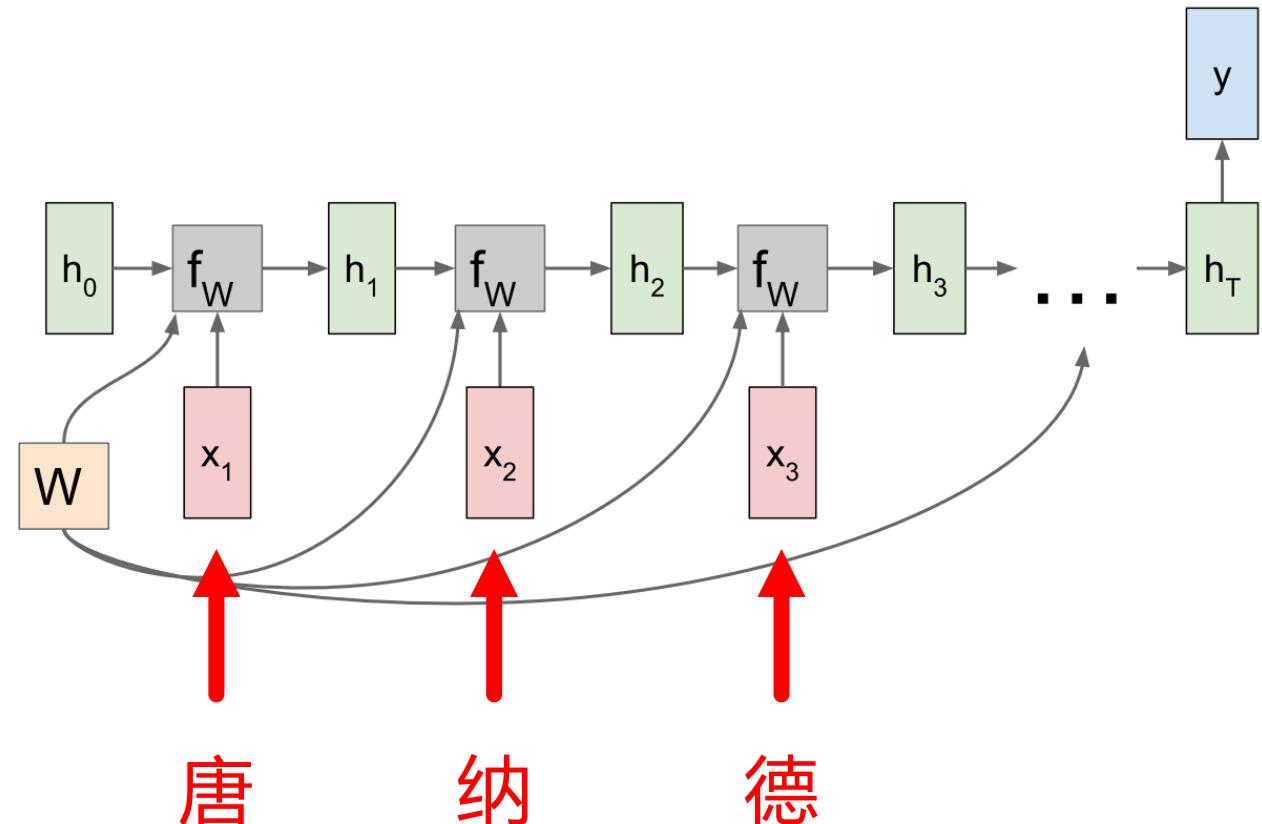
减小 “上海财=>政”的概率
增大 “上海财=>经”的概率



其他架构

- 姓名 => 性别
- 只关心最后的预测结果

预测: $p(\text{男})=0.9$
实际: 男



其他架构

■ 图片 => 文字描述

预测: 猫

实际: 猫

预测: 与

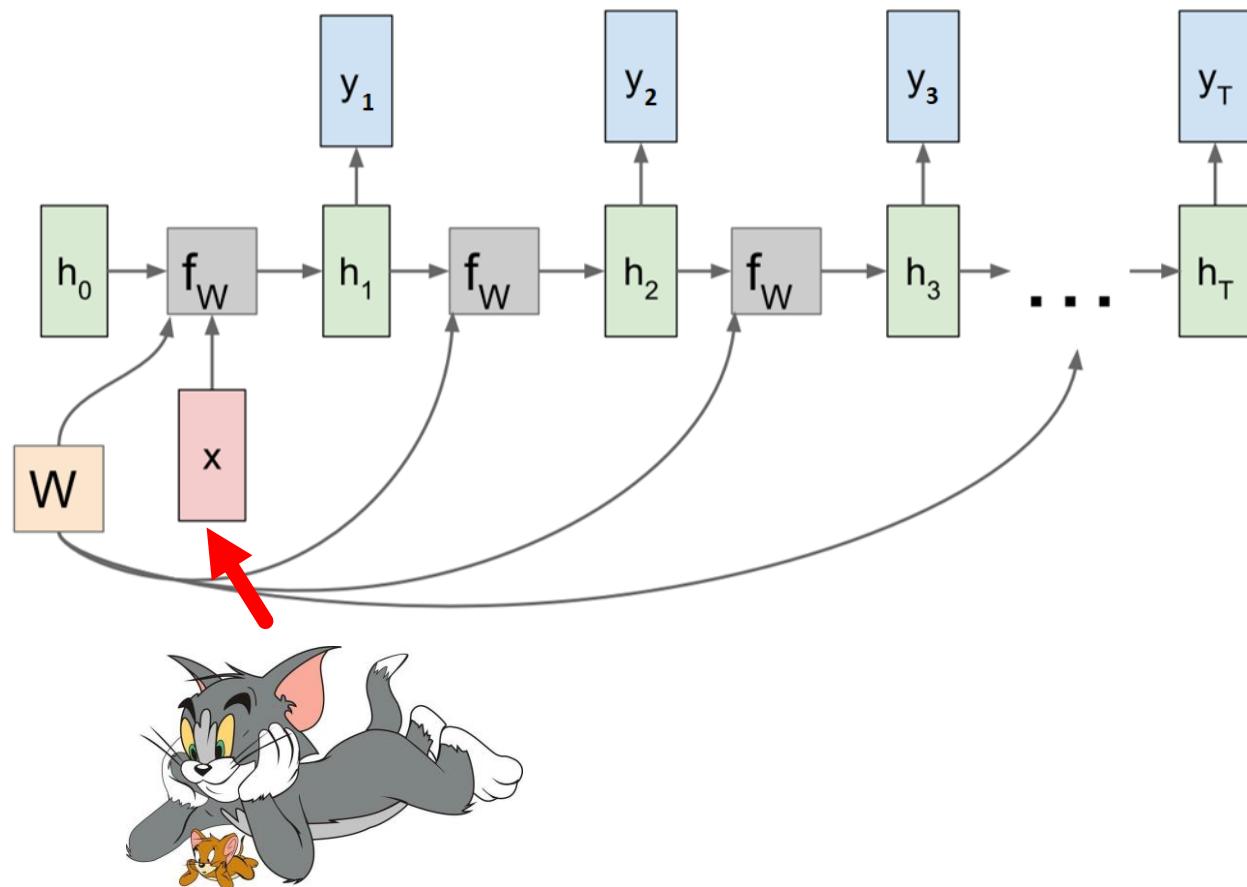
实际: 和

预测: 老

实际: 老

预测: 鼠

实际: 鼠



其他架构

■ 中文 => 英文

