

TCFD報告書

Text Mining評鑑內容探討

政治大學統計系余清祥

2025年12月5日


Email: csyue@nccu.edu.tw


<http://csyue.nccu.edu.tw>



研究目的

- 分析氣候相關財務揭露（TCFD）報告書，
以數位工具協助人工評鑑作業。
 - 註記及查詢「治理」、「策略」、「風險管
理」、「指標和目標」的相關文字。
 - 協助專家判讀TCFD報告、判斷
哪些文字為電腦生成(或抄襲)。
 - 提供文字分析模型及方法，
建立量化評鑑機制。





英文分析歷史悠久


- 莎士比亞(Shakespeare)的字彙總數
→ Efron and Thisted (1976) 以Poisson Process
估計莎士比亞字彙，推論1985年在莎翁故居
附近發現一首詩應是莎翁所作。
- 《聯邦主義議文集》 (The Federal Papers)
→ Mosteller and Wallace (1984) 以貝氏方法分析
「upon」之類虛字，判斷論文集中未署名的
12篇文章應是Madison、而非Hamilton。

紅樓夢代入Efron & Thisted估計新字彙

前八十回扣除第七十八回之8-fold cross-validation

Testing Data	比例	預測值	Variance of Est.	UC.I.	LC.I.	新字	是否在 95%C.I.
1~10	10/69	94.72	64.45	221.04	0	157	Y
11~20	10/69	96.30	64.50	222.71	0	151	Y
21~30	10/69	95.03	64.92	222.26	0	97	Y
31~40	10/69	95.21	65.08	222.78	0	75	Y
41~50	10/69	91.30	64.80	218.30	0	112	Y
51~60	10/69	97.11	64.94	224.39	0	94	Y
61~70	10/69	97.20	65.00	224.60	0	86	Y
71~80	9/70	81.98	64.63	208.65	0	134	Y

《紅樓夢》各回新出現的字彙



紅樓夢代入E&T估計新字彙

後四十回視為同一母體，4-fold cross-validation

Testing Data	比例	預測值	Variance of Est.	UC.I.	LC.I.	新字	是否在 95%C.I.
81~90	1/3	172.47	55.00	280.27	64.665	261	Y
91~100	1/3	170.36	55.38	278.91	61.817	219	Y
101~110	1/3	175.28	55.33	283.72	66.838	225	Y
111~120	1/3	182.97	55.68	292.10	73.843	186	Y

紅樓夢前八十回預測後四十回

Testing Data	比例	預測值	Variance of Est.	UC.I.	LC.I.	新字	是否在 95%C.I.
81~120	1/2	294.87	66.49	425.19	164.547	231	Y


紅樓夢與金庸小說的Jackknife覆蓋機率

* Magic Number !

→ 抽出 37.5%(25%) 即
可知道整部小說使
用多少種字彙！

- Jack1
- + Jack2

X軸: random proportion
Y軸: coverage probability



TCFD報告評分模型



<http://www.tnooz.com/2012/01/04/how-to/big-data-and-the-infinite-possibilities-for-the-travel-industry/>

量化模型

透過量化模型描述觀察結果：

$$\text{觀察現象} = \text{模型} + \text{誤差}$$

或是

$$y = f(x) + \text{error} ; \text{ 觀察值} = \text{訊號} + \text{雜訊}$$


■ 數量化模型的關鍵：


→ 量化目標值 y ：定義問題！

→ 選取關鍵變數： x_1, x_2, \dots, x_p

→ 建立量化模型：統計學習、機器學習。

如何分辨訊號、雜訊？






<http://www.ljagilamplighter.com/wp-content/uploads/noise.png>

http://www.ljagilamplighter.com/wp-content/uploads/noise_signal-mlab1_png_pagespeed_ce_b_GTiE6tAg.png

What we observe can be divided into:



<https://blog.solidsignal.com/wp-content/uploads/2018/03/expclas1.gif>

如何分析中文？

- 文字屬於非結構(Unstructure)資料，視文字特性、研究目標決定變數。
- 中文書寫現在以白話文為主，通常會透過雙字(多字)詞彙表達語意，因此斷詞一般是中文資料分析的關鍵步驟。
- 常見的斷詞工具包括中研院研發的CKIP，以及網路常見的jieba (結巴)。

斷詞與統計分析

- 根據研究目的及問題定義，挑選適當變數以提高分析的效率和準確性。
→ 統計量化模型注重實質解釋。
- 中文分析先經過斷詞、再挑選重要關鍵詞。
→ 白話文多以雙字詞（多字詞）表達觀念。
(註：字 → 詞 → 有意義的詞)

我想過過過兒過過的生活

用毒毒毒蛇毒蛇會不會被毒毒死

方塊字分析與生物多樣性

大致可由以下三個角度切入：

□ 豐富度(Richness)及不均度(Unevenness)：

→ 字/詞數與種類、相異字比例(TTR)

→ 常見字詞佔比、Entropy、Simpson Index

□ 字詞關聯性(生態系 Ecosystem)

→ 關鍵詞叢、主題模型(Topic Model)

□ 趨勢變化(字詞比擬為物種Species)

→ 共同字彙、新生及滅絕字彙



現行分析作法

- 先以字詞及文句結構切入，暫時沒有加入字詞的意義、詞性、關聯性等資訊。
→ 字詞的TTR、Entropy、Simpson Index
 - 此外，也加入各公司的相關資訊：
→ 資本額、官股、溫室氣體驗證
- 註：2023～2024年不細分四要素，文字分析以整篇報告為單位。

附表A-1、文字及公司變數

序號	本國銀行變數名稱	序號	壽險、產險變數名稱		
1	銀行狀態	1	有金控母公司	38	隨機抽樣500詞之平均Entropy
2	有金控母公司	2	金控母公司是公股	39	隨機抽樣1000詞之平均Entropy
3	銀行上市櫃狀態	3	資本額	40	隨機抽樣2000詞之平均Entropy
4	公股	4	TCFD_會計師確信	41	隨機抽樣3000詞之平均Entropy
5	資本額	5	TCFD_BSI查核	42	隨機抽樣4000詞之平均Entropy
6	TCFD_會計師確信	6	溫室氣體驗證	43	隨機抽樣5000詞之平均Entropy
7	TCFD_BSI查核	7	有委任第三方驗證	44	隨機抽樣500詞之平均Simpson
8	溫室氣體驗證	8	總字數	45	隨機抽樣1000詞之平均Simpson
9	有委任第三方驗證	9	不同字數	46	隨機抽樣2000詞之平均Simpson
10	總字數	10	隨機抽樣500字之平均TTR	47	隨機抽樣3000詞之平均Simpson
11	不同字數	11	隨機抽樣1000字之平均TTR	48	隨機抽樣4000詞之平均Simpson
12	隨機抽樣500字之平均TTR	12	隨機抽樣2000字之平均TTR	49	隨機抽樣5000詞之平均Simpson
13	隨機抽樣1000字之平均TTR	13	隨機抽樣3000字之平均TTR	50	全部詞彙詞向量
14	隨機抽樣2000字之平均TTR	14	隨機抽樣4000字之平均TTR	51	全部詞彙詞向量_主成分分析
15	隨機抽樣3000字之平均TTR	15	隨機抽樣5000字之平均TTR	52	前500大詞彙詞向量
16	隨機抽樣4000字之平均TTR	16	隨機抽樣500字之平均Entropy	53	前100大詞彙詞向量
17	隨機抽樣5000字之平均TTR	17	隨機抽樣1000字之平均Entropy	54	前10大詞彙詞向量
18	隨機抽樣500字之平均Entropy	18	隨機抽樣2000字之平均Entropy	55	文字源於TCFD報告書
19	隨機抽樣1000字之平均Entropy	19	隨機抽樣3000字之平均Entropy	56	文字源於ESG報告書
20	隨機抽樣2000字之平均Entropy	20	隨機抽樣4000字之平均Entropy		
21	隨機抽樣3000字之平均Entropy	21	隨機抽樣5000字之平均Entropy		
22	隨機抽樣4000字之平均Entropy	22	隨機抽樣500字之平均Simpson		
23	隨機抽樣5000字之平均Entropy	23	隨機抽樣1000字之平均Simpson		
24	隨機抽樣500字之平均Simpson	24	隨機抽樣2000字之平均Simpson		
25	隨機抽樣1000字之平均Simpson	25	隨機抽樣3000字之平均Simpson		
26	隨機抽樣2000字之平均Simpson	26	隨機抽樣4000字之平均Simpson		
27	隨機抽樣3000字之平均Simpson	27	隨機抽樣5000字之平均Simpson		
28	隨機抽樣4000字之平均Simpson	28	總詞數		
29	隨機抽樣5000字之平均Simpson	29	不同詞數		
30	總詞數	30	隨機抽樣500詞之平均TTR		
31	不同詞數	31	隨機抽樣1000詞之平均TTR		
32	隨機抽樣500詞之平均TTR	32	隨機抽樣2000詞之平均TTR		
33	隨機抽樣1000詞之平均TTR	33	隨機抽樣3000詞之平均TTR		
34	隨機抽樣2000詞之平均TTR	34	隨機抽樣4000詞之平均TTR		
35	隨機抽樣3000詞之平均TTR	35	隨機抽樣5000詞之平均TTR		
36	隨機抽樣4000詞之平均TTR	36	隨機抽樣500詞之平均Entropy		
37	隨機抽樣5000詞之平均TTR	37	隨機抽樣1000詞之平均Entropy		

生物多樣性

- 寫作風格如同生態系各有特色，字詞可比擬為物種(Species)。
- 物種豐富度及不均度可描述字詞特性，例如：相異字比(TTR, Type-Token-Ratio)、熵(Entropy, 或稱Shannon Index)。


$$Entropy = - \sum_{i=1}^W p(w_i) \log_2 p(w_i)$$




《新青年》各卷字彙豐富度(TTR)



各卷一千字出現不同字個數



各卷一萬字出現不同字個數



<https://kknews.cc/history/n3jrvr2.html>

TCFD文字與評分資料

<https://www.logicraysacademy.com/blog/wp-content/uploads/2023/08/DA2.jpg>



氣候相關財務揭露資料統計

	年度	銀行	壽險	產險
TCFD報告書	2023-24	29	14	11
永續報告書	2023-24	9	7	12
總計	2023-24	38	21	23
字總數	2023	263,590	117,889	57,056
	2024	420,006	147,334	68,272
每家平均字數	2023	6,937	5,614	3,003
	2023	11,053	7,016	3,593

2024年TCFD報告四要素文字統計

指標	本國銀行業				壽險業				產險業			
	治理	策略	風險	指標	治理	策略	風險	指標	治理	策略	風險	指標
字總數	47201	161076	121821	89908	14637	53545	37200	41952	9220	25369	17469	16214
每家平均	1242	4239	3206	2366	697	2550	1771	1998	485	1335	919	853
字種類	1105	1732	1472	1442	743	1310	1156	1272	700	1083	917	958
詞總數	23891	80790	61415	44001	7442	26557	18468	20689	4609	12617	8975	7827
詞種類	3700	10899	7981	7727	1572	5309	3829	4750	1244	2919	2261	2280
句數	2109	7156	5582	4170	657	2584	1773	2063	426	1124	882	778
句長	22.38	22.51	21.82	21.56	22.28	20.72	20.98	20.34	21.64	22.57	19.81	20.84
標點總數	3952	14593	10824	8116	1110	4908	3264	3960	753	2328	1449	1459
標點種類	20	23	22	19	16	19	18	19	17	20	17	20

2023年TCFD報告四要素文字統計

指標	本國銀行業				壽險業				產險業			
	治理	策略	風險	指標	治理	策略	風險	指標	治理	策略	風險	指標
字總數	29,007	105,204	82,546	46,833	15,323	50,036	36,471	16,059	6,506	22,260	19,675	8,615
每家平均	763	2,769	2,172	1,232	730	2,383	1,737	765	283	968	855	375
字種類	838	1,396	1,229	1,203	752	1,215	1,072	859	583	967	925	731
詞總數	11,995	42,114	33,464	18,365	6,245	20,158	14,777	6,246	2,637	8,983	7,911	3,310
詞種類	2,021	6,560	5,125	3,978	1,376	3,951	3,019	1,724	800	2,142	1,970	1,156
句數	1,419	5,656	4,257	2,590	710	2,421	1,814	759	284	977	892	395
句長	22.52	21.58	21.98	21.45	24.19	23.91	22.86	25.27	26.28	25.91	24.76	27.53

2023-24年內外部專家分數變異係數

專家分數	時間	內部人工 編碼評鑑	外部專家 學者評鑑
本國銀行業	2023年	0.25	0.08
	2024年	0.35	0.06
壽險業	2023年	0.24	0.07
	2024年	0.27	0.06
產險業	2023年	0.49	0.09
	2024年	0.52	0.10

2023-2024年文字 + 公司迴歸分析

產業別	年度	內部分數		外部專家	
		變數個數	R ²	變數個數	R ²
銀行	2023年	9(6)	0.87	9(5)	0.90
	2024年	8(4)	0.73	9(4)	0.69
壽險	2023年	3(2)	0.65	7(4)	0.77
	2024年	6(4)	0.59	7(3)	0.58
產險	2023年	4(3)	0.66	4(3)	0.73
	2024年	5(3)	0.64	4(1)	0.67

註：刮號內為文字變數個數。

迴歸模型與BERT的比較

- 迴歸模型未必不如大語言模型！
→ 傳統分析除了能確定哪些是關鍵變數，模型也相對準確、穩定。
- 以2023及2024年銀行業外部評審分數為例，計算交叉驗證的RMSE(均方誤差)：

銀行業	迴歸	BERT
2023年	3.51	5.62
2024年	4.41	4.61

量化模型的分析結果

- 迴歸等模型比較能捕捉外部評審的想法，以及銀行業TCFD的(內外部)評審結果
- 2023年、2024年模型結果類似
→仍以銀行業估計誤差較小。
- 2024年模型誤差略高於2023年，原因：
評分標準略有調整、文字篇幅增加(多元)、
ChatGPT等AI工具的影響。
- BERT模型未必較佳(樣本數較少)



討論與建議

- 文字分析僅置入物種豐富度、不均度
→ 由文字風格、語意組成關鍵詞叢(Cluster of Keywords)，計算詞彙間的關聯性。
- 樣本數較為不足
→ 樣本數少使得迴歸及BERT等模型較不穩定，
不同年度的結果略有差異。
- 四個核心要素的個別模型？
→ 模型細分為四個子模型、再結合為大模型？

2023～2024年銀行業迴歸分析結果

		全文	治理	策略	風險	指標
2024	R^2	73%	63%	50%	38%	51%
	變數個數	8	9	8	2	4
2023	R^2	89%	43%	73%	71%	53%
	變數個數	9	3	9	14	6

單一與四要素迴歸模型(2024年銀行業)



報告完畢，
敬請指教！

