ArchSummit 2017

深度学习在自然语言处理中的应用

邱锡鹏
复旦大学
2017年12月8日
http://nlp.fudan.edu.cn/xpqiu

主办方 Geekbang InfoQ

AiCon

全球人工智能与机器学习技术大会

助力人工智能落地

2018.1.13 - 1.14 北京国际会议中心

扫描关注大会官网

内容提纲

- 简介
  - 自然语言处理
  - 深度学习
- 语义表示学习
  - 词表示
  - 句子表示
- 自然语言处理的新范式
- 应用

自然语言处理

从人工智能开始

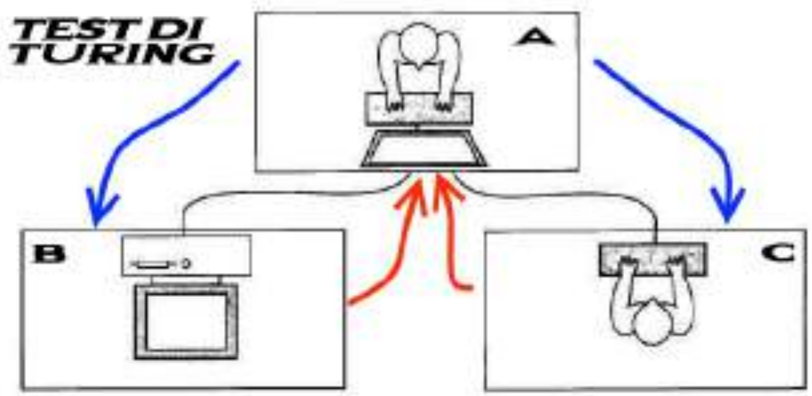

Alan Turing

自然语言处理：理解和生成

什么是自然语言？

- 语言是指在一个有限的字符集上，产生的符合一定规则的字符串集合。
- 自然语言通常是指一种自然地随文化演化的语言。
- 自然语言 VS 人工语言
  - 形式语言 (Chomsky,1950)
  - 区别
    - 自然语言：歧义性
    - 人工语言：确定性

歧义：以中文分词为例

- 不同的语言环境中的同形异构现象，按照具体语言环境的语义进行切法。
  - 交叉歧义
    - 他／说／的／确实／在理
  - 组合歧义
    - 两个/人/一起/过去、个人/问题
    - 从马/上/下来、马上/就/来
  - 句子级歧义
    - 白天鹅在水里游泳
    - 该研究所获得的成果

伪歧义

自然语言处理

- 自然语言处理包括语音识别、自然语言理解、自然语言生成、人机交互以及所涉及的中间阶段。
  - 是人工智能和计算机科学的子学科。

自然语言处理不等于研究语言学（计算语言学）、文学。

Every time I fire a linguist, the performance of our speech recognition system goes up.

-- Frederick Jelinek, 1985

https://en.wikiquote.org/wiki/Fred_Jelinek

理想中的自然语言处理流程

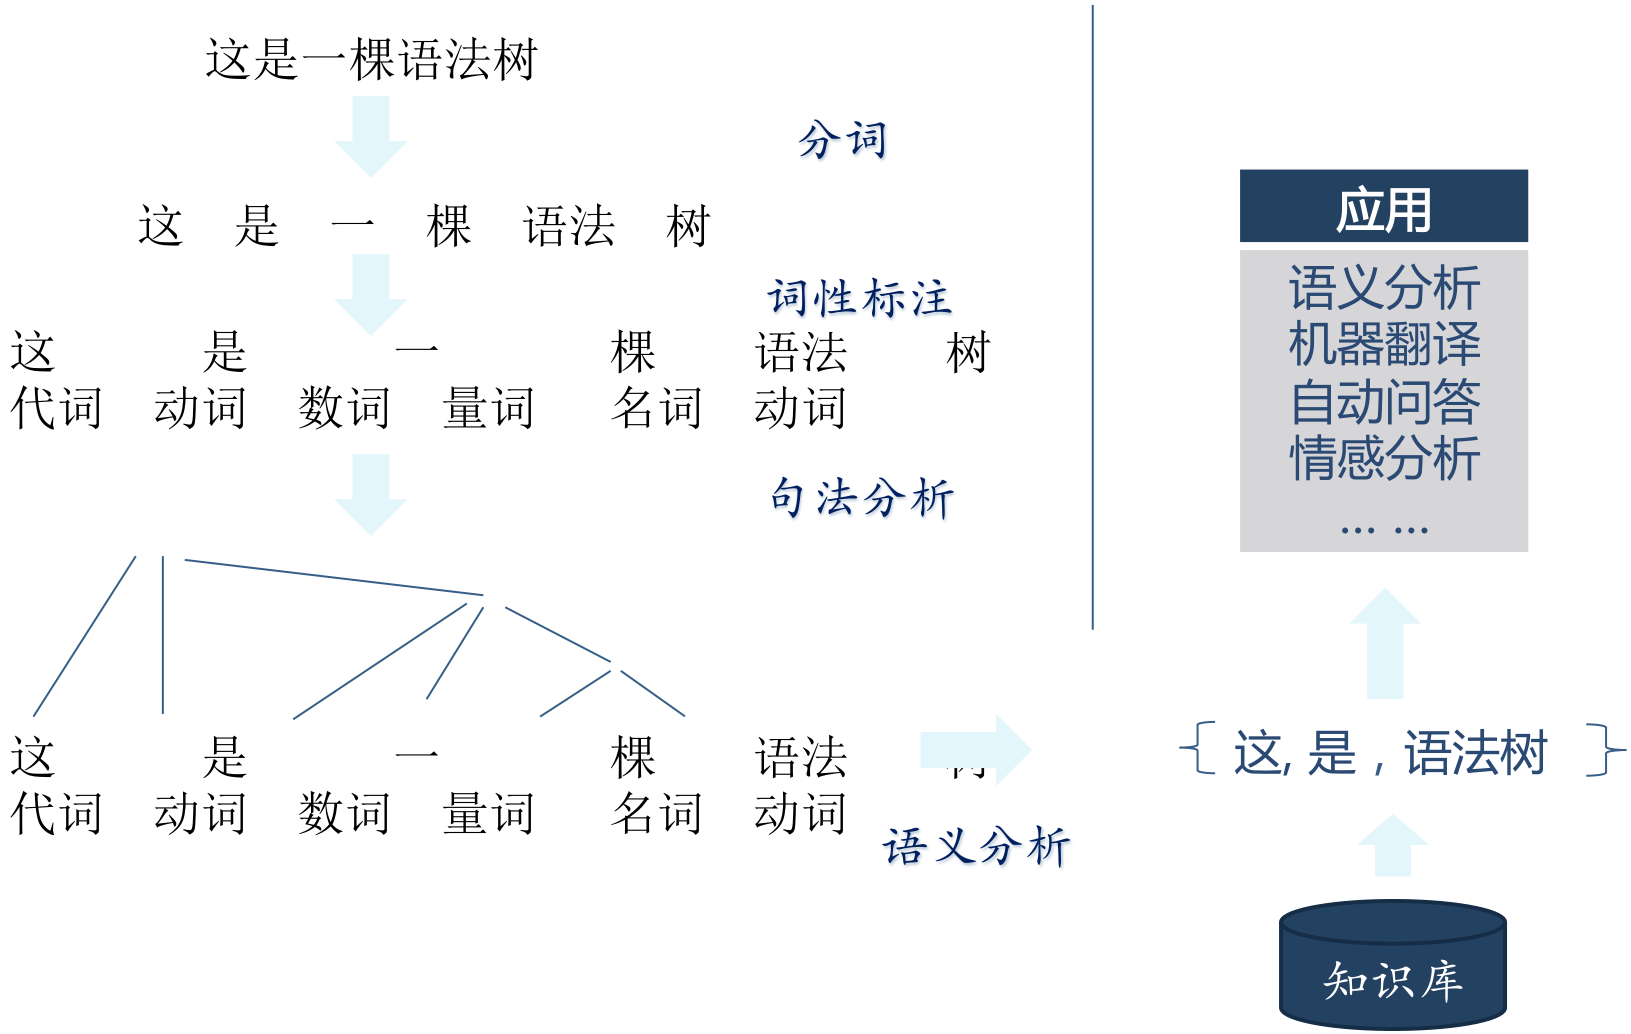

主要任务

- 自然语言处理任务可以分为四类：词法分析、句法分析、语义分析、应用。

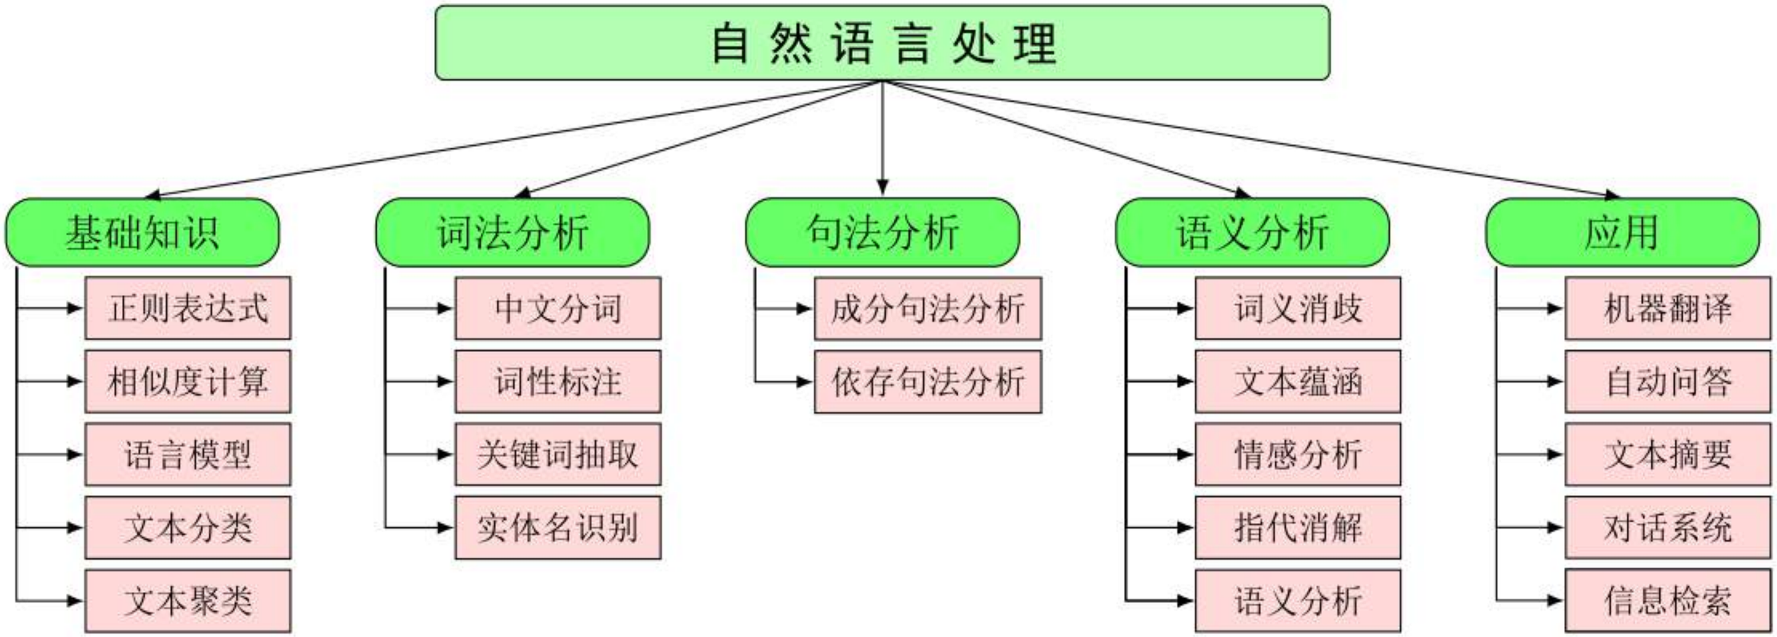

发展历程

- 1990年以前，基于规则（rule-based）的方法
  - 使用手写的规则
- 1990年以后，基于语料库（corpus-based）的方法
  - 也叫实证（ empirical ）方法或数据驱动（data-driven）方法
  - 大量使用统计或机器学习模型
  - 典型应用：*The mathematics of statistical machine translation: parameter estimation. 1993*
- 2011年以后，基于神经网络（neural-based）的方法
  - 端到端的神经网络模型
  - 典型应用：Sequence to Sequence Learning with Neural Networks, 2014

基于语料库的方法

- 语料库:文本数据的集合
- 技术手段:
  - 统计模型
  - 机器学习模型

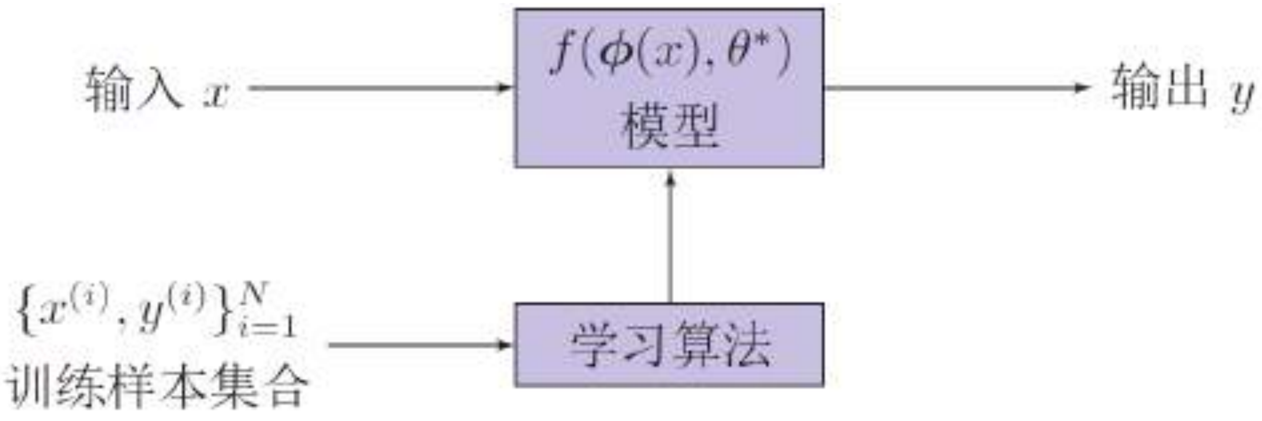

实际的自然语言处理流程

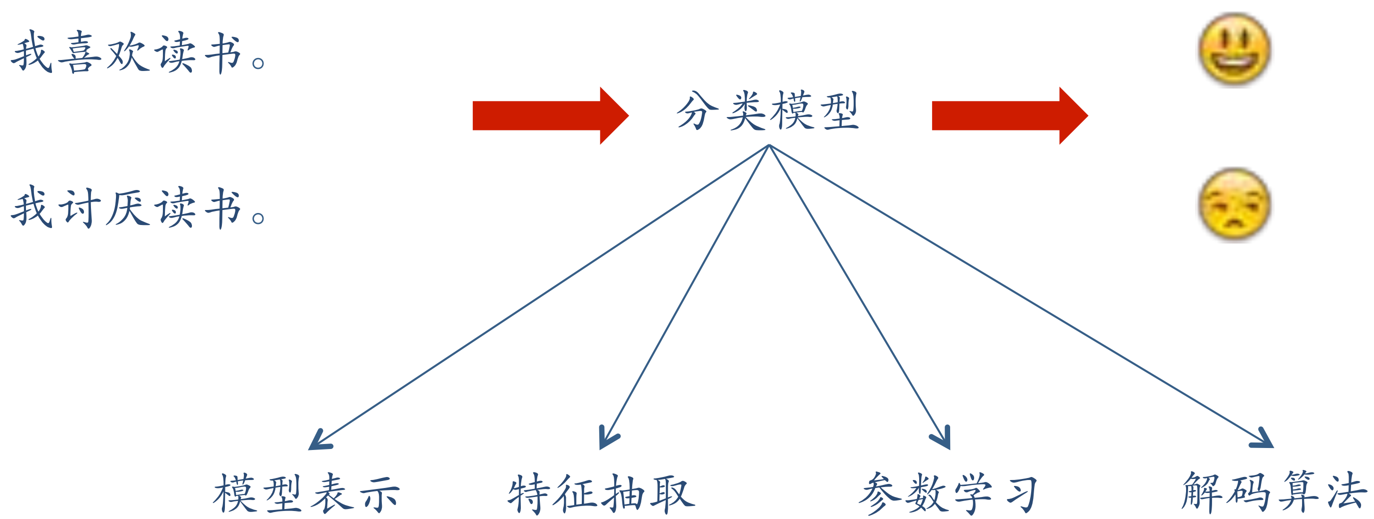

情感分析

文本分类

根据文本内容来判断文本的相应类别

D_1：“我喜欢读书”

D_2：“我讨厌读书”

	我	喜欢	讨厌	读书
D_1	1	1	0	1
D_2	1	0	1	1

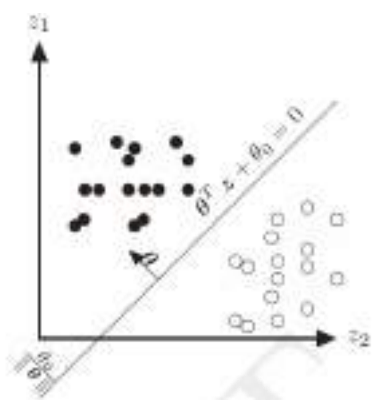

\+

\-

换个角度看中文分词

自	:	然	:	语	:	言	:	处	:	理
	0		1		0		1		0	

窗口大小	样本 x	类别标签 y
2	"自:然"	0
	"然:语"	1
	"语:言"	0
4	"自然:语言"	1
	"然语:言处"	0
	"语言:处理"	1

单字符特征	$x_{-2}y_0, x_{-1}y_0, x_0y_0, x_1y_0, x_2y_0$ [a]
双字符特征	$x_{-1}x_0y_0, x_0x_1y_0, x_{-1}x_1y_0,$
三字符特征	$x_{-1}x_0x_1y_0$
马氏链特征	$y_{-1}y_0$

[00001000100010001101]

1/0

特征工程问题

- 在实际应用中，特征往往比分类器更重要
  - 预处理：经过数据的预处理，如去除噪声等。比如在文本分类中，去除停用词等。
  - 特征提取：从原始数据中提取一些有效的特征。比如在图像分类中，提取边缘、尺度不变特征变换特征等。
  - 特征转换：对特征进行一定的加工，比如降维和升维。降维包括
    - 特征抽取（Feature Extraction）：PCA、LDA
    - 特征选择（Feature Selection）：互信息、TF-IDF

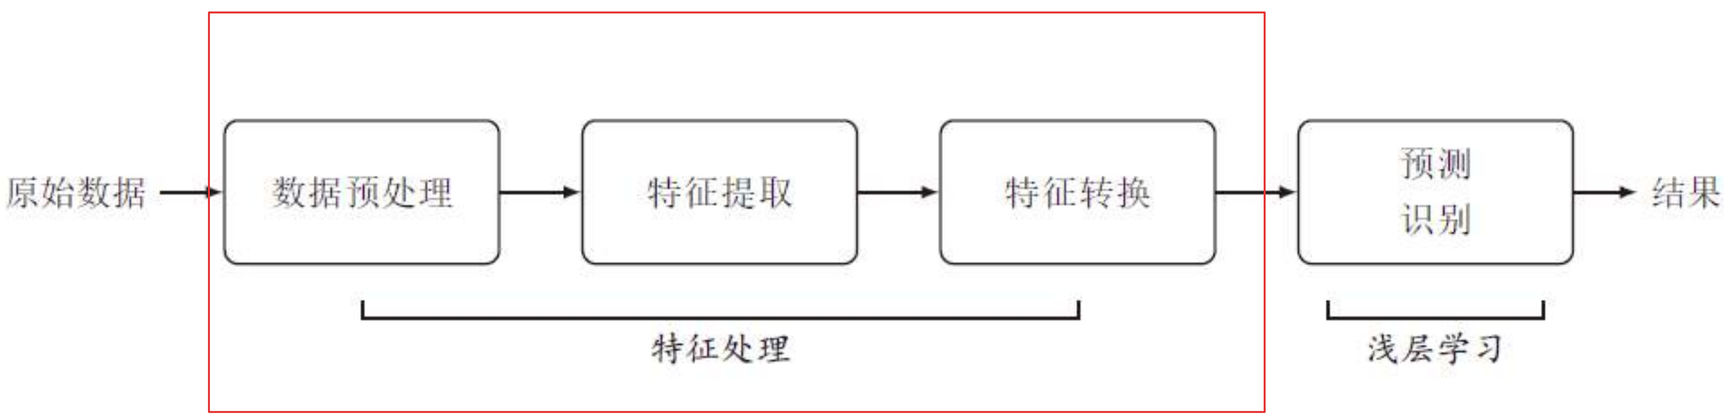

深度学习

深度学习

- 深度学习=表示学习+浅层学习
- 难点：贡献度分配问题

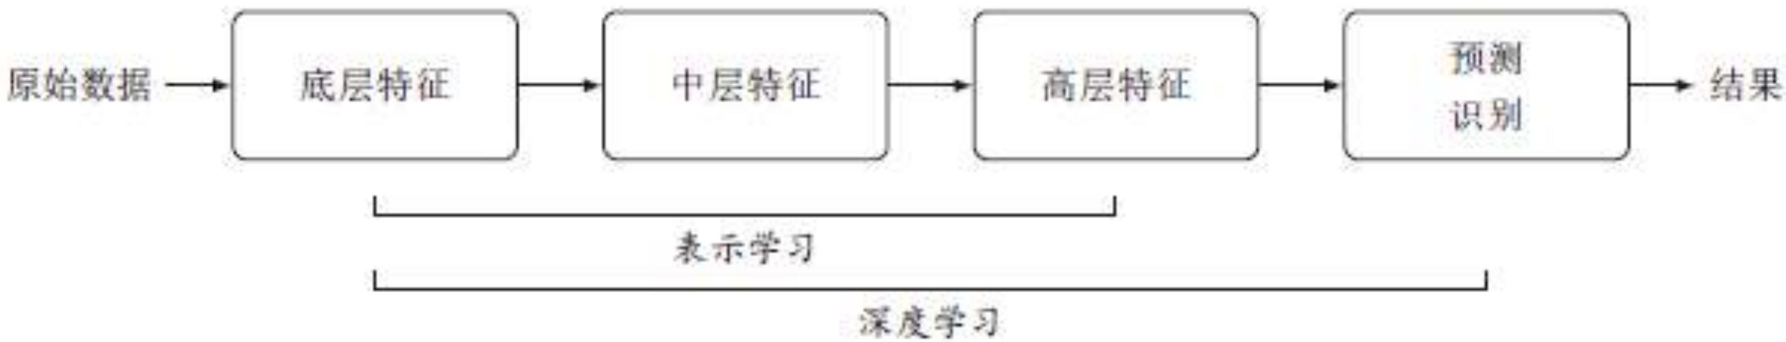

表示学习与深度学习

- 一个好的表示学习策略必须具备一定的深度
  - 特征重用
    - 指数级的表示能力
  - 抽象表示与不变性
    - 抽象表示需要多步的构造

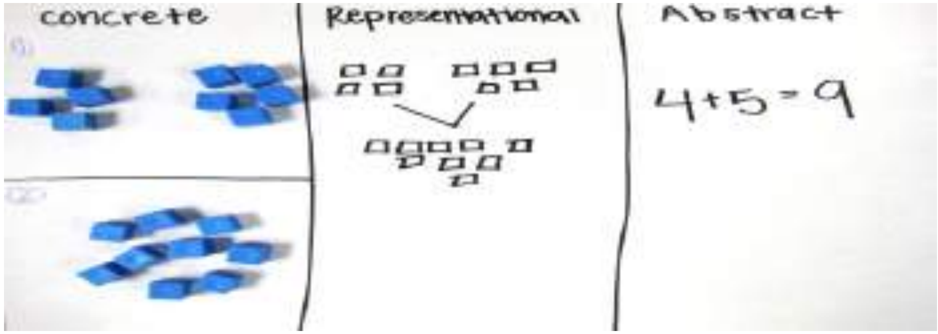

https://mathteachingstrategies.wordpress.com/2008/11/24/concrete-and-abstract-representations-using-mathematical-tools/

深度学习与神经网络

- 深度学习天然不是神经网络，但神经网络天然是深度学习！

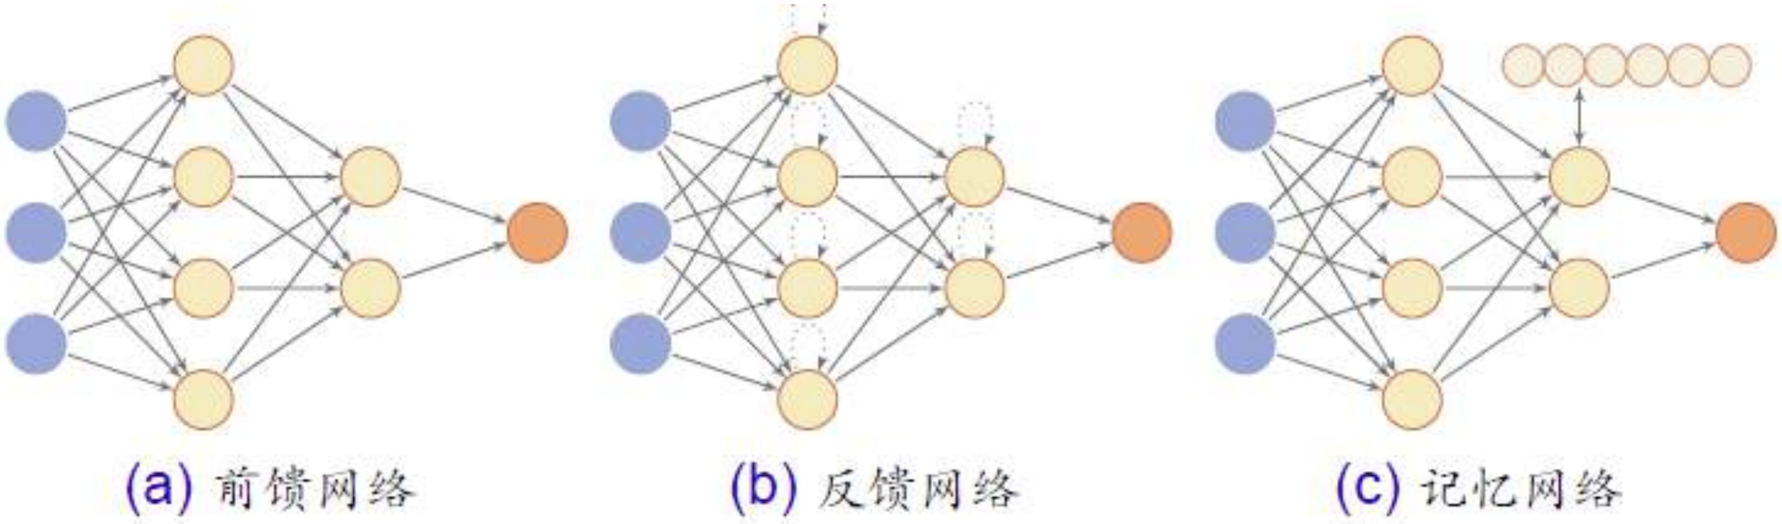

语言表示学习

语义鸿沟

- 底层特征 VS 高层语义
  - 人们对文本、图像的理解无法从字符串或者图像的底层特征直接获得

床前明月光，
疑是地上霜。
举头望明月，
低头思故乡。

表示学习

语言表示

- 如何在计算机中表示语言的语义?

知识库
规则

→

分布式表示

- 压缩、低维、稠密向量
- 用O(N)个参数表示 O(2^k)区间
  - k为非0参数，k<N

一个生活中的例子：颜色

命名	RGB值
红	[1,0,0]
绿	[0,1,0]
蓝	[0,0,1]
中国红	[0.67, 0.22, 0.12]
咖啡色	[0.64, 0.16,0.16]

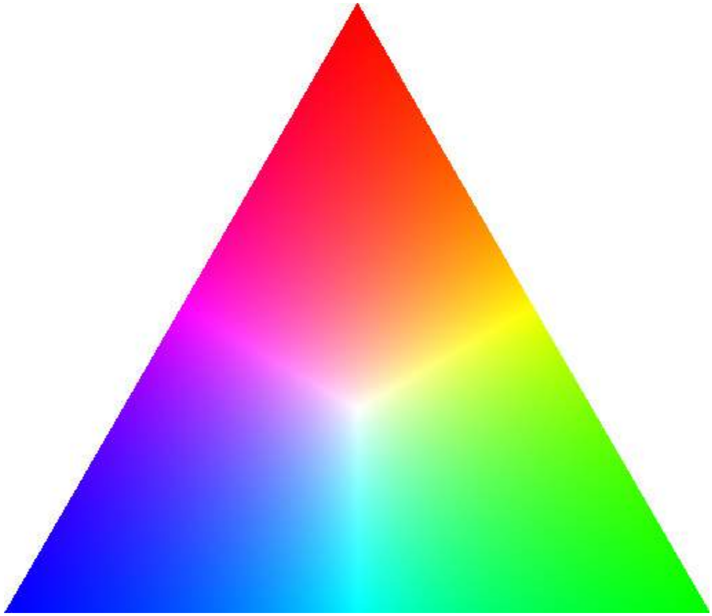

词嵌入（Word Embeddings）

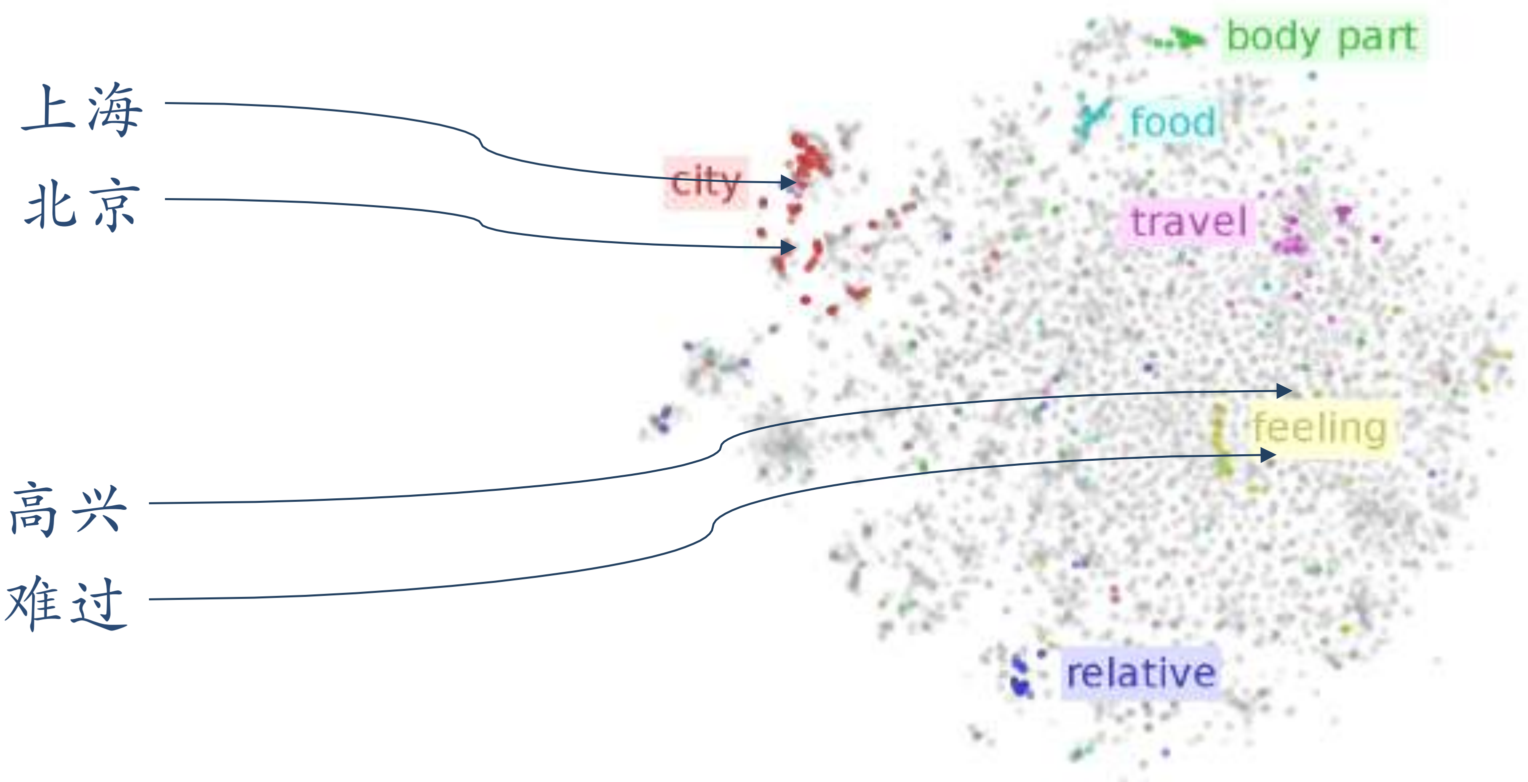

https://indico.io/blog/visualizing-with-t-sne/

分布式表示

--来自神经科学的证据

http://www.nature.com/nature/journal/v532/n7600/full/nature17637.html

词嵌入

W("woman")−W("man") ≃ W("aunt")−W("uncle")

W("woman")−W("man") ≃ W("queen")−W("king")

W("中国")−W("北京") ≃ W("英国")−W("伦敦")

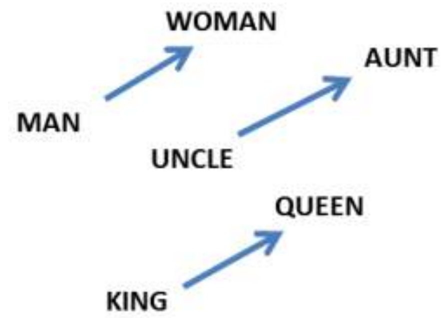

From Mikolov et al. (2013)

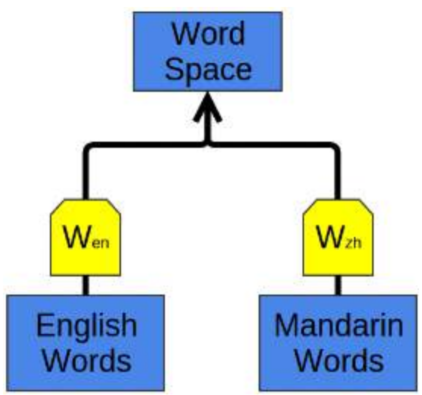

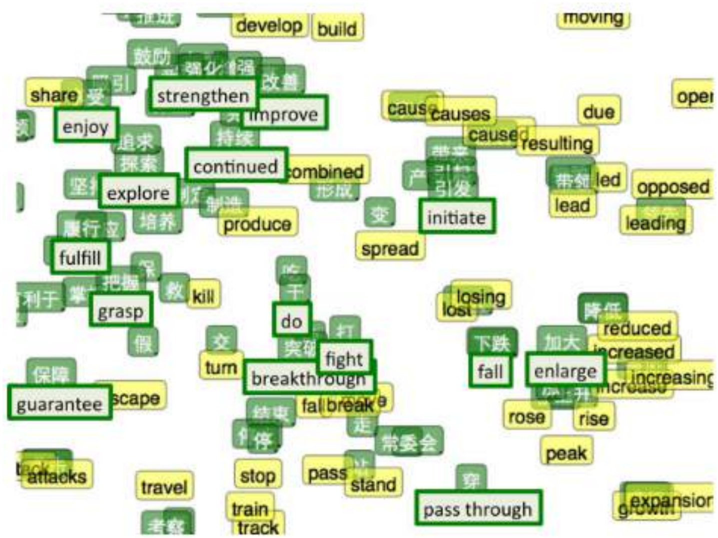

Socher et al. (2013)

句子表示

语言表示学习

- 词
- 短语
  - 组合语义模型
- 句子
  - 连续词袋模型
  - 序列模型
  - 递归组合模型
  - 卷积模型
- 篇章
  - 层次模型

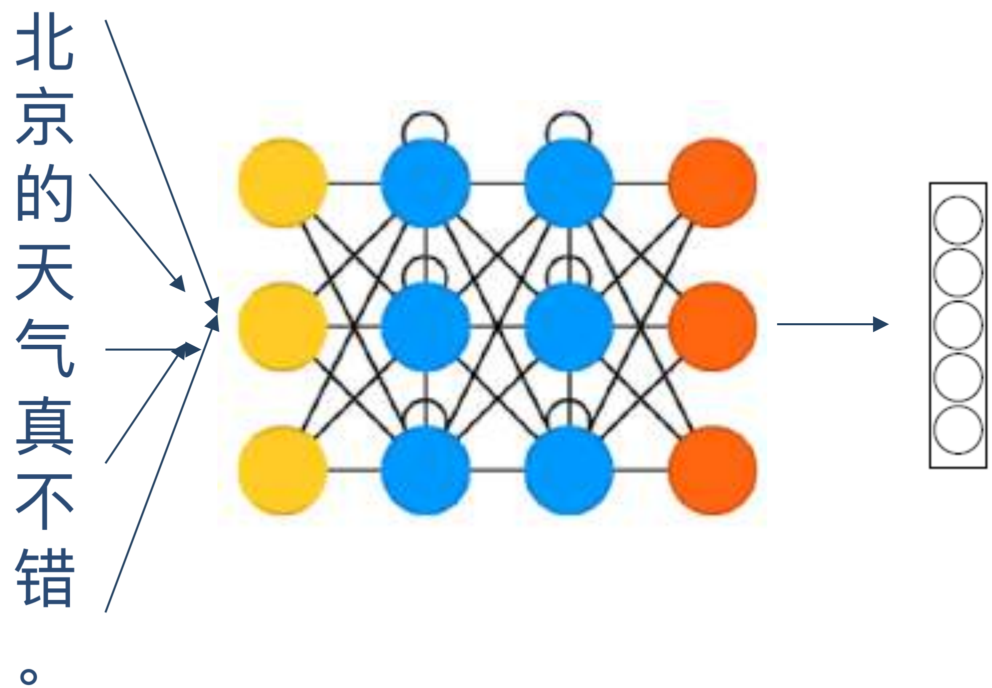

循环神经网络 (RNN)

缺点：长距离依赖问题

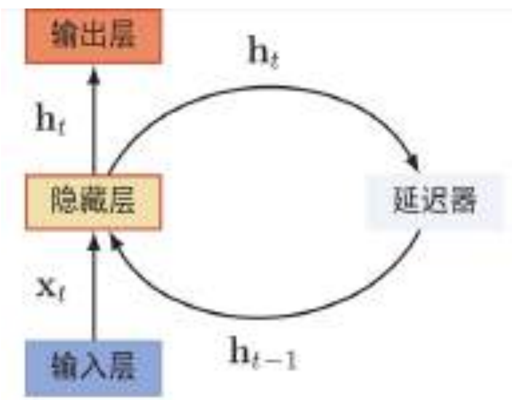

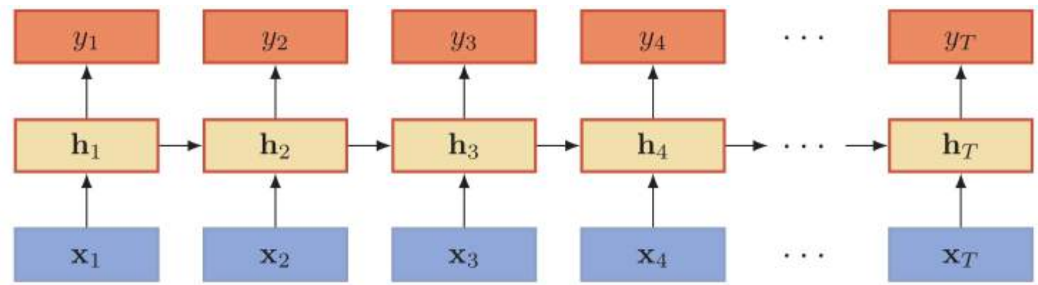

$$\mathbf{h}_t = \begin{cases} 0 & t = 0 \\ f(\mathbf{h}_{t-1}, \mathbf{x}_t) & \text{otherwise} \end{cases}$$

RNN是图灵完全等价的 (Siegelmann and Sontag, 1995)

FNN：模拟任何函数

RNN：模拟任何程序（计算过程）。

序列模型：RNN

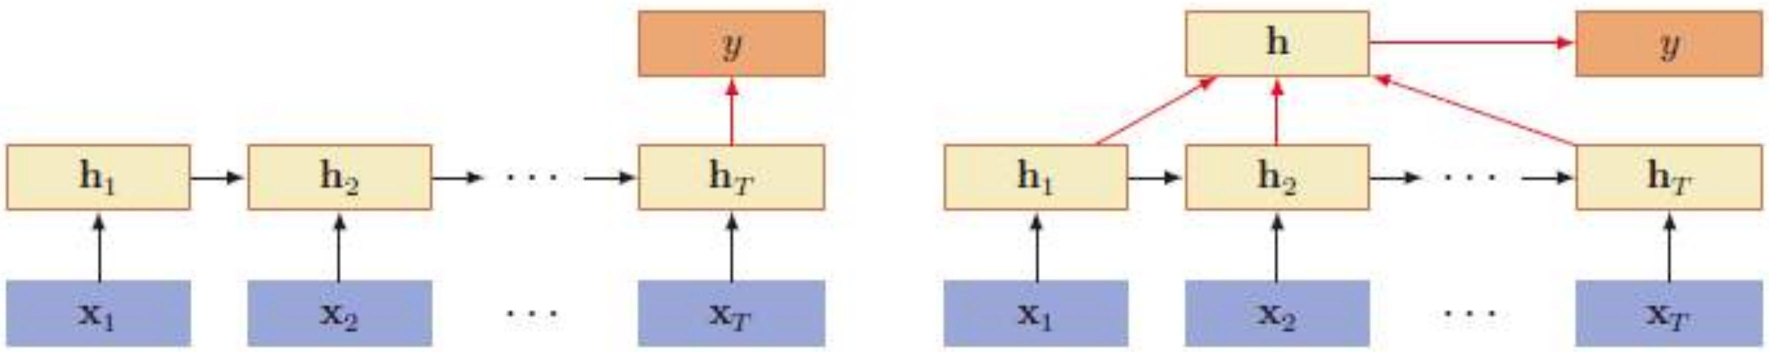

(a) 正常模式　　(b) 按时间进行平均采样模式

序列到序列模型

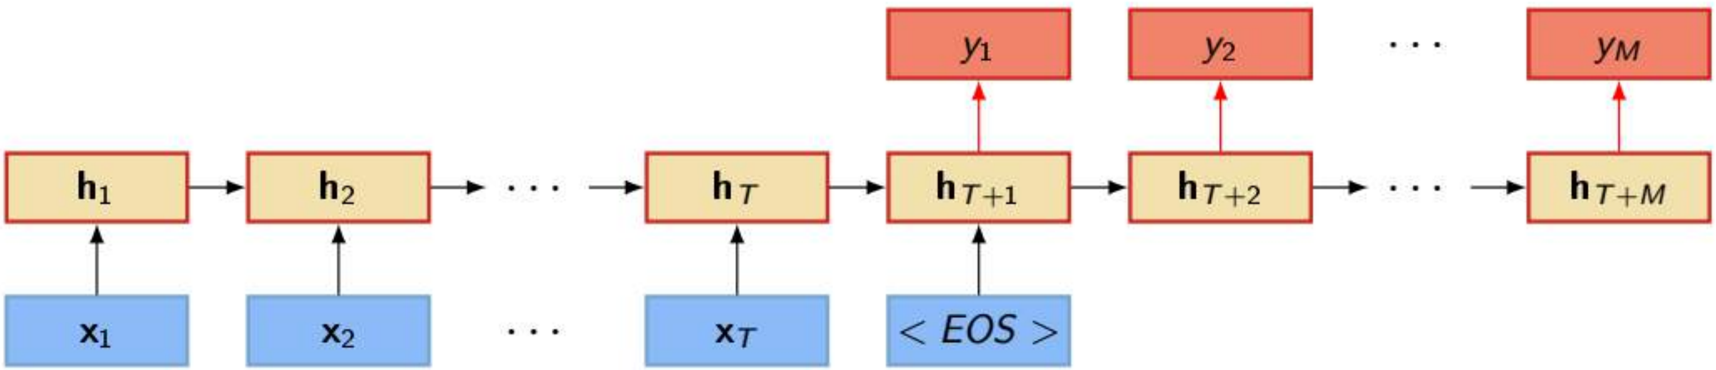

y_1
y_2
$\cdots$
y_M
$\mathbf{h}_1$
$\mathbf{h}_2$
$\cdots$
$\mathbf{h}_T$
$\mathbf{h}_{T+1}$
$\mathbf{h}_{T+2}$
$\cdots$
$\mathbf{h}_{T+M}$
$\mathbf{x}_1$
$\mathbf{x}_2$
$\cdots$
$\mathbf{x}_T$
$< EOS >$

文本序列的卷积

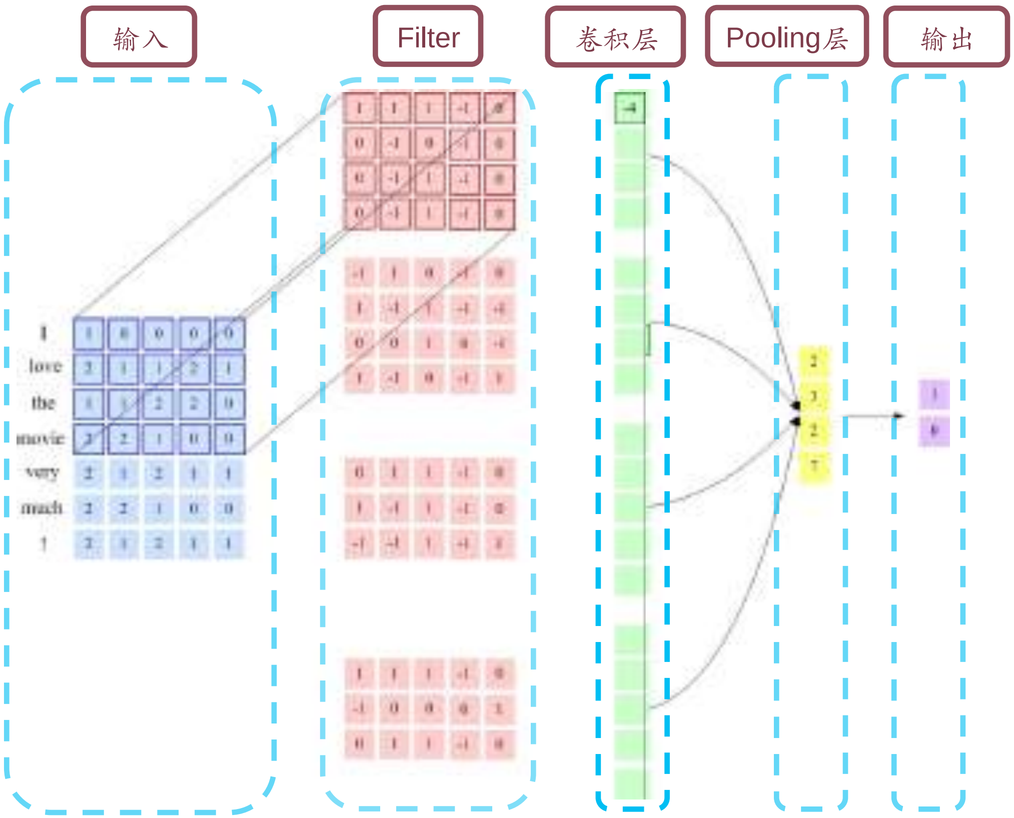

基于卷积模型的句子表示

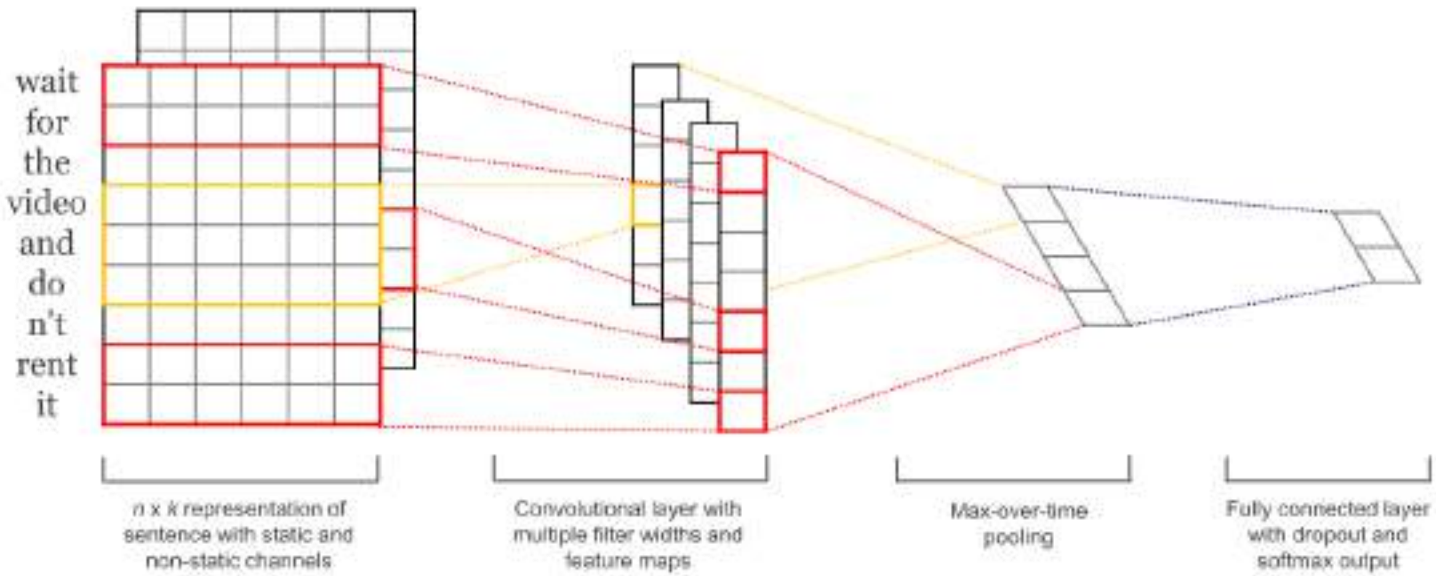

Y. Kim. “Convolutional neural networks for sentence classification”. In: *arXiv preprint arXiv:1408.5882* (2014).

递归神经网络

给定一个语法树，

$p_2 \rightarrow ap_1,$

$p_1 \rightarrow bc.$

$$\mathbf{p}_1 = f(\mathbf{W}\begin{bmatrix}\mathbf{b}\\ \mathbf{c}\end{bmatrix}),$$

$$\mathbf{p}_2 = f(\mathbf{W}\begin{bmatrix}\mathbf{a}\\ \mathbf{p}_1\end{bmatrix}).$$

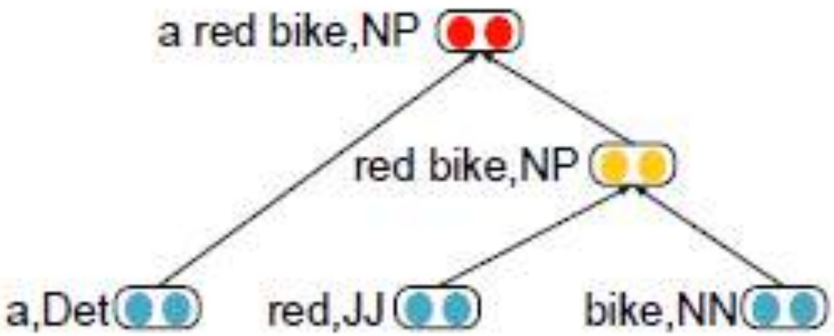

语言表示学习

		表示学习模型	
		词	句子、篇章
离散表示	符号表示	One-Hot表示	词袋模型 N元模型
	基于聚类的表示	Brown聚类	K-means聚类
连续表示	分布式表示	潜在语义分析 潜在狄利克雷分配	
	分散式表示	NNLM Skip-Gram模型 CBOW模型	连续词袋模型 序列模型 递归组合模型 卷积模型

为什么语言表示学习更难？

152 层

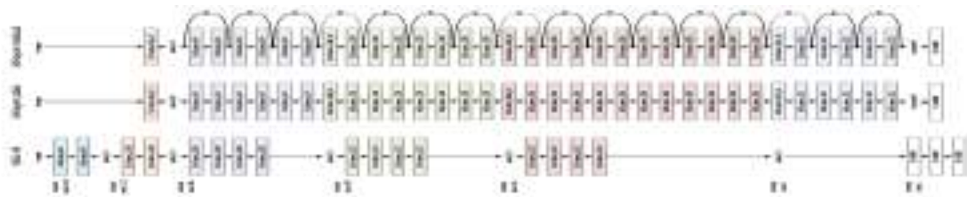

22层

计算机视觉中的深层网络模型

Results:

- golden retriever: 0.97293
- Tibetan mastiff: 0.01576
- Irish setter: 0.00364
- redbone: 0.00152
- standard poodle: 0.00127

对应NLP的最底层：词汇

语言表示的几个问题

认知层面
- 主观性
- 常识
- 知识

模型层面
- 长期依赖问题
- 语义组合问题

学习层面
- 迁移学习
- 多任务学习

长期依赖问题

- 梯度消失/爆炸（主要因素）
  - 改进：引入一个近似线性依赖的记忆单元来存储远距离的信息。
- 记忆容量（次要因素）
  - 记忆单元的存储能力和其大小相关。
  - 改进：注意力机制与外部记忆

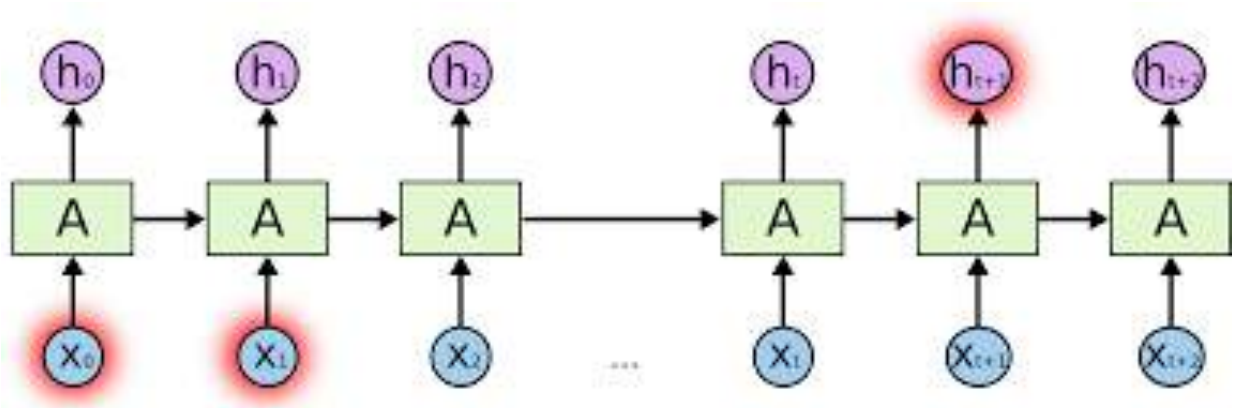

注意力模型

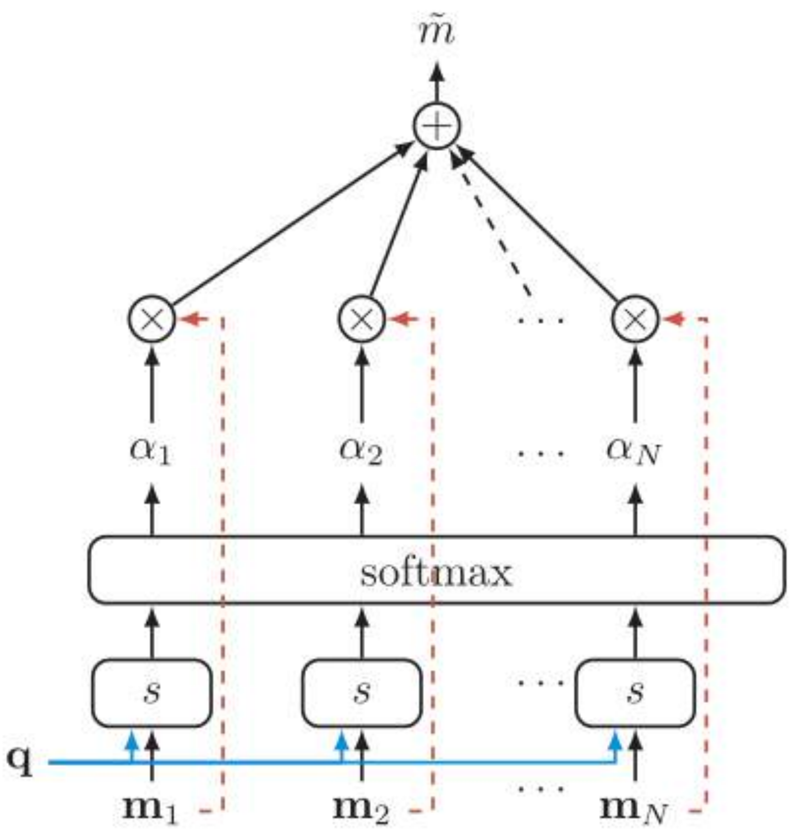

(a) 普通模式

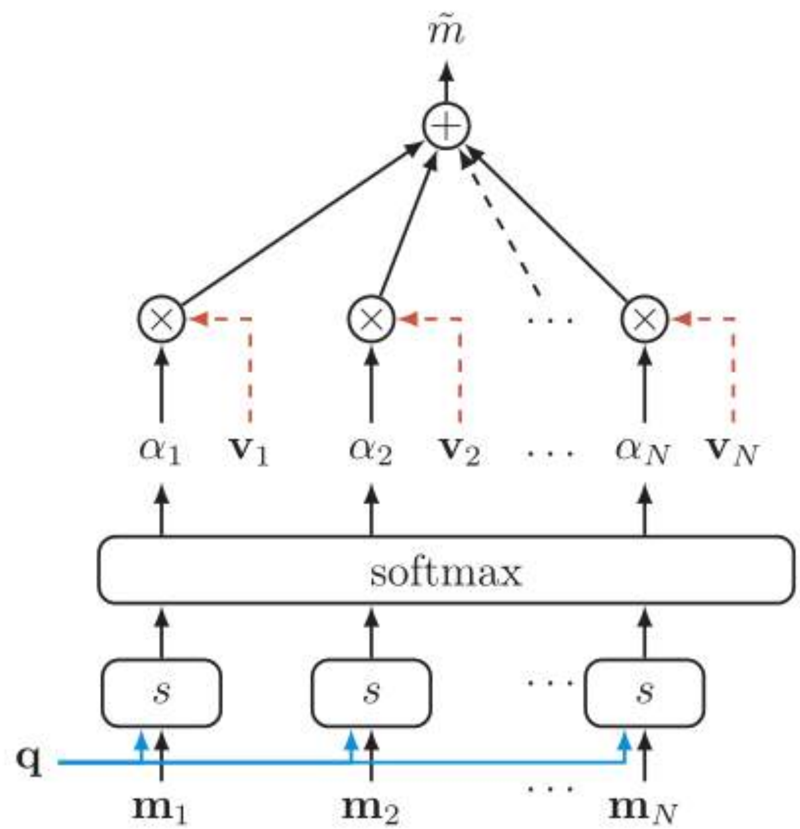

(b) 键值对模式

语言语义组合

- 如何组合自然语言的语义?
- 参数共享?

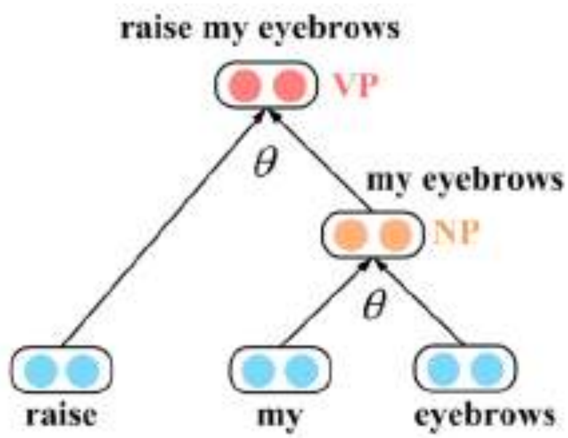

共享

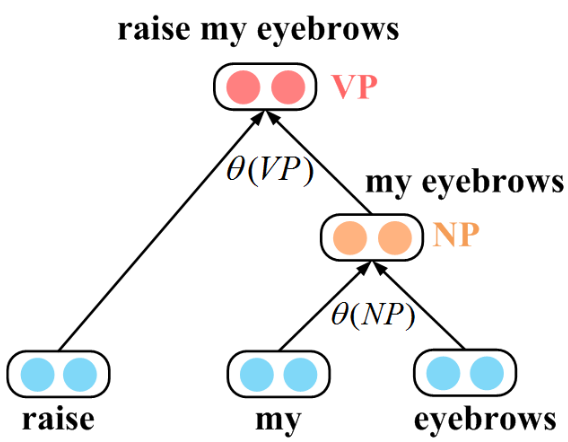

不共享

动态语义组合网络

- 元网络（Meta network）
  - 生成基网络参数
- 基网络（Basic Network）
  - 动态参数

Pengfei Liu, Xipeng Qiu, Xuanjing Huang, Dynamic Compositional Neural Networks over Tree Structure, In Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence (IJCAI), pp. 4054-4060, 2017.

Pengfei Liu, Kaiyu Qian, Xipeng Qiu, Xuanjing Huang, Idiom-Aware Compositional Distributed Semantics, In Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing (EMNLP), pp. 1215-1224, 2017.

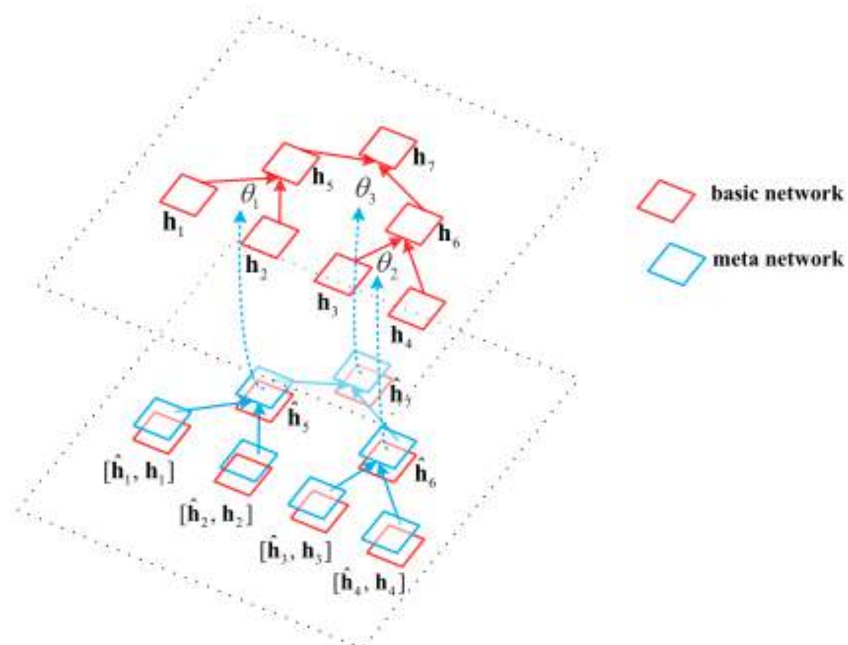

多任务学习

Hashimoto, K., Xiong, C., Tsuruoka, Y., & Socher, R. (2016). A Joint Many-Task Model: Growing a Neural Network for Multiple NLP Tasks. arXiv Preprint arXiv:1611.01587.

- 知识共享
  - 词性标注
  - 组块分析
  - 依次句法分析
  - 文本蕴涵

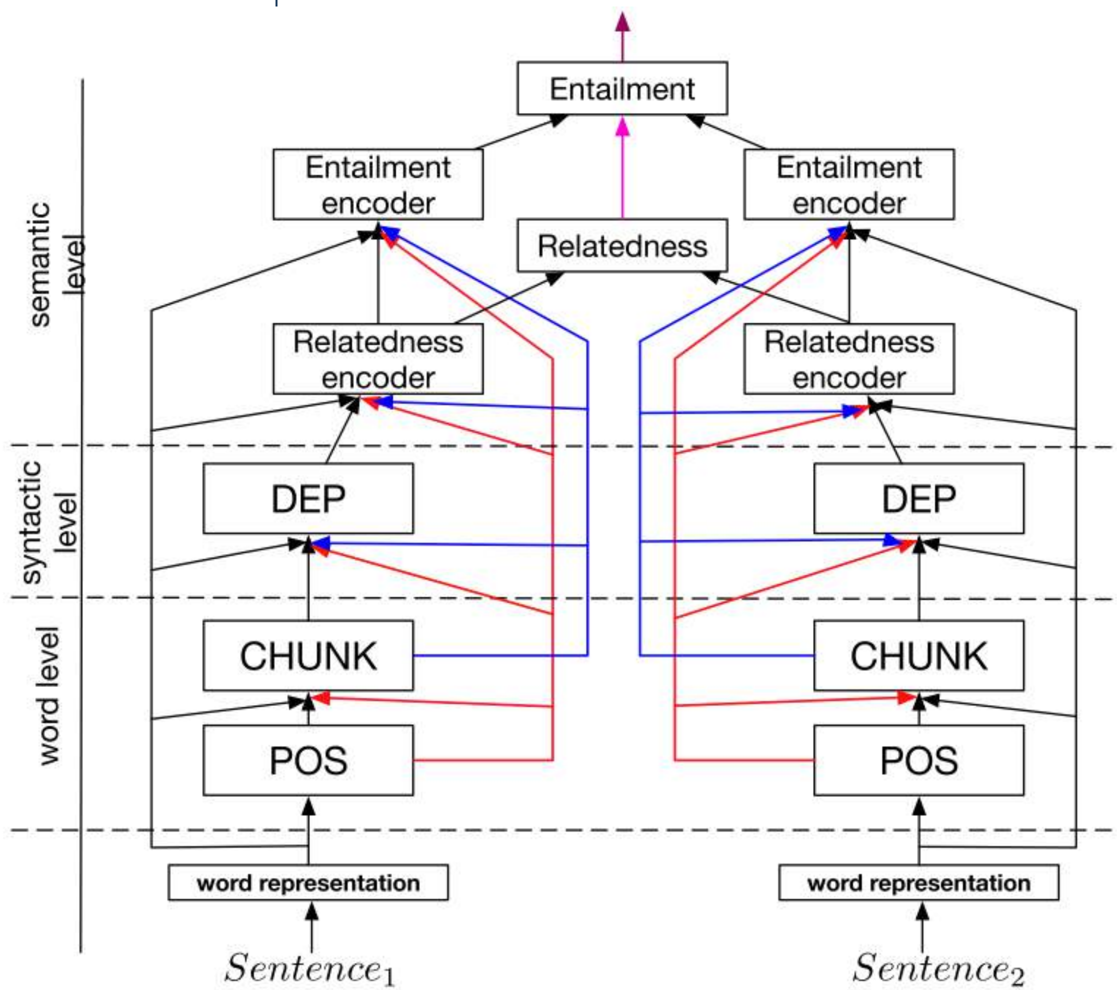

如何学习任务无关的共享表示

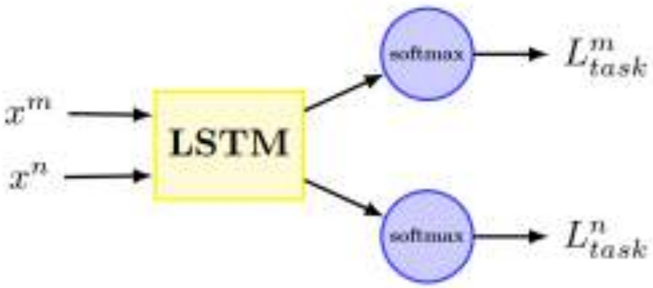

(a) Fully Shared Model (FS-MTL)

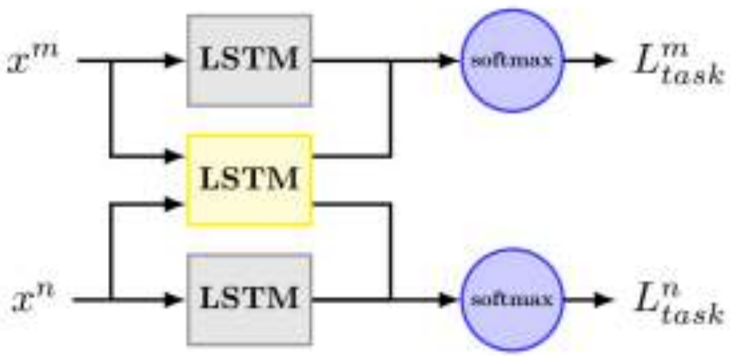

(b) Shared-Private Model (SP-MTL)

- 对抗学习

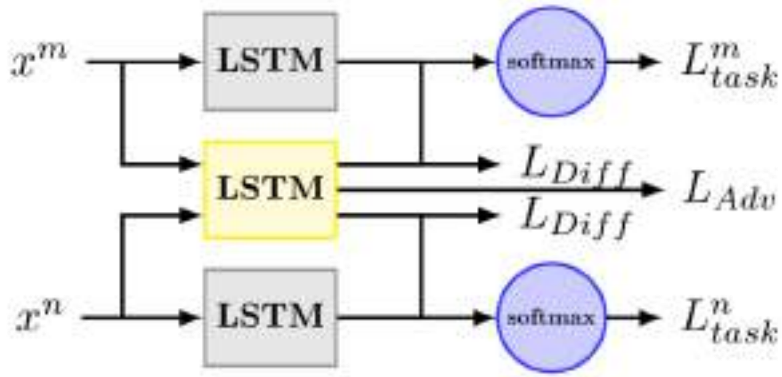

$$L = L_{Task} + \lambda L_{Adv} + \gamma L_{Diff}$$

Pengfei Liu, Xipeng Qiu, Xuanjing Huang, Adversarial Multi-task Learning for Text Classification, In Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (ACL), pp. 1-10, 2017.

自然语言处理的新范式

自然语言处理任务

- 在得到字、句子表示之后，自然语言处理任务类型划分为

- 类别（对象）到序列
  - 文本生成
  - 图像描述生成
- 序列到类别
  - 文本分类
  - 情感分析
- 同步的序列到序列
  - 中文分词
  - 词性标注
  - 语义角色标注
- 异步的序列到序列
  - 机器翻译
  - 自动摘要
  - 对话系统

减轻了对特征工程的依赖!

应用例子

传统统计机器翻译

- 源语言：f
- 目标语言：e
  - 模型：$\hat{e} = \arg\max_e p(e|f) = \arg\max_e p(f|e)p(e)$
  - p(f|e): 翻译模型
  - p(e)：语言模型

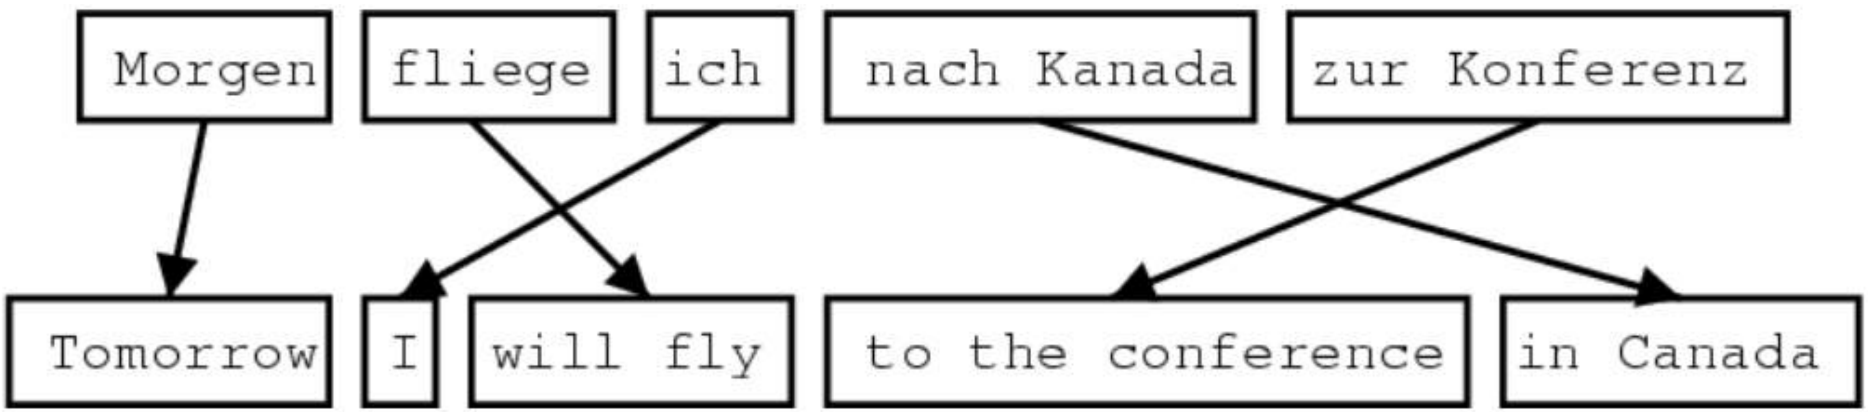

基于序列到序列的机器翻译

- 一个RNN用来编码
- 另一个RNN用来解码

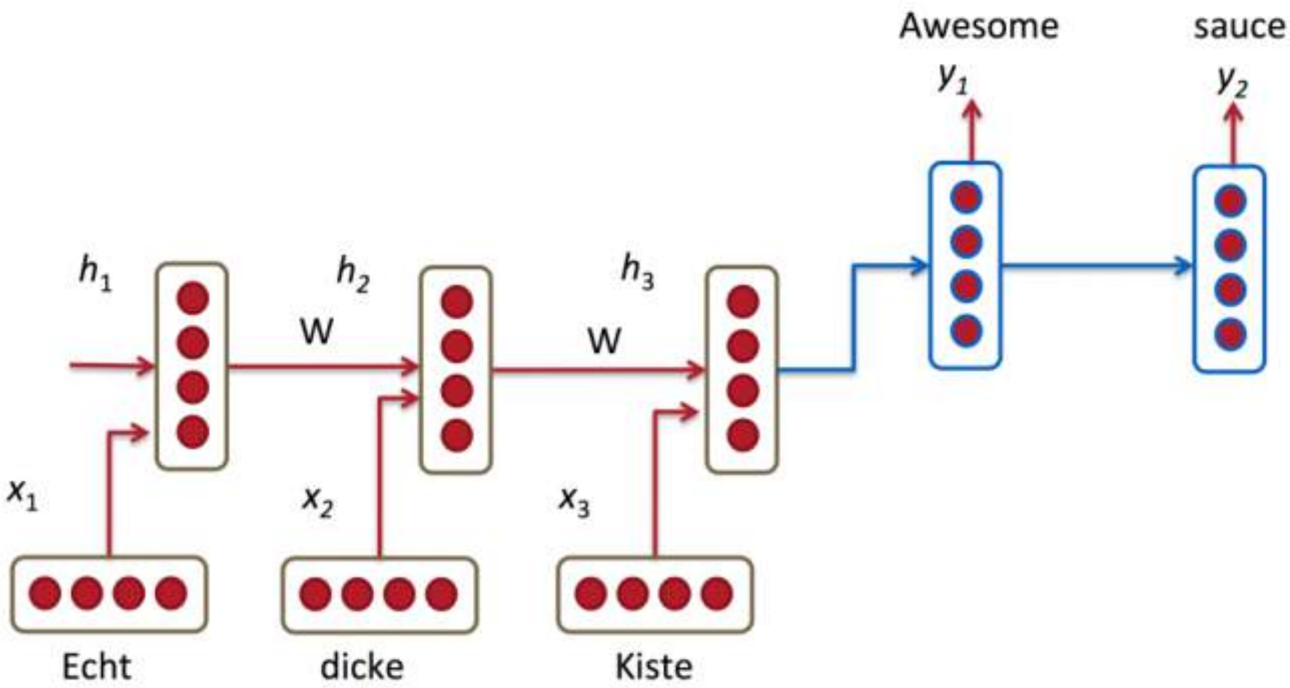

看图说话

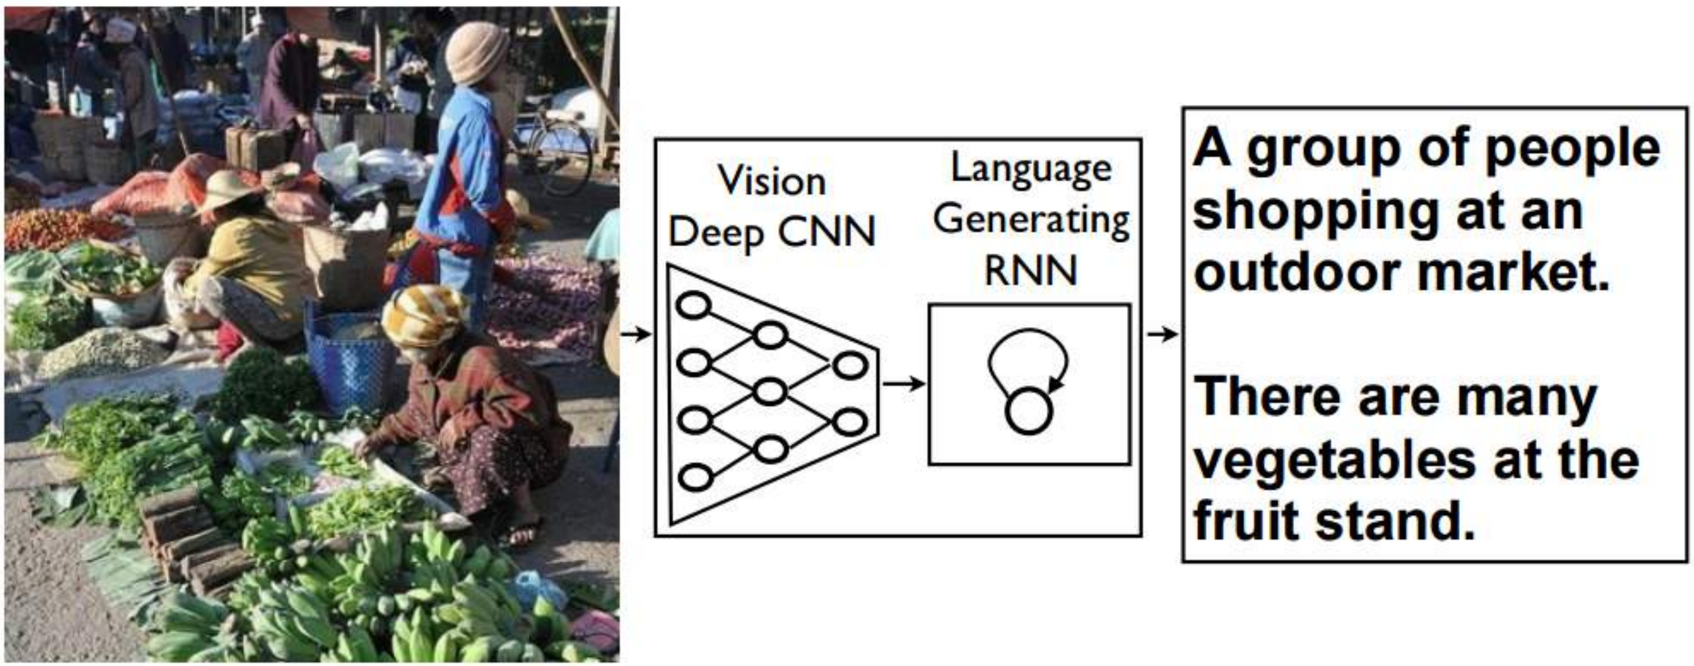
Vision
Deep CNN
Language
Generating
RNN
A group of people shopping at an outdoor market.
There are many vegetables at the fruit stand.

看图说话

Figure 5. A selection of evaluation results, grouped by human rating.

生成LINUX内核代码

```
/*
 * If this error is set, we will need anything right after that BSD.
 */
static void action_new_function(struct s_stat_info *wb)
{
  unsigned long flags;
  int lel_idx_bit = e->edd, *sys & ~((unsigned long) *FIRST_COMPAT);
  buf[0] = 0xFFFFFFFF & (bit << 4);
  min(inc, slist->bytes);
  printk(KERN_WARNING "Memory allocated %02x/%02x, "
    "original MLL instead\n"),
    min(min(multi_run - s->len, max) * num_data_in),
    frame_pos, sz + first_seg);
  div_u64_w(val, inb_p);
  spin_unlock(&disk->queue_lock);
  mutex_unlock(&s->sock->mutex);
  mutex_unlock(&func->mutex);
  return disassemble(info->pending_bh);
}

static void num_serial_settings(struct tty_struct *tty)
{
  if (tty == tty)
    disable_single_st_p(dev);
  pci_disable_spool(port);
```

作词机

- RNN在“学习”过汪峰全部作品后自动生成的歌词
  - 我在这里中的夜里
  - 就像一场是一种生命的意旪
  - 就像我的生活变得在我一样
  - 可我们这是一个知道
  - 我只是一天你会怎吗
  - 可我们这是我们的是不要为你
  - 我们想这有一种生活的时候

https://github.com/phunterlau/wangfeng-rnn

作诗

白鹭窥鱼立,	满怀风月一枝春,
Egrets stood, peeping fishes.	Budding branches are full of romance.
青山照水开.	未见梅花亦可人.
Water was still, reflecting mountains.	Plum blossoms are invisible but adorable.
夜来风不动,	不为东风无此客,
The wind went down by nightfall,	With the east wind comes Spring.
明月见楼台.	世间何处是前身.
as the moon came up by the tower.	Where on earth do I come from?

写字

- 把一个字母的书写轨迹看作是一连串的点。一个字母的“写法”其实是每一个点相对于前一个点的偏移量，记为(offset x, offset y)。再增加一维取值为0或1来记录是否应该“提笔”。

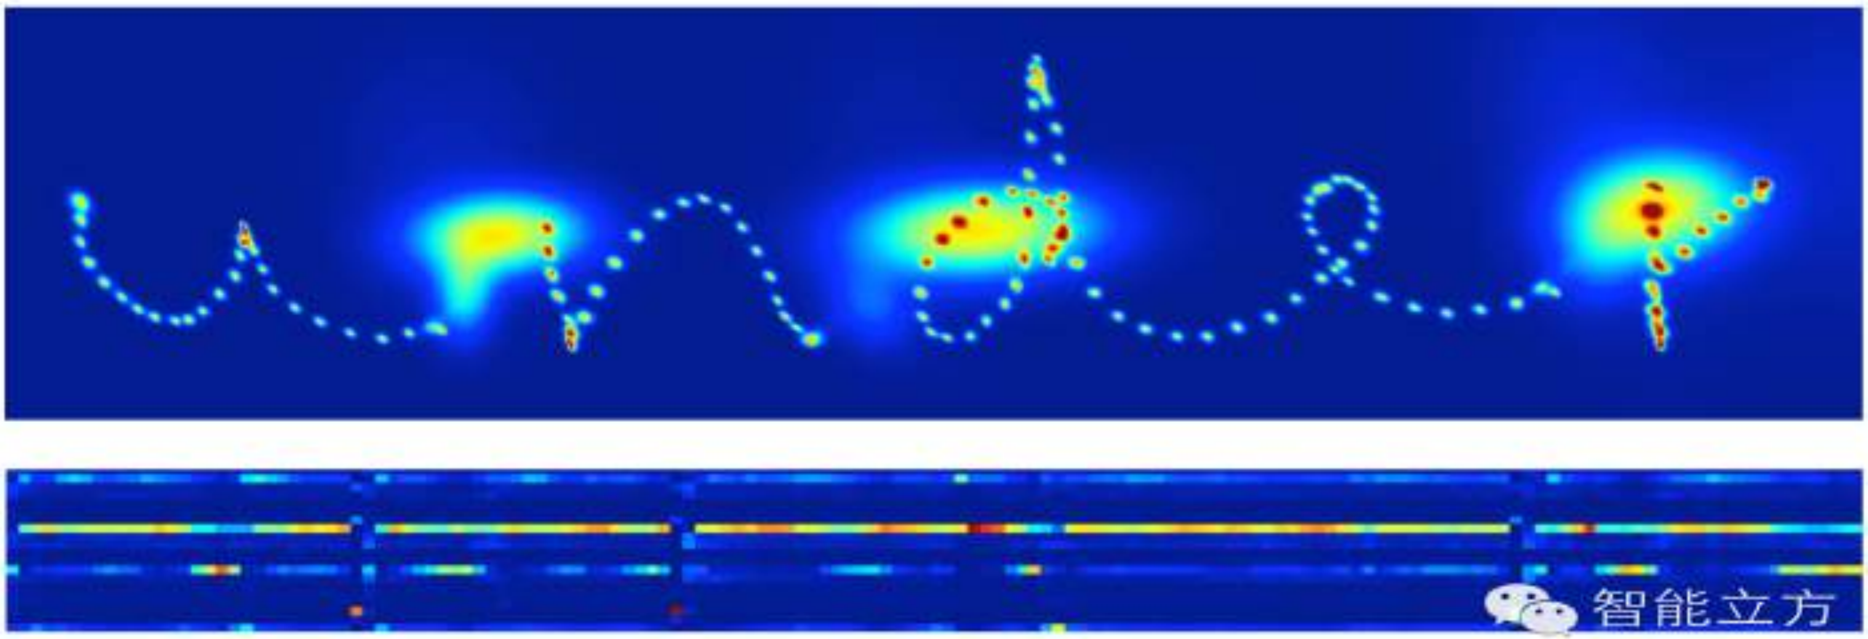

Making Neural Nets Great Again

Donald J. Trump @realDonaldTrump · May 30
The people are such a wonderful mistake in decades of my speech at the @nytimes yesterday. Big crowd! #Trump2016 pic.twitter.com/XW060pZbmm
7.2K 26K 97K

Donald J. Trump @realDonaldTrump · May 28
Last night was one of the worst things that Obama was a trillion dollar budget deficit with a single defeat. I won't report the truth and thanks.
50K 28K 106K

Donald J. Trump @realDonaldTrump · May 28
Congratulations to @HuffingtonPost poll with @MittRomney today. Be sure to watch the Trump Tower atrium. It should not be the most beautiful money on me. They will be a big loser and special interest money.
21K 14K 66K

Donald J. Trump @realDonaldTrump · May 28
The Trump Tower atrium is so great honor to be indeceing on chockey supporters at the Miss Universe Pageant. I think it should be dead, finally, billions of incredible!
18K 19K 74K

Donald J. Trump @realDonaldTrump · May 28
Why would the fact that I left the Democrats that he has a show that is a complete and money to a bad deal. Stop congratulating the U.S. Starting the bankruptcy proud. What a festing career!
21K 14K 79K

阅读理解

- 三元组（Q,D,A）
- 问题Q： $(q_1, q_2, \cdots, q_m)$
- 文档D: $(x_1, x_2, \cdots, x_n)$
- 答案A: $x_s, \cdots, x_e$

Fred moved to the bedroom and Joe went to the kitchen then Joe took the milk there and Dan journeyed to the bedroom; Joe discarded the milk.

Where is the milk now ?
A: the milk is in the kitchen

Where is Dan now?
A: I think he is in the bedroom

SIMULATED WORLD QA

一般流程

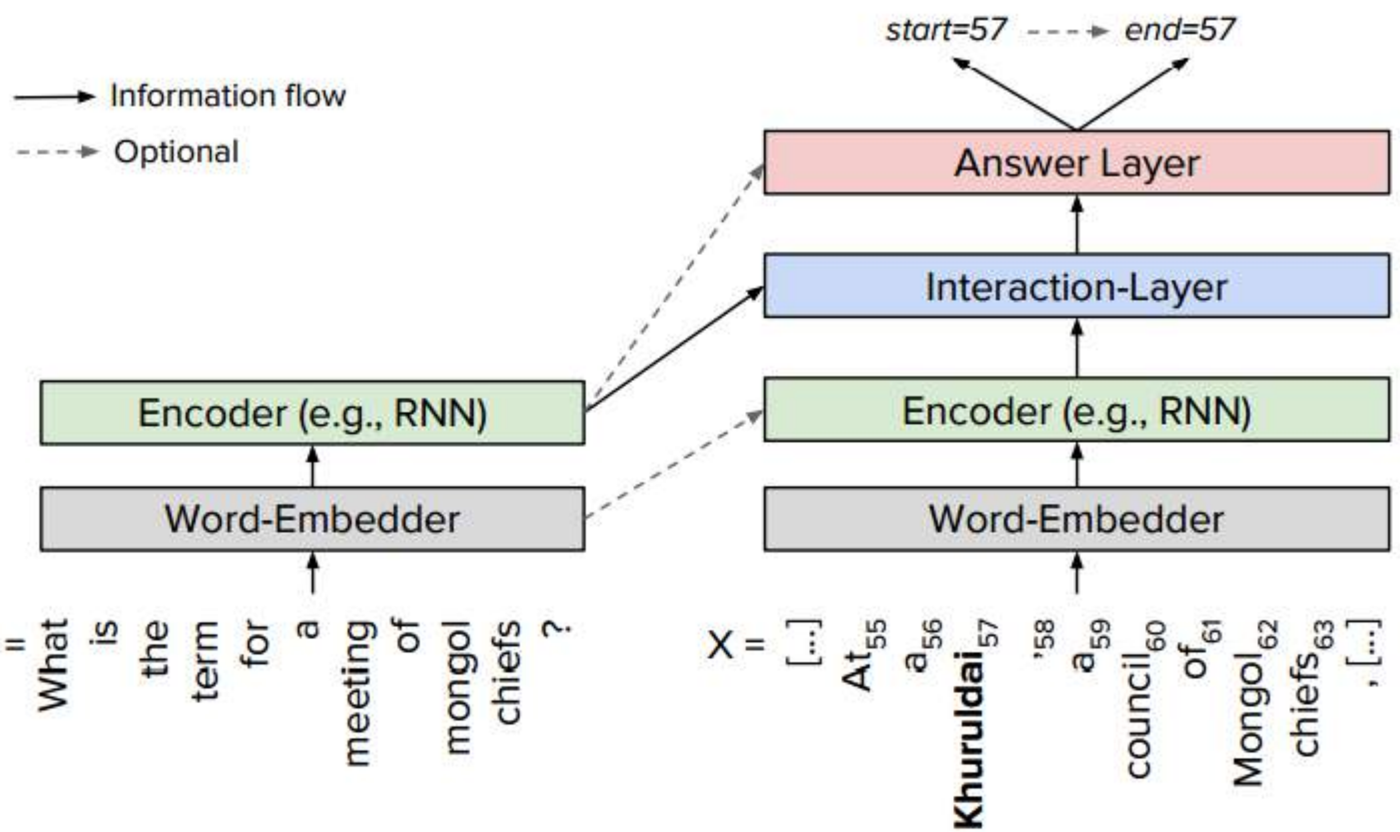
start=57
end=57
Information flow
Optional
Answer Layer
Interaction-Layer
Encoder (e.g., RNN)
Word-Embedder
Encoder (e.g., RNN)
Word-Embedder
What is the term for a meeting of mongol chiefs ?
X = [...] At55 a56 Khuruldai57 '58 a59 council60 of61 Mongol62 chiefs63 , [...]

Bidirectional Attention (Seo et al.,2016)

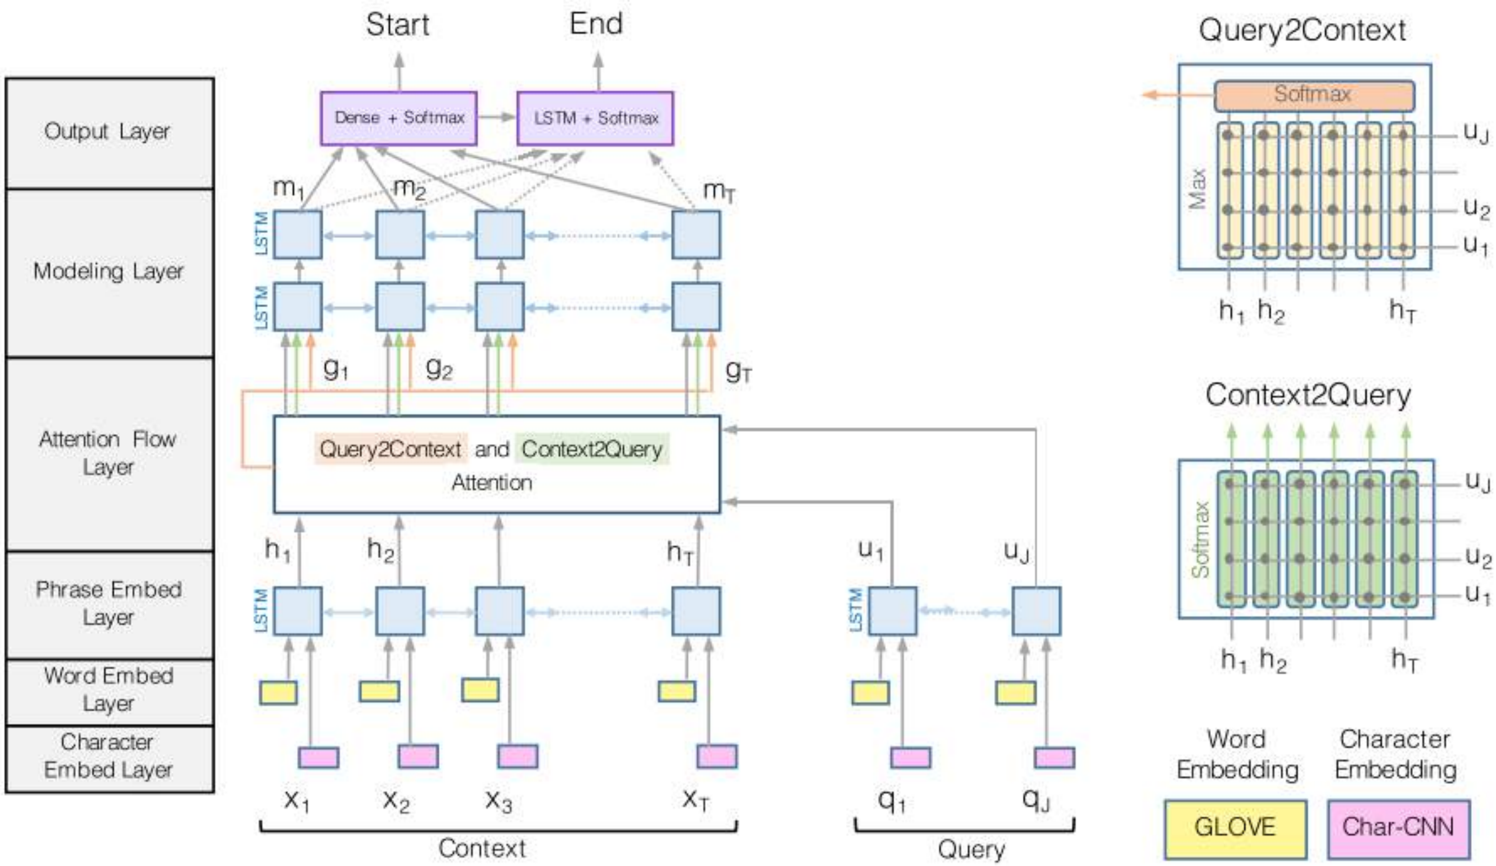

Mnemonic Reader

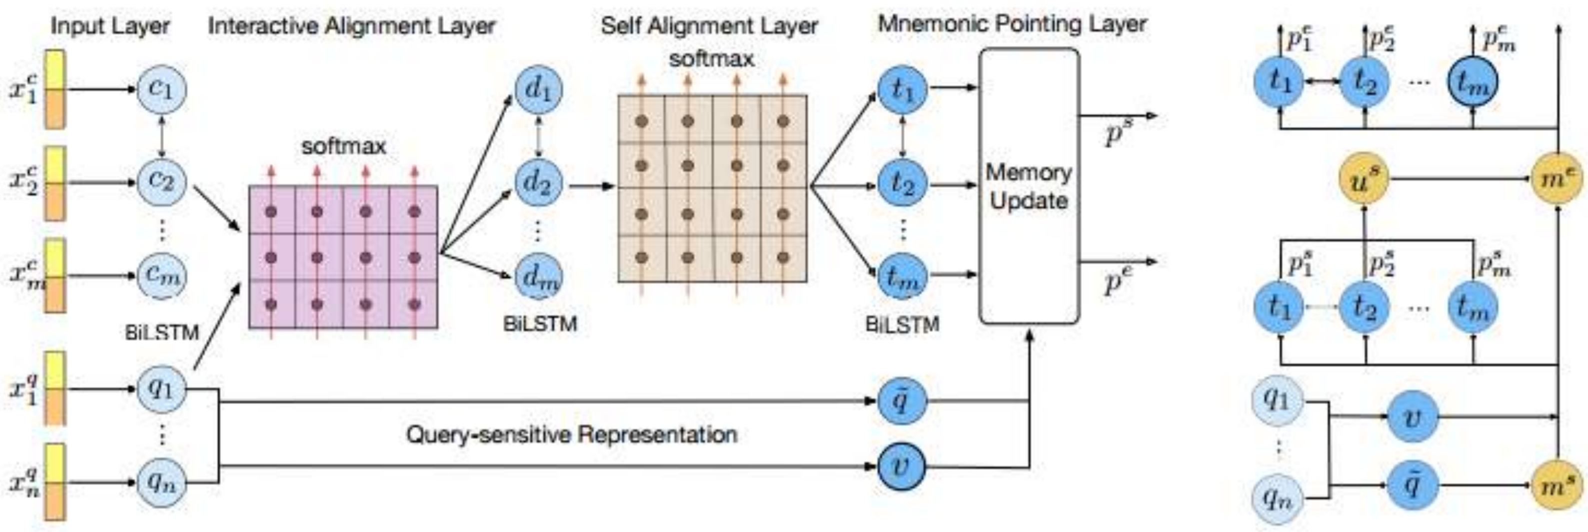

(a) A high level overview of Mnemonic Reader.

(b) The detailed one-hop schematic of mnemonic pointing layer.

https://arxiv.org/abs/1705.02798

文本摘要

http://www.abigailsee.com/2017/04/16
/taming-rnns-for-better-summarization.html

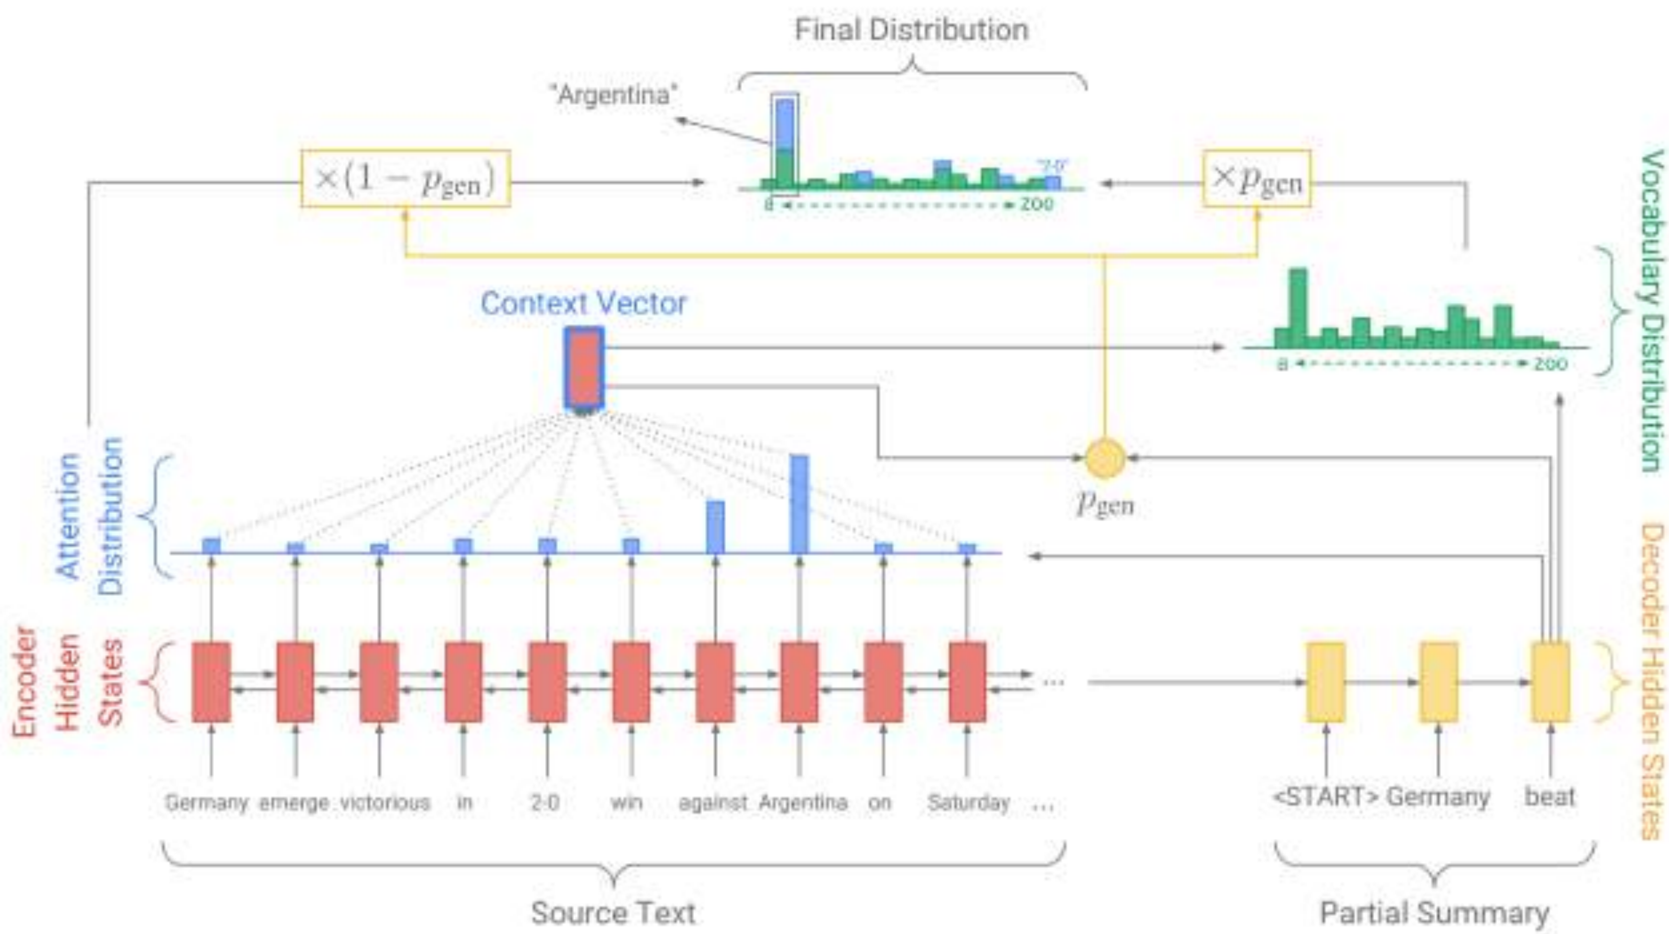

文本摘要

http://www.abigailsee.com/2017/04/16/taming-rnns-for-better-summarization.html

Reference summary

utility back francis *saili* will join up with munster later this year .
the new zealand international has signed a two-year contract .
saili made his debut for the all blacks against argentina in 2013 .

Sequence-to-sequence + attention summary

dutch international francis [UNK] has signed a two-year deal to join irish [UNK] super rugby side the blues .
[UNK] 's signature is something of a coup for munster and his head coach anthony foley believes he will be a great addition to their respective prospects .
[UNK] has been capped twice by new zealand .

Pointer-generator summary

new zealand international francis *saili* will move to the province later this year .
utility back *saili* made his all blacks debut against argentina in 2013 .
utility back *saili* will move to the province later this year .

Pointer-generator model + coverage summary

francis *saili* has signed a two-year deal to join munster later this year .
the 24-year-old was part of the new zealand under-20 side that won the junior world championship in italy in 2011 .
saili 's signature is something of a coup for munster and head coach anthony foley .

对话

Li J, Monroe W, Ritter A, et al. Deep reinforcement learning for dialogue generation[J]. arXiv preprint arXiv:1606.01541, 2016.

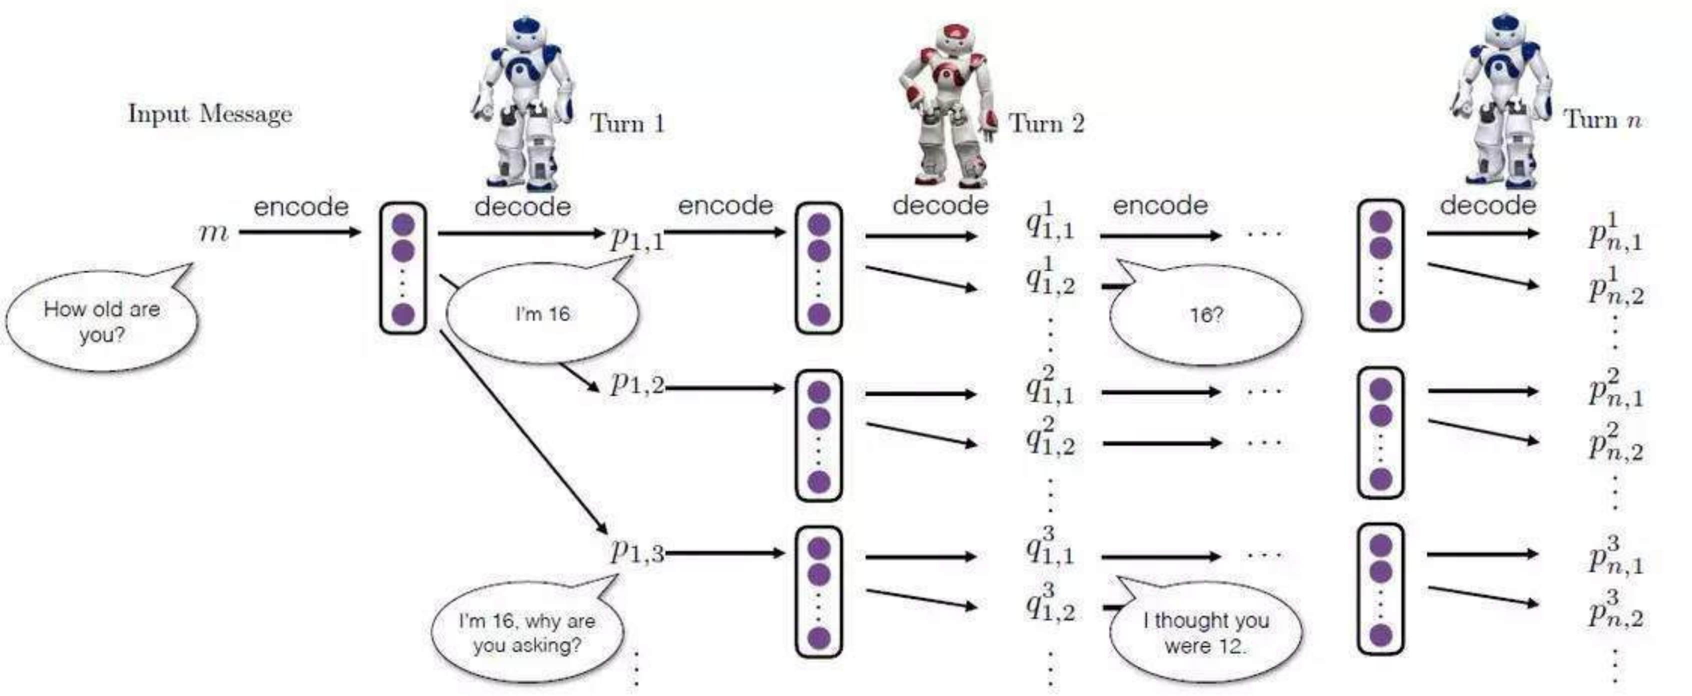

Figure 1: Dialogue simulation between the two agents.

总结

总结

- 模型

离散表示
+
线性模型

→

分布式表示
+
非线性模型

- 任务

理解 → 生成 → 交互

研究现状


ONE-SIZE FITS ALL
STORE
SALE

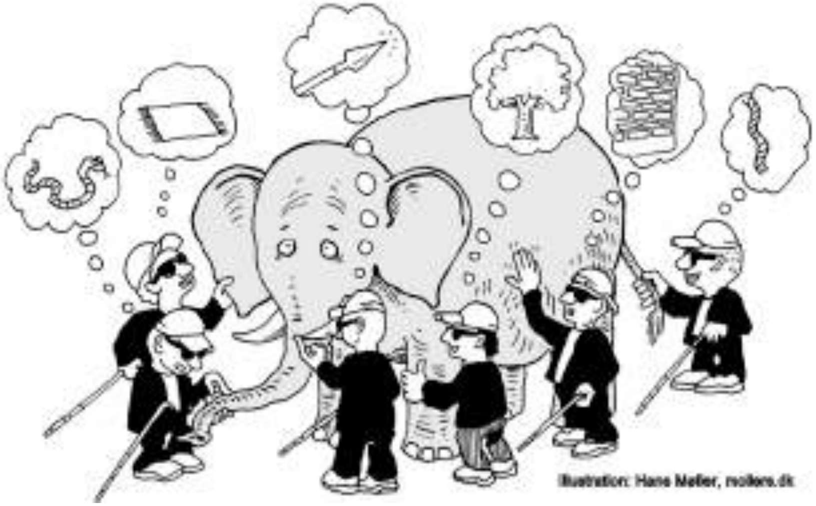
Illustration: Hans Møller, mollers.dk

Lapata's scream

[Lapata ACL talk 2017]

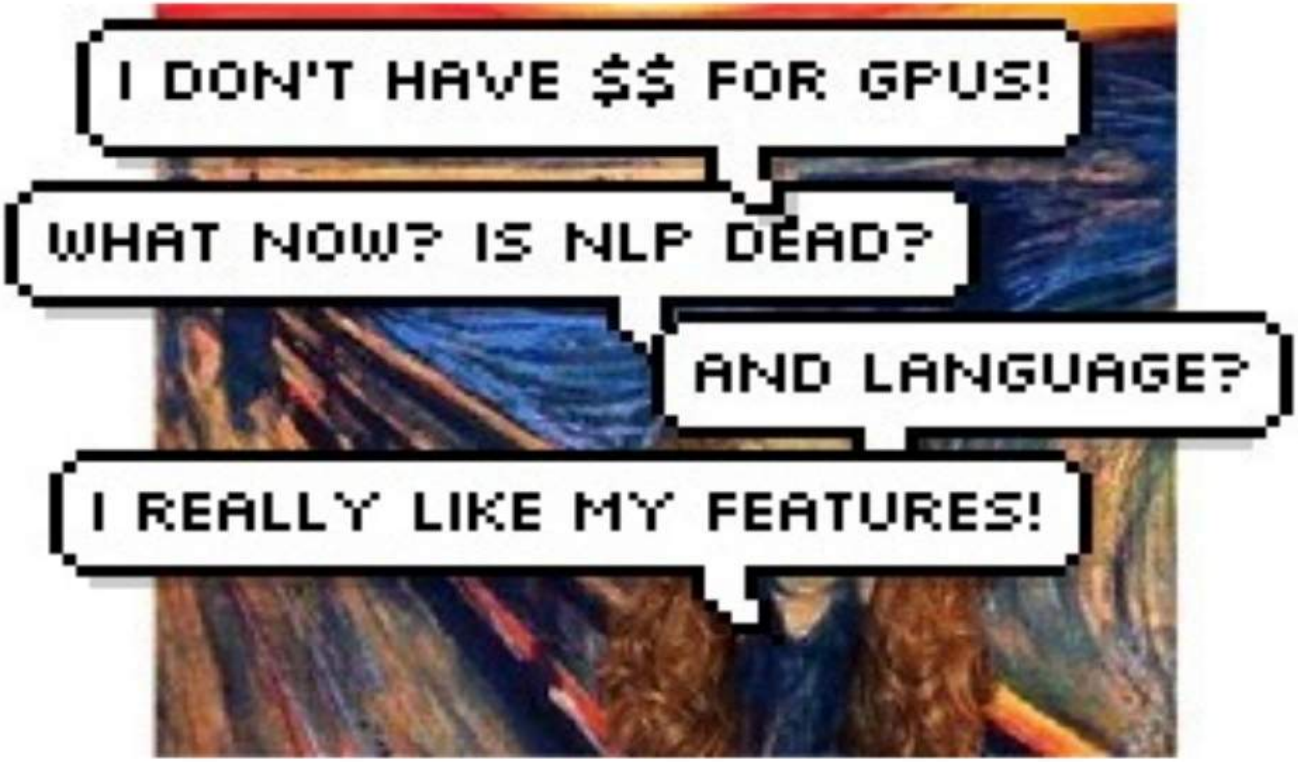

Noah's Bias

[Smith ACL talk 2017]

(structural)

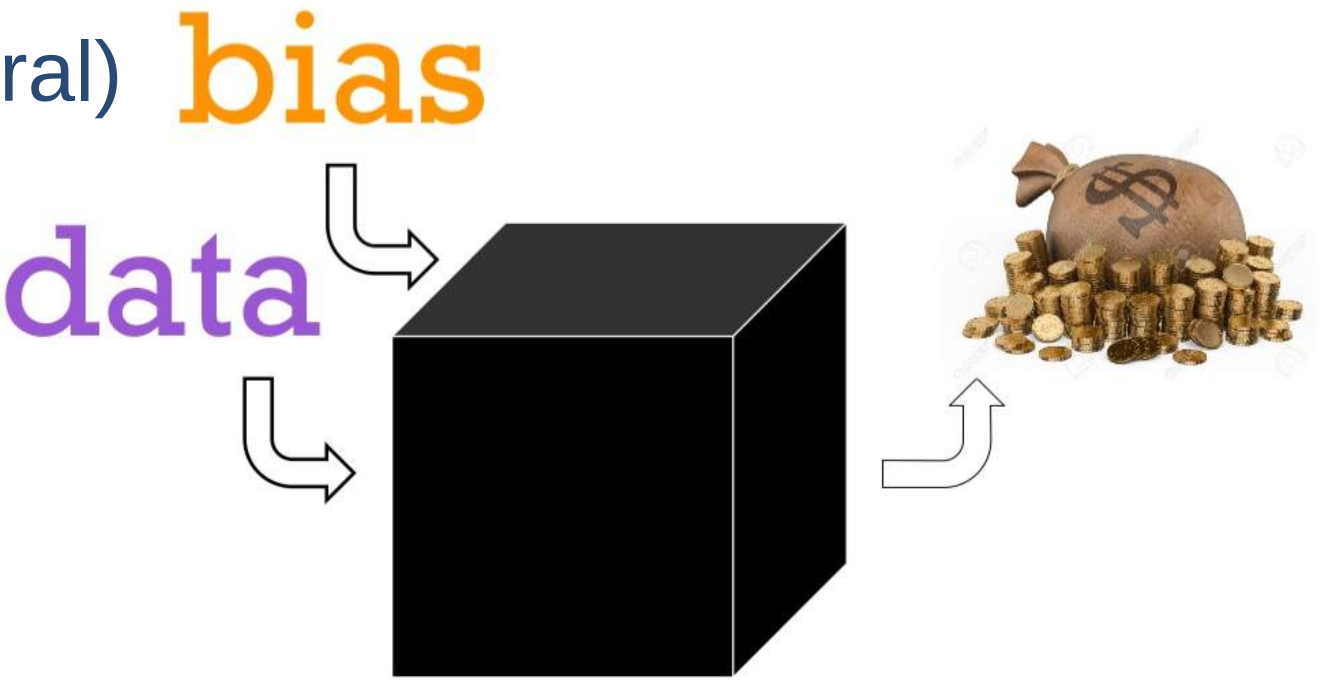

Putting things together

DL

function approximation

RL

correct training

NLP

structural bias

AlphaGo

?