

# 簡介AI文字處理技術與應用

淡江大學資訊管理學系

魏世杰副教授

[sekewei@mail.tku.edu.tw](mailto:sekewei@mail.tku.edu.tw)

# 大綱

- ▶ 語料前處理
- ▶ 文字的向量表示法
- ▶ 文字的比對法
- ▶ 文字檢索的技術與應用
- ▶ 文字探勘的技術與應用
- ▶ 文字生成的技術與應用
- ▶ 現況與未來

# 語料前處理

- ▶ 語料集(Corpus)
  - ▶ 單語系(Monolingual)
  - ▶ 雙語系(Bilingual): 平行語料(Parallel Corpus)
  - ▶ 網頁蒐集工具: scrapy, Beautiful Soup
- ▶ 單語化工具 → 系統字彙(Lexicon)
  - ▶ 英文: nltk
  - ▶ 中文: Jieba, MMSeg, CKIP斷詞系統
  - ▶ 日文: MeCab, ChaSen, Juman++
- ▶ 詞性 (POS, Parts of Speech)

# 文字的向量表示法

## ▶ 詞向量

- ▶ 單熱向量 (One Hot Vector): 稀疏向量，每個維度代表某詞有無。只有代表該詞維度為1，其餘維度皆為0
- ▶ 內嵌向量 (Embedding Vector): 緊密向量，每個維度代表某綜合成份意義。很少維度值為0


## ▶ 文件向量

- ▶ 布林向量
- ▶ TF-IDF向量
- ▶ 內嵌向量

**Table 4.6 A small document collection: six documents over 10 terms.**


$d$	Document $D_d$
1	Pease porridge hot, pease porridge cold,
2	Pease porridge in the pot,
3	Nine days old.
4	In the pot cold, in the pot hot,
5	Pease porridge, pease porridge,
6	Eat the lot.

# 如何訓練內嵌詞向量(Embedding Word Vector)



- ▶ 以下3種詞向量表示法皆提供預先訓練好的詞向量供下載使用
  - Google Word2vec: Skip Gram (SG) or Continuous Bag of Words (CBoW)
  - Stanford Glove
  - Facebook Fasttext

# Word2Vec訓練法



# Word2Vec訓練資料

假設視窗大小為前後1個字

## Source Text

(Here highlighted word is centre word)

Training sample  
OR  
Word paring

I like deep learning.



(I, like)

I like **like** deep learning.



(like, deep)  
(like, I)

I like **deep** learning.



(deep, learning)  
(deep, like)

I like deep **learning**.



(learning, .)  
(learning, deep)

(Thanaki, 2016)


## 詞向量訓練結果1: 群聚性(Clustering)

(Thanaki, 2016)



## 詞向量訓練結果2: 類推性(Analogy)

- ▶ king - queen + princess = ?
- ▶ computer\_programmer - man + woman = ?
- ▶ doctor - father + mother = ?
- ▶ 發現偏見與去除偏見 (Jurafsky, 2018)



## 文字的比對法


詞向量或文件向量可利用向量內積，  
計算向量相似度，又稱餘弦相似度

兩向量夾角 $\theta \downarrow$ ，內積或餘弦值 $\uparrow$   
表示兩向量相似度 $\uparrow$

$$\begin{aligned}\text{sim}(d_1, d_2) &= \frac{\vec{V}(d_1) \cdot \vec{V}(d_2)}{|\vec{V}(d_1)| |\vec{V}(d_2)|} \\ &= \cos(\theta)\end{aligned}$$

(Manning, 2008)

► **Figure 6.10** Cosine similarity illustrated.  $\text{sim}(d_1, d_2) = \cos \theta$ .



布林向量表示法  
1表示詞出現  
0表示詞未出現

- ▶ 文章向量
- ▶ 查詢向量
- ▶ 內積相似度當作排名指標

**Table 4.7 Vectors for inner product calculation: (a) document vectors; (b) query vectors.**

(a)	d	Document vectors $\langle w_{d,t} \rangle$									
		col	day	eat	hot	lot	nin	old	pea	por	pot
	1	1	0	0	1	0	0	0	1	1	0
	2	0	0	0	0	0	0	0	1	1	1
	3	0	1	0	0	0	1	1	0	0	0
	4	1	0	0	1	0	0	0	0	0	1
	5	0	0	0	0	0	0	0	1	1	0
	6	0	0	1	0	1	0	0	0	0	0

(b)	eat	0	0	1	0	0	0	0	0	0	0
	hot porridge	0	0	0	1	0	0	0	0	1	0

where the operation  $\cdot$  is inner product multiplication. The *inner product* of two  $n$ -vectors  $X = \langle x_i \rangle$  and  $Y = \langle y_i \rangle$  is defined to be

$$X \cdot Y = \sum_{i=1}^n x_i y_i.$$

(Witten, 1999)

For example,

$$M(\text{hot porridge}, D_1) = (0, 0, 0, 1, 0, 0, 0, 0, 1, 0) \cdot (1, 0, 0, 1, 0, 0, 0, 1, 1, 0) = 2.$$

**Table 4.8 Application of the cosine measure: (a) term frequencies  $f_{d,t}$  and document weights; (b) cosine similarities for queries.**

(a)	$d$	Document vectors ( $w_{d,t}$ )										$W_d$
		col	day	eat	hot	lot	nin	old	pea	por	pot	
	1	1.0	0.0	0.0	1.0	0.0	0.0	0.0	1.7	1.7	0.0	2.78
	2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	1.0	1.73
	3	0.0	1.0	0.0	0.0	0.0	1.0	1.0	0.0	0.0	0.0	1.73
	4	1.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.7	2.21
	5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.7	1.7	0.0	2.39
	6	0.0	0.0	1.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	1.41
	$f_t$	2	1	1	2	1	1	1	3	3	2	
	$w_t$	1.39	1.95	1.95	1.39	1.95	1.95	1.95	1.10	1.10	1.39	

(b)	$d$	Query			
		eat		porridge	
		$W_q = 1.95$	$W_q = 1.10$	$W_q = 1.77$	$W_q = 3.55$
	1	0.00	0.61	0.66	0.19
	2	0.00	0.58	0.36	0.18
	3	0.00	0.00	0.00	0.63
	4	0.00	0.00	0.36	0.00
	5	0.00	0.71	0.44	0.22
	6	0.71	0.00	0.00	0.39
	Top	6	5	1	3

## TF-IDF向量表示法

TF文件內詞頻，表示詞代表文件能力

IDF詞出現文件數倒數，表示詞區別文件能力

兩值相乘愈大表示

詞愈能在資料集區別該文件

- ▶ 文章向量
- ▶ 查詢向量
- ▶ 內積相似度當作排名指標

(Witten, 1999)

# 評估指標

- ▶ 召回率=回傳相關文件數/相關文件數
- ▶ 精確率=回傳相關文件數/回傳文件數
- ▶ 召回率-精確率曲線圖




Figure 4.10 Recall-precision curve for ranking of Table 4.9.

Table 4.9 Example showing calculation of recall and precision: (a) rank order; (b) calculating effectiveness.

(a)	$r$	$R_r$	$P_r$	(b)	Recall	Precision	Interpolated precision
	1	R	10%	100%	0%	—	100%
	2	—	10%	50%	10%	100%	100%
	3	—	10%	33%	20%	50%	60%
	4	R	20%	50%	30%	60%	60%
	5	R	30%	60%	40%	57%	57%
	6	—	30%	50%	50%	42%	50%
	7	R	40%	57%	60%	46%	50%
	8	—	40%	50%	70%	50%	50%
	9	—	40%	44%	80%	50%	50%
	10	—	40%	40%	90%	47%	47%
	11	—	40%	36%	100%	45%	45%
	12	R	50%	42%	3-point average	53%	
	13	R	60%	46%	11-point average	61%	
	14	R	70%	50%			
	15	—	70%	47%			
	16	R	80%	50%			
	17	—	80%	47%			
	18	—	80%	44%			
	19	R	90%	47%			
	20	—	90%	45%			
	21	—	90%	43%			
	22	R	100%	45%			
	23	—	100%	43%			
	24	—	100%	42%			
	25	—	100%	40%			

# 文字檢索的技術與應用

- ▶ Text Retrieval 文字檢索
  - ▶ Tokenization 斷詞
  - ▶ Indexing 索引
  - ▶ Vector Representation 向量表示法
    - ▶ Document Vector v.s. Query Vector
    - ▶ Binary v.s. TF-IDF
  - ▶ Similarity Metric 相似度指標
    - ▶ Cosine Measure 餘弦值
  - ▶ Document Ranking 文件排名
  - ▶ Evaluation Metric 評估指標
    - ▶ Precision, Recall, BLEU
- ▶ Cf: Manning et al. (2008), Introduction to Information Retrieval

# 文字探勘的技術與應用

- ▶ 文件摘要：依句子重要度及多樣性決定留下哪些句子
- ▶ 文字雲：依詞重要度及多樣性決定留下哪些詞及其顯示的大小及位置
- ▶ 文件主題分析：依文件內不同詞的出現頻度自動為文件作主題成份分析
- ▶ 商品推薦：累積客戶喜好，和商品計算相似度
- ▶ 垃圾分析/情感分析/輿情分析：
  - ▶ 利用人工或機器學習判定正負面評價或類別
    - ▶ Input: 文件向量
    - ▶ Model: NaiveBayes/SVM/XGBoost/RandomForest/...
    - ▶ Output: 正負面評價或類別

# 產生文字雲之前的斷詞範例

```
documents = tokenizedDocument(textData);
documentsRaw = documents;
documents(1:10)
```

(Matlab, 2018)

```
ans =
10x1 tokenizedDocument:

 5 tokens: 吾輩 は 猫 で ある
 2 tokens: 夏目 漱石
 0 tokens:
 1 tokens: -
11 tokens: 吾輩 は 猫 で ある 。 名前 は まだ 無い 。
264 tokens: ど こ で 生 れ た か とんと 見 当 が つか ぬ 。 何 で も 薄 暗 い じめじめ し た 所 で ニヤー ニヤー 泣 い て いた
100 tokens: この 書 生 の 掌 の 裏 で し ば らく は よ い 心 持 に 坐 つ て お つ た が 、 し ば らく す と 非 常 な 速 力 で 逃
 92 tokens: ふ と 気 が 付 い て 見 る と 書 生 は い ない 。 た く さ ん お つ た 兄 弟 が 一 止 も 見 え ぬ 。 肝 心 の 母 母 さ
693 tokens: よ う や く の 思 い で 笹 原 を 這 い 出 す と 向 う に 大 き な 池 が あ る 。 吾 肆 は 池 の 前 に 坐 つ て ど う し な
276 tokens: 吾 肆 の 主 人 は 滅 多 に 吾 肆 と 顔 を 合 せ る 事 が な い 。 職 業 は 教 師 だ そ う だ 。 学 校 か ら 帰 る と 終
```

```
tdetails = tokenDetails(documents);  
size(tdetails)
```

```
ans = 1x2  
80472 7
```

## MeCab斷詞範例

```
head(tdetails)
```

(Matlab, 2018)

```
ans = 8x7 table
```

...

	Token	DocumentNumber	LineNumber	Type	Language	PartOfSpeech
1	"吾輩"	1	1	letters	ja	pronoun
2	"猫"	1	1	letters	ja	noun
3	"夏目"	2	1	letters	ja	proper-noun
4	"漱石"	2	1	letters	ja	proper-noun
5	"吾輩"	3	1	letters	ja	pronoun
6	"猫"	3	1	letters	ja	noun
7	"まだ"	3	1	letters	ja	adverb
8	"無い"	3	1	letters	ja	adjective

# 文字雲範例

## Nouns

## Adjectives

薄い	どの
透けた	つらい 難しい
透けない	易い
美しい	大きい おかしい
おとなしい	好い にくい
苦しい	早い いかなる
済む	低い かの
長い	悪い 重い
きたない	よい 暗い
えらい	悲しい 熱い
遅い	どんな
強い	面白い 寒い 痞い
ひどい	若い あんな 悲しい
遠い	あんな
嬉しい	若く いわゆる旨い
つまらない	高い わが
軽い	いい
赤い	白い 喜び
よろしい	暑い 小さい
苦い	そんな 広い くい
美しい	善い 慶い 薫いたまらない
小さな	無い 遠慮ない
丸い	こんな
小さい	惜しい 多い 戒め うまい
怖い	多い 戒め うまい
あらゆる	大きい うるさい ありがたい
正しい	黒い わるい 烈しい
やかましい	悪い 怪しい
むずかしい	安い 少ない
變る	ためらう
出来ない	たのましい

(Matlab, 2018)

# LDA (latent Dirichlet allocation) 文件主題分析 範例結果1

(Matlab, 2018)

## Topic 1

あんなに そんなに あんな こんなに あんな  
若い まるで たい 無 博士 今日置く 一  
人れる まあ まるで たい 無 博士 今日置く 一  
様子 です ええ てる 迷亭 ああ さすが  
歩る いふ 貰う じや 行く やる なさる ところが  
それから だから だ もう 供 金田 中村  
見せる そんなだ わる た お 御 鼻 顔 金田 好い  
娘 ござる た お 細君 あ だつて お事  
引く 思う 細君 云う 知る 少し 待つ  
娘に ねえ 悪い 犯 来る お いい おっしゃる  
娘に ねえ 悪い 犯 来る お いい おっしゃる  
娘さん お 早い 大変 勝手 飲む お  
お出でを お 早く 持つ 聞く 声 飲む お  
娘さん お 早い 大変 勝手 飲む お

## Topic 2

## Topic 3


## Topic 4

# LDA

(latent Dirichlet allocation)

文件主題分析  
範例結果2




(Matlab, 2018)




# 文字生成的技術與應用

- ▶ 文字生成可視為馬可夫模型(Markov Model)的應用，如何由前文推出下一個詞  
 $\Pr(w_i \mid w_1, w_2, w_3, \dots, w_{i-1})$
- ▶ 神經網路(OpenNMT) vs 統計式(Moses) vs 規則式(SYSTRAN)
- ▶ 深度學習
  - ▶ Recurrent Neural Network (**RNN**)
    - ▶ Long and Short Term Memory (**LSTM**)
    - ▶ Gated Recurrent Unit (**GRU**)
  - ▶ Convolutional Neural Network (**CNN**)
  - ▶ Encoder/Decoder-based Sequence to Sequence (**seq2seq**) Generator
- ▶ 代表性: Google Translate
  - ▶ <https://www.youtube.com/watch?v=M8ZfR4iEwig>


# Seq2seq進行翻譯例子



# Seq2seq進行翻譯例子:加入雙向及注意力機制



# LSTM長短期記憶單元結構圖



**Figure 3-9.** LSTM module with four interacting layers 24

# 深度學習進入門檻

- ▶ 軟體
  - ▶ 程式語言: Python, Java, Matlab
  - ▶ 套件: numpy, scikit learn, pandas, matplotlib, ...
  - ▶ 深度學習框架 (Gulli, 2017)
    - ▶ 上層: PyTorch, Keras
    - ▶ 下層: TensorFlow, Theano, CNTK, Caffe, Torch
- ▶ 硬體
  - ▶ GPU 圖形處理單元
  - ▶ TPU 張量處理單元
- ▶ Google Colab深度學習平台: 提供GPU/TPU每天最多12小時用量

# 現況與未來

- ▶ 文字探勘研討會及競賽
  - ▶ 亞洲NTCIR <http://research.nii.ac.jp/ntcir/ntcir-14/>
  - ▶ 美洲TREC <https://trec.nist.gov/tracks.html>
  - ▶ 歐洲CLEF [http://clef2018.clef-initiative.eu/index.php?page=Pages/labs\\_info.html](http://clef2018.clef-initiative.eu/index.php?page=Pages/labs_info.html)
- ▶ 語言資料集
  - ▶ 政府官方多語文件網站、 Wikipedia 、電影字幕網站、日漢/漢日辭典、碩博士論文網、 ...
  - ▶ 公開NLP資料集 <https://machinelearningmastery.com/datasets-natural-language-processing/>
  - ▶ NTCIR 跨語言資料集 <http://research.nii.ac.jp/ntcir/permission/ntcir-6/perm-en-CLQA.html>
- ▶ 日中雙語應用
  - ▶ 學術面勘探應用：日語相關近年研究主題的趨勢分析、文本偏見分析、小說分析、 ...
  - ▶ 語言學習輔助應用：相近詞查詢、翻譯用詞建議、錯別字訂正、 ...
  - ▶ 其他創新應用：跨語言檢索、雙語聊天機器人、以自然語言檢索日文系相關常見問答集、 ...

# 自然語言技術與應用

(Thanaki, 2016)

## More Deeper Application of NLP

### Group 1

Cleanup, Tokenization

Stemming

Lemmatization

Part of Speech Tagging

Query Expansion

Parsing

Topic Segmentation and  
Recognition

Morphological Segmentation  
(Word/Sentences)

### Group 2

Information Retrieval and  
Extraction (IR)

Relationship Extraction

Named Entity Recognition  
(NER)

Sentiment Analysis/Sentance  
Boundary Disambiguation

World sense and  
Disambiguation

Text Similarity

Coreference Resolution

Discourse Analysis 27

### Group 3

Machine Translation

Automatic Summarization/  
Paraphrasing

Natural Language Generation

Reasoning over  
Knowledge Based


Quation Answering System

Dialog System

Image Captioning & other  
Multimodel Tasks

# 中日雙語系自然語言研究的機會

- 單語系自然語言處理已吸引足夠多關注
- 雙語系自然語言處理多和英文相關
- 中日雙語的自然語言處理須求大但少研究關注
- 自然語言處理研究的挑戰
  1. 資料集(dataset)
  2. 資訊處理能力(IT knowhow)
  3. 領域知識(domain knowledge)



# 參考文獻

- ▶ Goyal et al. (2018) Deep Learning for Natural Language Processing- Creating Neural Networks with Python, Apress.
- ▶ Gulli et al. (2017) Deep Learning with Keras- Implement neural networks with Keras on Theano and TensorFlow, Packt.
- ▶ Jurafsky et al. (2018) Speech and Language Processing- An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition, 3<sup>rd</sup> Ed., (Draft).
- ▶ Manning et al. (2008) Introduction to Information Retrieval, Cambridge.
- ▶ Matlab (2018) Analyze Japanese Text Data,  
<https://jp.mathworks.com/help/textanalytics/ug/analyze-japanese-text.html>
- ▶ Thanaki (2017) Python Natural Language Processing- Explore NLP with machine learning and deep learning techniques, Packt.
- ▶ Witten et al. (1999) Managing Gigabytes- Compressing and Indexing Documents and Images, 2<sup>nd</sup> Ed., Morgan Kaufmann.