

國立臺灣大學電機資訊學院資訊網路與多媒體研究所

碩士論文

Graduate Institute of Networking and Multimedia

College of Electrical Engineering and Computer Science

National Taiwan University

Master Thesis

以生成對抗網路達成非監督式文章摘要及主題模型

Unsupervised Text Summarization and Topic Modeling using  
Generative Adversarial Networks

王耀賢

Yau-Shian Wang

指導教授：李琳山 教授

Advisor: Lin-shan Lee, Ph.D.

中華民國一百零八年七月

July, 2019





國立臺灣大學碩士學位論文  
口試委員會審定書

以生成對抗網路達成非監督式文章摘要及主題模  
型

Unsupervised Text Summarization and Topic  
Modeling using Generative Adversarial Networks

本論文係王耀賢君 (R06944019) 在國立臺灣大學資訊網  
路與多媒體研究所完成之碩士學位論文，於民國 108 年 7 月  
9 日承下列考試委員審查通過及口試及格，特此證明

口試委員：

李琳山

(簽名)

(指導教授)

陳仁宏

鄭秋豫

王少川

李宏毅

系主任、所長

楊佳玲

(簽名)



# 摘要



隨著網際網路的興起，人類在網路上留下各式各樣的資料，由於這些資料大多是未標註的，使用未標註資料來做訓練的非監督式學習成了近年來重要的研究課題。在本論文中，我們使用生成對抗網路來探索非監督式學習在自然語言處理上的可能性，並專注在在兩個不同的主題上。

第一個主題是非平行抽象式文章摘要，亦即不需要平行成對的訓練文章搭配其人類撰寫的摘要便可訓練機器撰寫文章的非抽象式摘要。在這個主題中，我們使用摘要來作為文章自編碼器的潛在表徵，並且使用生成對抗網路來限制此潛在表徵必須具備人類可讀的形式，只要提供較少量的人類撰寫的不相關的內容的文章摘要作為辨識器的範本就可讓機器學習人類是如何寫摘要的。我們衡量我們所提出的模型在英文以及中文的新聞摘要資料庫上，模型的表現也驗證了這樣的方法的可行性。

第二個主題則是非監督式文章主題模型，希望機器可以自動發現文章的接近人類認知的主题。我們使用資訊生成對抗網路來模擬文章的產生是由一個離散的主题分佈，以及一個連續的向量來控制主题下的文章的變異，而不若前人所提出的主题模型模擬文章的產生是由若干瑣碎的次要主题所產生。實驗顯示我們的模型在文章分類的任務上，以及所抽取出的每一個主题的關鍵詞的品質上，相較於先前的研究結果均有著顯著的進步。

# 英文摘要



With the development of the Internet, humans put various data on the Internet. As most of the data is unannotated, how to efficiently utilize unlabeled data for unsupervised learning, becomes an important research direction. In this thesis, we use Generative Adversarial Network (GAN) to explore the possibility of unsupervised learning on NLP, which mainly covers the two different topics.

The first topic is unsupervised abstractive text summarization. That is text summarization without any paired data. We use summaries as latent representations of an auto-encoder and use GAN to constrain the latent representation to be human-readable. With fewer summaries as examples for discriminator, machine can understand how humans write summaries for documents. The results on English and Chinese news datasets demonstrate the effectiveness of our model.

The second topic is unsupervised topic model. The goal of this section is to train a machine that is able to automatically discover the latent topics similar to humans' cognition. Unlike prior topic models which models text generated from a mixture of sub-topics, we utilize InfoGAN to model texts generated from a discrete code controlling high-level topics and a continuous vector controlling variance within the topics. Compared to prior works, our proposed method greatly improves the performance on unsupervised classification and topical word extraction.




# Contents



口試委員會審定書	i
中文摘要	ii
一、導論	1
1.1 研究動機	1
1.2 研究方向	5
1.3 章節安排	5
二、背景知識	7
2.1 深層類神經網路(Deep Neural Network)	7
2.1.1 模型架構	7
2.1.2 類神經網路的訓練	8
2.2 遞迴式類神經網路	10
2.2.1 基本模型	10
2.2.2 長短期記憶模型 (Long Short-Term Memory, LSTM)	10
2.2.3 序列至序列網路	11
2.2.4 專注式序列至序列網路	11
2.2.5 混合式指標網路	12
2.3 自編碼器(Autoencoder)	13
2.3.1 基本原理	13
2.3.2 變分自編碼器(Variational Autoencoder, VAE)	14
2.4 生成對抗網路(Generative Adversarial Neural Networks, GAN)	15
2.4.1 基本原理	15
2.4.2 使用生成對抗網路產生語言	16
2.4.3 資訊生成對抗網路(Info-GAN)	20
2.5 本章總結	20
三、使用生成對抗網路達成非監督式抽象文章摘要	21
3.1 任務簡介	21
3.2 訓練方法	22
3.2.1 方法概述	22
3.2.2 最小化重構損失	24
3.2.3 生成對抗網路的訓練	25
3.3 實驗	29
3.3.1 資料介紹	29
3.3.2 實做細節	30
3.3.3 評量方法	31
3.3.4 非平行式摘要用於英文十億詞	32
3.3.5 半監督式摘要於英文十億詞	34
3.3.6 遷移式學習於英文十億詞	35



3.3.7	非平行式摘要用於有線電視日常信件	36
3.3.8	非平行式摘要用於中文十億詞	37
3.4	本章總結	38
四、	使用資訊生成對抗網路達成文章主題模型	42
4.1	任務簡介	42
4.2	訓練方法	43
4.2.1	方法簡介	43
4.2.2	模型介紹	44
4.2.3	模型的訓練	46
4.2.4	由產生的詞袋向量產生文章	48
4.3	實驗	48
4.3.1	資料介紹	48
4.3.2	模型架構與參數	50
4.3.3	非監督式文章分類	50
4.3.4	主題一致性	52
4.3.5	切除分析 (Ablation Study)	56
4.3.6	分離式表徵	58
4.4	本章總結	59
五、	結論與展望	65
5.1	結論與主要貢獻	65
5.2	未來展望	67
5.2.1	使用兩階段式的方法達成非平行式文章摘要	67
5.2.2	使用遞迴式類神經網路的文章主題模型	67
	參考文獻	68



# 圖目錄



2.1	類神經網路示意圖. . . . .	8
2.2	自編碼器的模型示意圖. . . . .	13
3.1	模型示意圖。給定長文，生成器設法產生摘要，它所產生的摘要必須最小化重構損失並且讓鑑別器認為產生的摘要為真，也就是要設法騙鑑別器讓它認為此摘要來自於人類。 . . . . .	22
3.2	提出模型的詳細的架構。 . . . . .	24
3.3	自我批判學習強化法的實際例子。 . . . . .	26
3.4	英文十億詞的例子。 . . . . .	33
3.5	英文十億詞的例子。 . . . . .	34
3.6	有線電視新聞網的例子。 . . . . .	37
3.7	英文十億詞的例子。 . . . . .	39
3.8	英文十億詞的例子。 . . . . .	39
3.9	英文十億詞的例子。 . . . . .	40
3.10	英文十億詞的例子。 . . . . .	40
3.11	英文十億詞的例子。 . . . . .	41
3.12	英文十億詞的例子。 . . . . .	41
4.1	我們的模型的示意圖。(A)在左邊的部份中，生成器 $G$ 以離散的文章主題分佈 $c$ 以及連續的雜訊向量 $z$ 為輸入來產生詞袋向量；鑑別器 $D$ 以詞袋向量為輸入並且鑑別其是來自於人類或者生成器；主題分類器 $Q$ 以生成的詞袋向量為輸入並且預測文章的隱藏主題。在(A)右邊的部份則是自編碼器的訓練，自編碼器的訓練以人類寫的文章的詞袋向量為輸入，其中雜訊預測器 $E$ 以及主題分類器 $Q$ 形成一個編碼器，而 $G$ 則是解碼器，他們要設法重構輸入的詞袋向量。(B)則是文章的生成，首先 $G$ 會先產生詞袋向量，再來 $G'$ 設法根據輸入的詞袋向量並且設法產生文章。 . . . . .	44

# 表目錄



3.1	The caption . . . . .	28
3.2	ROUGE 分數在有線電視日常信件的資要庫上。 . . . .	36
3.3	ROUGE 分數在中文十億詞資料庫上。 . . . .	38
4.1	非監督式文章分類準確度。 . . . .	52
4.2	主題一致性的分數，越高越好。 . . . .	53
4.3	由我們模型所發現的主題所產生的主題詞。在資料庫百科中主題 1 是有關於音樂，主題 2 是有關於建築而主題 3 是有關於運動。在英文十億詞主題 1 是有關於經濟，主題 2 是有關於疾病，而主題 3 是有關於政治。 . . . .	55
4.4	表 4.3 中的主題所產生的對應的文章。在相同資料庫的文章是由相同 $z$ 但是不同的 $c$ 所產生的。 . . . .	56
4.5	切除分析在非監督式文章分類上，表中的數字代表準確度。 . . . .	57
4.6	由表 4.3 主題編號 2 所產生的文章，他們來自於相同的 $c$ 但是不同的 $z$ 。 . . . .	58
4.7	由表 4.3 英文十億詞中主題 2 不同的雜訊向量 $z$ 所產生的文章，很明顯的每個文章都與疾病有關。 . . . .	60
4.8	在雅虎問答中我們的模型所產生的文章主題詞。 . . . .	61
4.9	在雅虎問答中 ProdLDA 所產生的文章主題詞。 . . . .	62
4.10	在雅虎問答中 NVDM 所產生的文章主題詞。 . . . .	63
4.11	在雅虎問答中 LDA 所產生的文章主題詞。 . . . .	64

# 第一章 導論



## 1.1 研究動機

在現今人工智慧興起的時代，使用機器學習(Machine learning)相關的技巧處問題已成未來的趨勢，許多科技公司期望能利用機器學習來處理更為複雜的問題，並且推出更好的產品以及服務。舉例來說，蘋果(Apple)利用機器學習推出智慧語音助理Siri，透過語音的互動幫助人們解決生活中各式的煩惱；亞馬遜(Amazon)也利用機器學習推出居家語音智慧助理Alexa，幫助人類居住生活更為便利；谷歌(google)也亦利用深層學習(Deep Learning)推出谷歌翻譯的功能，讓人與人的互動交流能夠跨越語言的障礙。

早期的機器學習主要依賴人類專家的先驗知識(Prior Knowledge)來抽取出問題的特徵(Feature)，接著再利用傳統機器學習的相關模型像是支援向量機(Support Vector Machine, SVM) [1]，決策樹(Decision Tree) [2]及感知器(Perceptron)等方法來解決問題。早期的方法會需要人類的先驗知識主要是因為早期的計算資源的不足，讓機器無法處理極為複雜的模型，又或者處理模型的時間會極為緩慢；以及訓練資料的稀少，迫使機器無法抽取出廣泛有效的特徵。

然而現今隨著計算資源的大幅度進步，尤其是圖形處理器(GPU)的發展，機器得以處理極為複雜的模型，並且能夠以數十倍甚至數百倍的速度來處理模型的運算；以及隨著網路世界的興起，人類在網路世界中留下各式各樣的足跡，也就讓機器有了各式各樣訓練的資料，現今主流模型像是深層學習就傾向於讓機器透過大量的訓練資料，自己去發現人類專家所學習到的先驗知識，並且除了傳統的分類問題外，也能解決更多更複雜的問題，像是複雜的生成(Generation)問題，複雜的生成問題有像是圖片的生成，文句翻語音的生成(Text to Speech)，又或者

是自然語言處理(Natural Language Processing, NLP)的生成像是機器翻譯(Machine Translation)，又或者是文章摘要(Text Summarization)。

因為模型更為複雜能夠更好的模擬問題，在有充足資料的問題上，利用大量標註訓練資料的監督式學習(Supervised Learning)都能有不錯的表現，然而在網路世界中大部份的資料都是未經標註的，像是網路上大量的文章，上傳到社群軟體上的照片，又或者在網路播放器上的沒有字幕的影片，要人工標註這些幾近無限的未經標註的資料是一件十分昂貴並且不可行的事情，因此如何利用這些未經標註資料的訓練方法就成為現今最為熱門的研究問題。這類問題包含用少量標註資料以及大量未標註資料的半監督式學習(Semi Supervised Learning)，只利用大量未標註資料的非監督式學習(Unsupervised Learning)，又或者將其他領域學習到的知識廣泛化到目標領域的遷移學習(Transfer Learning)。


我選擇研究非監督式學習類的問題，並且將此問題應用在自然語言處理的領域上，這類的問題的核心精神是要讓機器能夠有如人類一般，藉由閱讀大量的文字資料，就能從這些資料中學習新知，像是了解句子與句子之間的關係、文法架構，並且進一步理解這些文字背後深層的含意。然而在實際上要讓機器理解這些是十分困難的，因為機器所學習到的資料的特徵往往與人類的認知有著極大的差異，但這類的研究仍然吸引研究者很大的注意，因為如果能讓機器如同人類一般，從未標註的文本學習出更廣泛的知識，幾乎所有的其他自然語言處理的任務都能因此而進步。在近期相關領域也有許多著名的研究，舉例來說BERT(Bidirectional Encoder Representations from Transformers) [3]就預訓練(Pre-training)轉換器模型(Transformer) [4]在大量的未標註文本上，他們訓練模型在兩個自我訓練 (Self-Training) 任務上，藉由達成這兩個自我訓練的任務，模型得以成功的學習到更廣泛的知識，並且將預訓練後的模型微調在許多其他自然語言

的任務上也取得最佳的表現。

本論文的研究則專注在其他的相關問題上，可以分為兩個不同的主題，第一個主題是有關於非配對式文章摘要(Unpaired Text Summarization)，這個主題的目標是希望機器能夠設法由大量的文章中去做抽象式文章摘要 (Abstractive Text Summarization)，第二個主題則是文章主題模型的建立，目標是希望藉由閱讀大量的文本，能讓機器如同人類一般，去發現文章各式的主題，像是文章是屬於政治類的主題亦或是運動類的主題。

首先先來介紹非配對式文章摘要，在現今抽象式文章摘要的問題上，模型的訓練往往需要依賴極為大量人工標註的資料，因為人工標註資料的取得不易，因此這類模型往往只能訓練在有大量標註資料的任務上像是新聞的摘要，然而在其他資料取得不易的任務上像是演講的摘要、課程的摘要，這些往往都是沒有人工標註的資料的，然而這些資料也是非常需要摘要來幫助人們一眼了解所述，因此我希望能讓機器能用少量的摘要就能夠達成學習，甚至在不看到任何摘要的情況下就完成學習。

非配對式文章摘要的方法啓發於人類做摘要的方式，一個好的摘要首先必須要精簡，再來摘要必須要能包含大部分的文意，我發現在深層學習的領域中有種模型的概念與之極為接近，那就是自編碼器(Auto-Encoder)，自編碼器希望能用更精簡的表徵(Representation)來表徵資料，並且這種精簡的表徵還要能夠重構(Reconstruct)回原本的資料，因此這精簡的表徵必須要抓住資料的重點，直觀來看這精簡的表徵就好似資料的摘要。然而，摘要還有另外一個重要的特徵，那就是摘要必須要是人類能夠理解的，由於自編碼器的表徵只有機器才能理解，因此我選用近來最為成功的生成模型(Generative Model)中的生成對抗網路(GAN) [5]來限制自編碼器產生人類可讀的表徵。



再來要談的是非監督式文章主題模型的建立，主題模型是機器學習以及自然語言處理一個非常經典的問題，這個問題的價值在於他給予人類一種方式去分析以及了解歸納文章的主題。然而不論傳統的文章主題模型亦或是使用類神經網路的主題模型，他們都有些共同的通病，那就是他們必須要設定很多的文章主題數目，舉例來說在一個新聞的資料庫，他可能只有”運動”，”政治”以及”體育”這三類不同的文章，就人類直觀而言這個資料庫應該只有三種不同的主題，然而由於先前的主題模型的方法上的限制，他們必須要設定遠遠高於三個以上的主題，可能是50甚至100個，這樣子他們就必須要將一個運動類主題拆成許多不同的子主題，像是依據不同運動來劃分主題，由於這樣子拆解主題違反人類直觀上的主題的定義，於是我就提出個全新的方法設法讓機器能夠有如人類般直接學習這些較高層次的主題。

我發現在圖像上已經有人處理過類似主題模型的問題，前人提出資訊生成對抗網路(Info-GAN) [6]來將圖片歸類成為不同的類別，因此我設法將此模型應用到文章主題模型中，然而我發現直接套用這個模型在文字上很難讓模型成功學會有意義的主題，因此我額外再提出些額外的延伸來幫助此模型能夠在文字資料上也能取得成功，這些延伸包含使用詞嵌入(Word Embedding)來幫助機器學習有意義的話題，將資訊生成對抗網路與自編碼器結合等等，最後這些延伸也在實驗中被證實能大幅提升效能。

由於文字的離散特性，使用生成對抗網路訓練文字資料仍然是一件非常困難的事情，這個領域仍然遠遠稱不上是成熟，但有鑑於生成對抗網路在電腦視覺上所取得的巨大成功，我相信這仍舊是個值得探索的方向，因此我選擇這主題作為我的碩論主軸，並且藉由上述的這兩個成功的應用，更進一步探索可能的訓練方法，以及如何應用在實際的問題上。



## 1.2 研究方向

本論文之研究方向為使用生成對抗網路 (Generative Adversarial Networks) 達成非監督式自然語言文意理解，主要包含以下幾點：

- 本論文會探討兩種不同的使用生成對抗網路在非監督式自然語言處理的題目，包含非配對式文章摘要，以及非監督式文章主題模型。
- 由於使用生成對抗網路產生文句是一件極為困難的事情，因此本論文會探討如何成功的使用生成對抗網路產生文句，首先會介紹文字生成的困難之處，再來介紹最近的研究如何提出新的生成對抗網路的目標函式以及如何使用強化學習(Reinforcement Learning)來解決此問題，再來會說明本篇文章如何將前人的方法做結合，並且提出一種新的使用生成對抗網路產生文字的方法，此方法也在實驗中被證實能成功產生出合理的文字。
- 使用資訊生成對抗網路(Info-GAN)在電腦視覺的領域上取得巨大的成功，因為能夠達成非監督式地分類圖片，然而由於文字十分難生成，以及十分難學出合理的類別，因此先前的研究在這方面的嘗試都沒有取得很好的結果。本論文嘗試將資訊生成對抗網路與霍氏生成對抗網路(Wasserstein Generative Adversarial Networks)結合以及與自編碼器結合來讓訓練更為穩定，並且提出使用預訓練的詞向量來鼓勵模型學到有意義的文章主題。

## 1.3 章節安排

本論文之章節安排如下：

- 第二章：介紹本論文相關背景知識。



- 第三章：介紹使用生成對抗網路達成非監督式抽象文章摘要。
- 第四章：介紹使用生成對抗網路達成文章主題模型。
- 第五章：本論文之結論與未來研究方向。



## 第二章 背景知識



### 2.1 深層類神經網路(Deep Neural Network)

#### 2.1.1 模型架構

深層類神經網路為現今機器學習最著名的模型之一，它可以被視為一個函式，會將輸入向量映射到輸出向量。它的靈感是來自於人類神經元的運作模式，人類的神經元的節點是彼此相互連結在一起的，並且只有通過某個閾值 (Threshold) 才會激發訊號繼續往下傳遞。受此啟發，最基本的順向類神經網路 (Feedforward Neural Network) 由許多層 (Layer) 所構成，並且如圖 2.1 所示，層跟層之間的節點都是彼此緊密的連結在一起的，下個層的輸入是由上層而來，如此一來輸入經由不斷的轉換後就能階層式地抽取出低層次到高層次的特徵。

簡單來說，首先輸入層會先接收來自於輸入 (Input) 的訊號，再來輸入的訊號會進入隱藏層做複雜的處理以及運算，最後經由輸出層產生輸出(Output)。每層的運算方式都是相似的，每層都把該層的每一個節點的輸入訊號都乘上一個可以被訓練的權重(Weight)，圖 2.1 中的每個箭頭即代表一個權重，下一層的節點為上層所有節點的權重加總，再加上一個可訓練的偏移值(Bias)，最後為了避免模型只是個簡單的線性模型並且讓模型能表示更複雜的函數，線性轉換的輸出會再通過一個激發函數(Activation Function)，每一層的輸出 $f(x)$ 如下：

$$f(x) = \sigma(Wx + b) \quad (2.1)$$

其中  $W$  是所有可訓練的權重所排成的矩陣 (Matrix)，而  $b$  則是所有節點偏移值所排成的向量， $x$  是該層的輸入， $\sigma$  則是激發函數。通常來說，激發函數有整流線




圖 2.1: 類神經網路示意圖.

性單元 (ReLU) 或S型函數 (Sigmoid) :

$$Relu(z) = \max(z, 0) \tag{2.2}$$

$$Sigmoid(z) = \frac{1}{1 + e^{-z}}$$

其中  $z$  是線性轉換  $Wx + b$  的值。類神經網路的輸出層則不會使用上列的激發函數，而是會隨著訓練任務的不同使用其他的輸出函數，將在下一節作詳細的介紹。

### 2.1.2 類神經網路的訓練

要訓練類神經網路，首先必須要定義一個損失函數 (Loss Function)，類神經網路的目標就是要找出一組類神經網路的參數來盡可能的最小化損失函數，此損失函數會隨著訓練任務的不同而有所變動，而輸出層的輸出函數也會隨著損失函數而改變。在此要由機器學習其中兩個著名的訓練任務說起，第一個是迴歸 (Regression) 任務第二個則是分類 (Classification) 任務。

迴歸任務的輸出是個連續的值，像是預測溫度、預測年齡甚至是圖形的生成都可以被形成一個迴歸任務。為了讓模型能夠輸出任何的值，有時輸出層不會額



外再放輸出函數，而是直接拿輸出層線性的輸出來做為模型的輸出，在這任務最常用的損失函數是均方差 (Mean Square Error, MSE)，均方差要最小化模型的輸出與目標的值，其式如下：

$$\mathcal{L}_{MSE} = \sum_i \|y_i - f(x_i; \theta)_i\|^2 \quad (2.3)$$

其中  $f(x_i; \theta)$  是個輸入為第  $i$  筆資料  $x_i$  並且參數為  $\theta$  的類神經網路的輸出， $y_i$  是第  $i$  筆資料的正確的標籤。

再來要介紹的是分類問題，我要介紹的是多元分類問題 (Multiclass Classification)，多元分類指類別的數目大於二的分類問題，圖片的鑑別或文章的分類都可以被視為多元分類問題，值得一提的是文句的產生也可以被視為一個多元分類的問題：依序產生文字，產生文字時每一個字都是一個獨立的類別，正確的字則是被視為正確的類別。多元分類問題的輸出層的輸出是一個機率分佈，機率分佈的輸出通常會使用軟性最大化函數 (Softmax)，輸出層第  $i$  個節點經過軟性最大化函數後的機率如下：

$$\text{Softmax}(x)_i = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad (2.4)$$

與之搭配的損失函數則是交叉熵 (Cross Entropy, CE) 函數，其數學式子如下：

$$\mathcal{L}_{CE} = - \sum_i y_i \cdot \log(f(x; \theta)_i) \quad (2.5)$$

有了上述這些輸出函數以及損失函數後，我們就可以調整類神經網路的參數來最小化損失函數，最常使用的是梯度下降法 (Gradient Descent Algorithm) 輔以反向傳播演算法 (Back Propagation) 來訓練。梯度下降法首先會計算損失函數對於參數的梯度 (Gradient)，接著為了最小化損失函數，會將模型參數往梯度的相反方向做更新。藉由不斷迭代更新參數，損失函數會逐漸下降，每次更新式子如下：



$$\theta' = \theta - \eta \frac{\partial \mathcal{L}(x, y; \theta)}{\partial \theta} \quad (2.6)$$

其中  $\theta'$  是更新過後的參數。

## 2.2 遞迴式類神經網路

### 2.2.1 基本模型

上一個章節介紹的順向類神經網路雖然能解決許多問題，但是在序列性的資料 (Sequential Data)，像是語音、文字或影片，這類網路就不能表現十分良好，關鍵在於它不能夠由左至右地“記憶”並且處理這些資料，人類在處理序列性的資料時，會由左至右，依序儲存資料中重要的部分在記憶中，最後在形成對於資料的表示。為了模仿人類的這個特性，遞迴式類神經網路會依序讀入資料到記憶體單元 (Memory Cell) 中，在第  $t$  個時間點會讀入  $x_t$ ，再將  $x_t$  與上個時間點的記憶體單元  $c_{t-1}$  結合成新的記憶體  $c_t$ ， $c_t$  經過輸出層後會產生輸出  $h_t$ ， $c_t$  也會同時傳入下個時間點，其處理資料函數如下所示：

$$\begin{aligned} c_t &= \sigma_c(W_x x_t + U_c c_{t-1} + b_c) \\ h_t &= \sigma_h(W_h c_t + b_h) \end{aligned} \quad (2.7)$$

其中  $\sigma$  代表激活函數，而  $W, U, b$  都是可訓練的參數。

### 2.2.2 長短期記憶模型 (Long Short-Term Memory, LSTM)

然而原始的遞迴式類神經網路在更新較長的序列時會有很嚴重的梯度消失 (Gradient Vanishing) 的問題，因為遞迴式類神經網路每經過一次激活函數他的梯度都會下降些，在較長的序列中往往最後會減至為零，也造成參數無法更新。



為了解決此問題，先前研究者提出一種新的遞迴式類神經網路，其名為長短期記憶模型 [7]，長短期記憶模型的處理資料方法如下所示：

$$\begin{aligned}f_t &= \sigma_g(W_f x + U_f h_t - 1 + b_f) \\i_t &= \sigma_g(W_i x + U_i h_t - 1 + b_i) \\o_t &= \sigma_g(W_o x + U_o h_t - 1 + b_o) \\c_t &= f_t \circ c_{t-1} + i_t \circ \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\h_t &= o_t \circ \sigma_h(c_t)\end{aligned}\tag{2.8}$$

其中  $f, i, o$  分別是遺忘閘門 (Forget Gate)、輸入閘門 (Input Gate)、以及輸出閘門 (Output Gate)， $f$  控制上個時間點的記憶單元要遺忘多少， $i$  控制那些資料要被輸入， $o$  控制那些潛在特徵要被輸出。如果對  $c_t$  微分可以發現當  $f_t$  為 1 時，梯度可以完全地傳遞到上一個時間點的  $c_{t-1}$  也因此長短期記憶模型能夠有效的減緩梯度消失的問題。

### 2.2.3 序列至序列網路

一個序列至序列網路 [8]由一個編碼器以及一個解碼器所構成，不論編碼器或解碼器都是一個遞迴式迴歸網路。編碼器會輸入一段長度為  $l$  的序列資料  $x = x_1, x_2, \dots, x_l$ ，再將最後一個時間點的隱藏狀態 (Hidden State)  $h_l$  餵給解碼器，在此最後一個時間點的隱藏狀態向量代表著編碼器對於輸入序列資料的理解；接著解碼器會用編碼器最後一個時間點的隱藏狀態來初始化他自身的隱藏狀態，再根據此去產生長度為  $m$  的序列化的輸出  $y = y_1, y_2, \dots, y_m$ 。

### 2.2.4 專注式序列至序列網路

原始的序列至序列網路解碼器只會拿編碼器的最後一個隱藏狀態，然而這麼做可



能會較為忽略先前時間點的重要資訊，為了讓機器能夠專注在先前某個時間點的重要資訊，研究者提出了專注力 (Attention) [9] 機制，讓機器在產生輸出時也能夠專注在先前的若干時間點重要的輸入上。

專注式序列至序列網路的編碼器與原始的序列至序列網路相同然而編碼器做了如下的改變，首先在時間點  $t$  要產生一個輸出時，他會先計算要專注在編碼器的哪個時間點，如下：

$$e_i^t = v^T \tanh(W_h h_i + W_s s_t + b_a t t n) \quad (2.9)$$

$$a^t = \text{softmax}(e^t)$$

$e_i^t$  代表著編碼器第  $i$  時間點的資訊對於解碼器第  $t$  個時間點的重要性，而  $s_t$  是目前解碼器的隱藏狀態， $h_i$  是編碼器的第  $i$  個隱藏狀態， $W_h$  和  $W_s$  都是可訓練的參數，最後的  $a^t$  則是要專注編碼器哪個時間點的機率分佈。

再來根據這個機率分佈，可以得出一個前後文向量 (Context Vector)  $h_t^*$ ：

$$h_t^* = \sum_i a_i^t h_i \quad (2.10)$$

這個式子的意思就是把編碼器的隱藏狀態根據專注機率分佈來做加權平均得出前後文向量。最後這個前後文向量會再跟解碼器的隱藏狀態一起產生最後的詞分佈機率：

$$p_{vocab} = \text{softmax}(V'(V[h_t^*, s_t] + b) + b') \quad (2.11)$$

### 2.2.5 混合式指標網路

在文章摘要的任務中，因為摘要中的許多詞都會與編碼器的輸入文章中的詞相同，因此研究者提出指標網路 (Pointer Network) [10] 設法直接由文章複製詞成為摘要。指標網路是一種專注式序列至序列網路的變形，他以專注式序列至序列網路

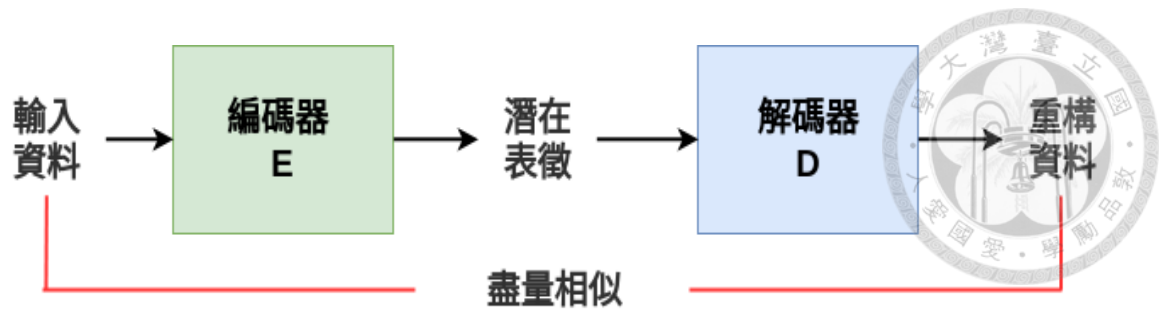


圖 2.2: 自編碼器的模型示意圖.

所產生的專注機率  $a_t$  來由文章複製詞。然而，摘要並非完全由文章的詞而來，於是研究者針對此特點進一步的提出混合式指標網路 (Hybrid Pointer Network) [11]，讓指標網路不只能由文章中去複製詞，更能如同一般的專注式序列至序列網路直接去產生詞的分佈。具體來說混合式指標網路改寫式 2.11 如下:

$$u = \text{sigmoid}(w_h^T h_t^* + w_s^T s_t + w_x^T x_t + b_u) \quad (2.12)$$

$$P'_{vocab} = u P_{vocab} + (1 - u) \sum_{i:w_i=w} a_i^t$$

上式以可訓練的參數  $u$  來控制新的字的機率分佈要由原來的專注式序列至序列網路的字分佈而來或者由文章中複製而來，其中如果字沒有出現在文章中  $\sum_{i:w_i=w} a_i^t$  就為 0，否則為那個字被專注的機率。

## 2.3 自編碼器(Autoencoder)

### 2.3.1 基本原理

自編碼器是一種非監督式學習的方法，希望能學習到代表資料的潛在表徵(Latent Representations)，此潛在表徵可以被視為機器對於資料的理解，一個好的潛在表徵能幫助機器達成各類任務，此外自編碼器也可以被用做模型的預訓練 (Pre-training)。如圖 2.2 所示，自編碼器通常會具備兩個元件：編碼器 (Encoder)



以及解碼器 (Decoder)，編碼器會先將資料壓縮成一個維度相較於原本資料較小的瓶頸向量，解碼器再設法由瓶頸向量去重構 (Reconstruct) 原本的資料，它訓練的目標是最小化重構損失函式，根據資料的不同或選用不同的損失函式，如果資料是連續的像是語音或者圖片，就會使用均方差的減損函數；而如果資料是離散的像是文字，通常就會使用交叉熵函數。

### 2.3.2 變分自編碼器(Variational Autoencoder, VAE)

原來的自編碼器傾向於將資料編碼成一個個點狀的離散分佈，只有在潛在空間(Latent Space)中自編碼器看過的資料才能夠被解碼器解碼為有意義的資料，因此自編碼器並非一個好的生成模型(Generative Model)，因為在潛在空間中大部份的點都不能被解碼器解碼為合理的資料。

為了解決此問題，研究者提出變分自編碼器 [12]，希望將每筆的資料不再編碼成一個點，而是一個分佈 (Distribution)。首先由機率模型的假設開始推導起，一個機率模型我們期望他最大化資料的似然度 (Likelihood)  $\log(p(x))$ ，於是可以利用變分推論 (Variational Inference) 將  $\log(p(x))$  展開如下：

$$\begin{aligned} \log(p(x)) &= \mathbb{E}_{z \sim q(z|x)}[\log(x|z)] - D_{KL}[q(z|x) \parallel p(z)] + \underbrace{D_{KL}[p(z|x) \parallel p(z)]}_{>=0} \\ &\geq \mathbb{E}_{z \sim q(z|x)}[\log(x|z)] - D_{KL}[q(z|x) \parallel p(z)] \end{aligned} \quad (2.13)$$

如此一來我們可以定義證據下界 (Evidence Lower Bound, ELBO) 為：

$$ELBO = \mathbb{E}_{z \sim q(z|x)}[\log(x|z)] - D_{KL}[q(z|x) \parallel p(z)] \quad (2.14)$$

最大化證據下界即為間接地最大化  $p(x)$ ，並且證據下界可拆為兩個不同的目標，第一項  $\mathbb{E}_{z \sim q(z|x)}[\log(x|z)]$  就是原先的自編碼器的目標函式，他要設法將由  $q(z|x)$  所抽樣的  $z$  重構回原來的  $x$ ，第二項則是要最小化編碼器編碼的  $q(z|x)$  與

先驗分佈  $p(z)$  間的庫雷散度 (Kullback-Leibler Divergence)，意即要讓兩個分佈之間的距離越近越好。一般來說，大多數人選擇使用標準常態分佈 (Standard normal Distribution):  $N(0, 1)$  來作為先驗分佈。



## 2.4 生成對抗網路(Generative Adversarial Networks, GAN)

### 2.4.1 基本原理

生成對抗網路 [5]成功的被應用在無數的任務上，包含非監督式學習，半監督式學習，語音的生成以及圖片的生成。生成對抗網路主要由兩個模組所組成，第一個模組是生成器 (Generator)  $G$ ，第二個模組是鑑別網路 (Discriminator)  $D$ ，這兩個網路會彼此相互對抗，這對抗的過程稱之為最小值最大化遊戲(Minimax Game)，當這個最小值最大化遊戲平衡時，我們期望生成器由先驗機率  $P_z$  所產生的資料分佈 $G(z)$ 能與真實資料分佈  $P_x$  相近，這個真實的資料分佈可以是人類所拍攝的照片、人類所講的語音又或是人類所書寫的文字。

- 鑑別網路 (Discriminator)

鑑別網路  $D$  的目標只有一個，就是要設法鑑別他的輸入是由真實的資料分佈(Distribution)  $P_x$  中抽樣的，又或是由生成器 $G$ 所產生的分佈 $G(z)$ 所抽樣的，其損失函數可以寫成如下所示:

$$\mathcal{L}_D = -(\mathbb{E}_{x \sim P_{data}} [\log(D(x))] + \mathbb{E}_{z \sim P_{noise}} [\log(1 - D(G(z)))]) \quad (2.15)$$

值得一提的是因為這是一個二元分類的問題，因此在 $D$ 的輸出層是一個sigmoid函式。



- 生成器 (Generator)

生成器  $G$  的目標是要某個分佈(Distribution)  $P_z$  映射到另外一個我們所期望的由人類所產生的分佈  $P_x$ ，也就是說我們希望生成器所產生出的輸出分佈  $G(z)$  能夠越像  $P_x$  越好。為了達成通常來說這個我們所期望的分佈是像是人類所產生的資料的分佈，像是人類所拍攝的照片、人類所講的語音又或是人類所書寫的文字，換句話說我們期望生成器能夠由  $P_z$  產生出像是人類所產生的真實分佈  $P_x$ 。為了達成此目地，生成器所產生的輸出必須要設法騙過鑑別網路，也就是說要設法讓鑑別網路認為它所產生出的輸出是出自於人類，其數學式子如下：

$$\mathcal{L}_G = -\mathbb{E}_{z \sim P_{noise}} [\log(D(G(z)))] \quad (2.16)$$

可以發現  $G$  的損失函數和  $D$  的損失函數是完全相反的，也就是說他們會一直互相對抗。2.16與2.15會一直不斷地交替的訓練下去，並且在訓練一方時另外一方的參數是固定的，這個訓練會一直持續到生成器能夠完全地騙過對抗網路，也就是說生成器所產生的分佈已經與真實資料的分佈一模一樣了。

## 2.4.2 使用生成對抗網路產生語言

### 使用生成對抗網路產生文字的困境

根據霍氏生成對抗網路(Wasserstein Generative Adversarial Networks, WGANs) [13]的推導，當鑑別網路被最佳化時，GAN 的公式 2.15 可以被視為要最小化由生成器產生的分佈以及人類產生的真實資料分佈間的JS散度(JS divergence)，JS散度在當兩個分佈間完全沒有交集時會是定值，這個意味著公式 2.15將無法提供任何的梯度給生成器，當想要產生的分佈是離散的分佈時，這個問題會更加嚴重，因為兩個離散的分佈間是幾乎沒有任何交集的，由於語言離散

的特性，因此這個問題在產生文字上會更加嚴重，也造成原來的生成對抗網路無法成功的運用在語言的生成上。

為了解決此問題，近年的研究朝向兩個方向發展，第一個方向是提出一種新的目標函式，這個目標函式必須要能更精準的評估兩個分佈間的距離，即使在兩個分佈間沒有交集也必須要能夠衡量他們間的距離，並且提供梯度給生成器。第二種方向則是使用強化學習(Reinforcement Learning, RL)，強化學習的優勢在於它能夠使用獎勵(Reward)來最佳化無法微分的目標函式。

### 使用新的目標函式

這類的方法不只適用於讓機器能夠產生離散的文字，也期望能讓生成對抗網路的訓練更加穩定，在此我要介紹的是霍氏生成對抗網路這個新的生成對抗模型。由於原始的生成對抗模型使用的JS散度是造成訓練不穩定以及兩個分佈沒有重疊時沒有梯度的主要原因，因此他們期望找到一種新的衡量兩個分佈間距離的方法，此方法必須要能夠衡量兩個沒有重疊分佈間的距離，於是在霍氏生成對抗網路中，作者將目光投射到一種名為推土距離(Earth-Mover Distance 又稱 Wasserstein Distance)的距離衡量方法，而兩個分佈間的推土距離約可以寫成如下的式子：

$$W(P_r, P_g) \approx \max_{w: |f_w(x_1) - f_w(x_2)| \leq K |x_1 - x_2|} \mathbb{E}_{x \sim P_r} f_w(x) - \mathbb{E}_{x \sim P_g} f_w(x) \quad (2.17)$$

這個式子的意思是兩個分佈間的推土距離可以被一個能夠最大化右式的函式 $f$ 所衡量，並且要求這個函式必須要滿足立氏 (Lipschitz) 連續條件，一個函式要滿足立氏連續條件，它的一階導函數必須不能超過某個範圍。在深度學習的領域中，每個類神經網路都可以被視為一組函式，這個函式由他的參數來掌握他的輸出，在對抗式生成器中這個要衡量兩個距離的函式即為鑑別器 $D$ ，而兩個分佈一個是來自於人類所產生的真實資料分佈，另外一個則是來自於生成器 $G$ ，於是  $D$  的損



失函數可以被寫成如下，

$$\mathcal{L}_D = -\mathbb{E}_{x \sim P_r} D(x) + \mathbb{E}_{z \sim P_z} D(G(z)) \quad (2.18)$$

直觀上，式子2.18可以理解為要讓真實的資料分佈有著越高的分數越好，而由生成器所產生的資料分佈有著越低的分數越好。為了要使D滿足立氏連續條件霍氏生成對抗網路使用梯度懲罰(Gradient Penalty) [14]來限制  $D$  的微分越接近1越好。因此加上梯度懲罰後， $D$  的式子變成如下，

$$\mathcal{L}_D^{gp} = \mathcal{L}_D + \lambda \mathbb{E}_{\hat{x}} [(\|\nabla_{\hat{x}} D(\hat{x})\|_2 - 1)^2] \quad (2.19)$$

其中  $\hat{x}$  是由真實資料與生成器所產生的輸出內差而來。由於G的目標與鑑別網路剛好相反，因此他的目標就是要讓D給他越高的分數越好，如下：

$$\mathcal{L}_G = -\mathbb{E}_{z \sim P_z} D(G(z)) \quad (2.20)$$

與原本的生成對抗網路相似，式子2.19 跟式子2.20也是交替著訓練。由於  $D$  的任務由二元分類任務改為直接輸出分數的迴歸任務，因此D輸出層的sigmoid也因此被拿掉了。

## 使用強化學習

這裡我要介紹的是這個方法中最有名的一篇文章序列生成對抗網路 (Sequence GAN, Seq-GAN) [15]，這個方法跟上述方法的最大不同之處在於上述的方法是直接把G的輸出詞分佈(Word Distribution)直接輸入  $D$ ，然而在使用強化學習類的方法中，會先根據每個時間點G所產生的詞分佈機率去抽樣一串詞，這一串詞也就是一個句子，然後再被餵進鑑別網路中，由於抽樣這個操作是無法微分的，因此會造成梯度無法由  $D$  流回  $G$ ，因此為了能讓  $G$  能夠最佳化它與  $D$  相

關的目標函式，強化學習成為最佳的選擇。一個強化學習的問題必須要定義幾個重要的要件，第一個是何為狀態(State)，第二個是狀態間要如何轉移(State Transition)，第三個是獎勵的函式(Reward Function)為何，最後是行為者(Agent)的行動空間(Action Space)為何。如果要將語言生成套用在強化學習的框架，它的行為者是產生文字的深度學習模型，通常此模型是遞迴式類神經網路，狀態則是目前產生了哪些詞的抽象表示，也就是遞迴式類神經網路得隱藏狀態，狀態的轉移則是由行為者所決定的產生下一個詞的機率，它每個時間點的行動則是產生一個詞，因此他所有可能的行為數目就是詞典中詞的數目。由於 $G$ 的目標函式是要騙過 $D$ ，亦即讓 $D$ 的分數越高越好，因此自然是 $D$ 的分數越高，他的獎勵越大。對於 $D$ 來說，他的目標函式依然不變，因此與式子2.15相似，只是多了個由 $G$ 抽樣一個句子這個操作，如下所示：

$$\mathcal{L}_D = -\mathbb{E}_{x \sim P_x} \log(D(x)) - \mathbb{E}_{s \sim G(z), z \sim P_z} (\log(1 - D(s))) \quad (2.21)$$

其中 $s$ 是由 $G(z)$ 所產生的分佈中抽樣出來的句子。接著 $G$ 則使用強化學習中的策略梯度 (Policy Gradient) 來進行學習，其損失函數 $\mathcal{L}_G$ 定義如下：

$$\begin{aligned} r_i &= -\mathbb{E}_{s \sim G(z), z \sim P_z} D(s) \\ \mathcal{L}_G &= -\frac{1}{L} \sum_{i=1}^L r_i \cdot \log(G(z)_i) \end{aligned} \quad (2.22)$$

其中 $L$ 是句子的長度，而 $G(z)_i$ 代表生成器在第 $i$ 個時間點所產生的詞分佈， $r_i$ 是在第 $i$ 個時間點的獎勵。然而由於這樣子做會使得生成器在每個時間點拿到的獎勵都會相同，於是在序列生成對抗網路中他在每個時間點都會做蒙地卡羅樹狀搜尋 (Monte Carlo Tree Search, MCTS)，由目前的時間點 $i$ 不斷的抽樣完整的句子給鑑別器評分，再用所有評分的平均當作第 $i$ 時間點的獎勵 $r_i$ 。



### 2.4.3 資訊生成對抗網路(Info-GAN)

如前所述，生成對抗網路是由一個先驗分佈  $P_z$  所抽樣的向量  $z$  去產生資料，然而  $z$  的每一個維度並沒有學到分離的，各自具有代表意義的特徵，以圖片生成為例，通常我們會期望  $z$  的某一個維度能夠代表圖片的種類，角度等等之類的特徵，為了讓生成對抗網路能夠學習更具有代表性的特徵，資訊生成對抗網路設法由一個干擾分佈  $z$  以及一個希望能學習到有代表特徵的  $c$  去產生資料  $G(z, c)$ ，並且最大化  $G(z, c)$  以及  $c$  之間的相互資訊(Mutual Information)。

然而，要衡量  $G(z, c)$  與  $c$  之間的相互資訊需要知道後驗機率  $P(c|G(z, c))$ ，由於在實際中我們無法知道後驗機率，因此資訊生成對抗網路 [6]使用變異推論來估計此項的證據下界，他們推出可以使用一個輔助函式  $Q$  來估計此最低限制， $Q$  可以是可訓練的類神經網路。訓練  $Q$  的方法很簡單，就是要盡量讓  $Q$  能由生成器的輸出  $G(z, c)$  去預測它的特徵向量  $c$ ，因此我們可以把  $Q, G, D$  的目標函式寫成如下：

$$\min_{Q, G} \max_D \mathbb{E}_{x \sim P_x} \log(D(x)) + \mathbb{E}_{c \sim P_c, z \sim P_z} \log(1 - D(G(c, z))) + \mathbb{E}_{c \sim P_c, z \sim P_z} c \log(Q(G(c, z))) \quad (2.23)$$

由式中可以發現  $Q$  與  $G$  的目標是相同的，他們都期望可以盡量讓  $Q$  去預測  $G$  的輸入向量  $z$ 。另外值得一提的是在原始的論文中  $Q$  與  $D$  的部分參數是共享的。

## 2.5 本章總結

這個章節介紹了本論文所會用到的有關於深層學習的背景知識，首先介紹深層網路以及其相關模型，再來介紹深層對抗網路以及其如何用於文字的生成。

# 第三章 使用生成對抗網路達成非監督式抽

## 象文章摘要



### 3.1 任務簡介

首先要介紹的是何為文章摘要 (Text Summarization)，文章摘要顧名思義就是要把一段較長的文章擷取其精華，濃縮成一段較短的文字，這個較短的文字可能是標題，又或者是一小段的摘要。

而文章摘要的方法大致上可以分為兩大類，第一大類是抽取式文章摘要 (Extractive Text Summarization)，抽取式文章摘要這類的方法是要為文章中的每一小段文字評估其重要程度，並且取重要程度分數高於個閾值或是重要前幾高的文字段落來當作摘要，通常這種每一小段文字會以句子為單位。

然而，事實上人類在做摘要時並非是抽取式的文章摘要，因為抽取式的文章摘要所選出的句子不見得會組成一段合理的短文，此外這樣選出的句子極有可能含有許多不必要的贅詞或者不重要的資訊，因此近年來研究者提出另一種更為接近人類的摘要方式，稱為抽象式摘要 (Abstractive Text Summarization)，抽象式摘要是要讓機器先讀過文章並且消化文章後，再根據機器對於文章主旨的吸收，一個詞一個詞的去產生摘要，並且摘要的詞不限於是否在文章出現過，因此機器能夠選擇更精簡抽象的詞來描述文章。

相較於抽取式文章摘要，抽象式文章摘要需要極為大量的資料來做訓練，因為文字的生成遠比句子的評分來的困難得多，然而在許多情況下取得大量的文章以及相對應的摘要並非易事，像是課程、會議的紀錄往往就沒有相對應的摘要。因此本論文設法讓機器由大量的沒有摘要的文章中去學習生成其抽取式摘要，並



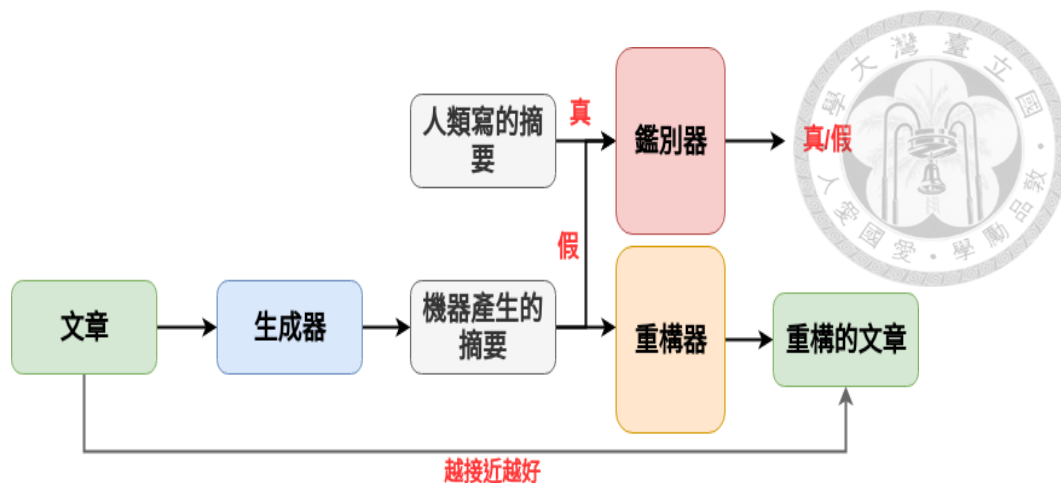


圖 3.1: 模型示意圖。給定長文，生成器設法產生摘要，它所產生的摘要必須最小化重構損失並且讓鑑別器認為產生的摘要為真，也就是要設法騙鑑別器讓它認為此摘要來自於人類。

且提供少量的人類寫的摘要當作範本讓機器瞭解人類是如何寫摘要的，這些人類寫的範本摘要並非需要和機器訓練的文章是配對的，並且本論文將這種訓練情境稱為非配對式文章摘要。

## 3.2 訓練方法

### 3.2.1 方法概述

方法主要的靈感來自於自編碼器，如先前章節所介紹的，自編碼器會將資料編碼成代表資料的潛在表徵，此潛在表徵相較於原來的資料有著較低的維度，並且潛在表徵為了要能夠良好的重構回原來的資料，他必須要抓住資料中重要的部分，因此這個潛在表徵就可以被視為資料的摘要。然而此潛在表徵跟文章摘要不同的地方是文章摘要是人類可讀的語言，於是本論文設法讓編碼器使用人類可讀的語言作為潛在表徵，為了達成此目標，本論文使用生成對抗網路來限制中間的潛在



表徵是人類可讀的語言。

如圖 3.1 所示，模型由三個模組所構成，分別是生成器  $G$ ，鑑別器  $D$  以及重構器  $R$ ，其中  $G$  和  $D$  組成一個生成對抗網路，而  $G$  和  $R$  組成一個自編碼器。 $G$  的網路架構是一個混合式指標網路，並且有兩個角色，一個角色是生成對抗網路的生成器，另外一個角色則是自編碼器中的編碼器，它以長度為  $M$  的文章  $x = \{x_1, x_2, \dots, x_M\}$  為輸入，其中每個  $x$  代表一個詞，並且設法把文章編碼成長度為  $N$  的人類可以理解的語言潛在表徵  $G(x) = \{y_1, y_2, \dots, y_N\}$ ，其中每個  $y_i$  都是一個詞的機率分佈。為了讓  $G(x)$  是文章的摘要， $G(x)$  必須要能夠重構回原本的文章  $x$ ，並且要能夠騙過鑑別器  $D$ ，讓它誤以為這是人類寫的摘要。

而  $D$  的模型架構則是一個長短期記憶模型，它的角色則是生成對抗網路中的鑑別器，它以機器產生的摘要  $G(x)$  或者人類寫的摘要  $y^{real} = \{y_1^{real}, y_2^{real}, \dots, y_N^{real}\}$  為輸入，並且要設法鑑別此摘要是人類寫的或者機器產生的，其中  $D$  輸入的人類寫的範本摘要跟  $G$  所輸入的文章是完全無關的，只是要讓  $G$  了解人類寫的摘要的寫法。第三個網路  $R$  的角色就好比自編碼器中的解碼器，它以  $G$  所產生摘要為輸入，並且設法將此摘要重構回原來  $G$  所輸入的文章。可以把  $D, R, G$  的目標函數寫成數學式如下：

$$\begin{aligned} \mathcal{L}_D &= \mathbb{E}_{y^{real} \sim P_{y^{real}}} \log(D(y^{real})) + \mathbb{E}_{x \sim P_x, y^s \sim G(x)} \log(1 - D(y^s)) \\ \mathcal{L}_R &= \mathbb{E}_{x \sim P_x, y^s \sim G(x)} - \sum_i^M x_i \cdot \log(R(y^s)_i) \\ \min_{G, R} \max_D \mathcal{L}_D + \alpha \mathcal{L}_R \end{aligned} \quad (3.1)$$

其中  $\mathcal{L}_R$  是重構回原來文章的重構損失， $\alpha$  則是控制重構損失比例的超參數 (Hyper-parameter)，而  $\mathcal{L}_D$  則是生成對抗網路訓練的目標，值得專注的是  $R$  及  $D$  並非直接輸入  $G(x)$ ，而是由  $G(x)$  分佈抽樣一個句子  $G(x)^s = \{y_1^s, y_2^s, \dots, y_N^s\}$  出來，上標  $s$  代表是根據機率隨機抽樣的，其中每個  $y_i^s$  都是一個離散的詞。

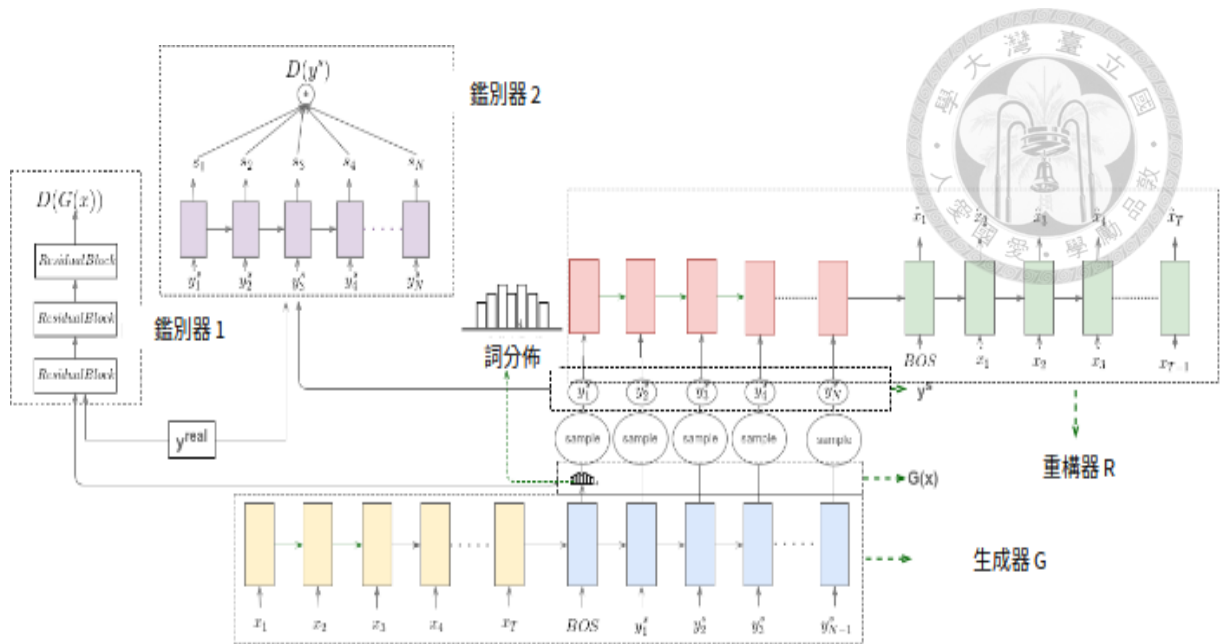


圖 3.2: 提出模型的詳細的架構。

### 3.2.2 最小化重構損失

然而，實際上上述的  $\mathcal{L}_R$  對於  $G$  來說是沒有辦法直接得到來自於  $R$  的梯度的，因為中間有經過抽樣這個離散的操作。於是，為了使  $G$  能夠最小化  $\mathcal{L}_R$ ，我使用強化學習中的策略梯度來解決此問題，對於生成器來說其損失函數如下：

$$\mathbb{E}_{x \sim P_x} - \sum_i^N r^R \log(G(x)_i) \quad (3.2)$$

其中  $r^R$  是  $-\mathcal{L}_R$ ，上標  $R$  的意思是這個獎勵是來自於重構網路  $R$ ，然而由於重構損失隨著資料的不同會有很大的差異，也造成  $r^R$  的變異 (Variance) 非常大，於是這裡引入強化學習中最常被拿來使用降低變異的方法：將獎勵減去基準 (Baseline)。本論文選擇一種被拿來用在序列產生的基準，自我批判 (Self-Critic) [16]來做訓練，首先他還會再用貪婪 (Greedy) 算法抽樣一個句子，貪婪算法就是在每個時間點都選擇機率最大的詞，最後使用貪婪算法所抽樣的句子  $y^a$  輸入  $R$  的分數當作



基準，於是  $r^R$  可以被寫成如下：

$$r^R = \sum_i^M [x_i \cdot \log(R(y^s)_i)] - \sum_i^M [x_i \cdot \log(R(y^a)_i)] \quad (3.3)$$

### 3.2.3 生成對抗網路的訓練

生成對抗網路訓練的目的是希望生成器能夠學習如何產生很像人類寫的摘要的輸出，在本節我們試著用兩種方法來達成生成對抗網路的訓練，一種是不做抽樣，直接將生成器的輸出詞分布輸入鑑別器來評分，並且使用霍氏對抗網路來做訓練；另外一種則是我們所提出的強化學習的方法，此方法會對生成器的輸出詞分布做抽樣，再將抽樣的輸出輸入鑑別器來鑑別真偽。

#### 霍氏對抗網路學習法

如圖 3.2 所示，最左邊的鑑別器-1 是此方法所使用的鑑別器，由數個殘差網路 (Residual Blocks) 所構成，以生成器所輸出的一系列的詞分佈作為輸入，由於在此使用霍氏生成對抗網路，因此改寫式 3.1 的  $\mathcal{L}_D$  函數如下：

$$\begin{aligned} \mathcal{L}_D = & \mathbb{E}_{x \sim P_x} D_1(G(x)) - \mathbb{E}_{y^{real} \sim P_{real}} D_1(y^{real}) \\ & + \beta_1 \mathbb{E}_{y^i \sim P_i} (\Delta_{y^i} D_1(y^i) - 1)^2 \end{aligned} \quad (3.4)$$

其中  $y^i$  是產生的  $G(x)$  以及任意挑選的  $y^{real}$  內差而來，此方法實施梯度懲罰在  $y^i$  上，而  $\beta_1$  則是控制梯度懲罰大小的超參數。

而生成器的損失函數如下：

$$\mathcal{L}_G = -\mathbb{E}_{x \sim P_x} D_1(G(x)) \quad (3.5)$$

，生成器損失函數的目的就是要盡量混搖  $D$ ，也就是盡量讓生成器產生的資料  $G(x)$  由  $D$  得到較高的分數。




圖 3.3: 自我批判學習強化法的實際例子。

### 自我批判強化學習法

有鑑於霍氏對抗網路學習法所產生的文字品質仍然不夠好，我們試著提出一種新的強化學習訓練方式來改善原先序列生成對抗網路，並且將其與霍氏生成對抗網路結合。

序列生成對抗網路最大的問題在於它在每個時間點都必須要使用蒙地卡羅搜尋樹來衡量目前時間點生成器的獎勵，否則生成器所產生的整個序列的獎勵都會相同，也會因此而無法有效的訓練生成對抗網路。然而，蒙地卡羅搜尋樹是很花時間的，會使訓練的時間與序列長度的平方成正比，在訓練速度本身就極慢的遞迴式類神經網路更是加深了此問題。

為了解決此問題，本論文試著不做蒙地卡羅搜尋樹，而是直接使用一個長短期記憶體網路來估計在每個時間點生成器應該要拿到的獎勵。此方法使用的鑑別器是圖 3.2 的鑑別器-2 簡寫為  $D_2$ ， $D_2$  以由  $G(x)$  所抽樣的  $y^s$  或者人類所產生的  $y^{real}$  為輸入，並且如圖 3.2 所示， $D_2$  在每個時間點  $i$  都會輸出一個分數  $s_i$ ， $s_i$  代表著截至目前時間點  $i$ ， $y_{1:i} = \{y_1, y_2, \dots, y_i\}$  是否像人類寫的摘要，越高分代表越像人類寫的摘要，並且  $D_2$  要盡可能地在越早的時間點鑑別它的輸入是來自於人類亦或是生成器。

舉例來說，如圖 3.3 所示，因為“arrested”這個詞重複出現了，在第二個

“arrested” 出現後，鑑別器判斷這是一個由生成器所產生的句子，因此序列後面的詞也同樣被打分了很低的分數，並且由於  $D_2$  使用霍氏生成對抗網路來做訓練，它所輸出的分數不限於 0 到 1 之間。具體而言，為了定義  $D_2$  的損失函數，給予一個句子  $y = \{y_1, y_2, \dots, y_N\}$  為  $D_2$  的輸入， $D_2$  會輸出  $s = \{s_1, s_2, \dots, s_N\}$ ，再來定義  $D_2$  的損失函數  $\mathcal{L}_{D_2}$  如下：

$$D_2(y) = \frac{1}{N} \sum_{i=1}^N s_i \quad (3.6)$$

$$\mathcal{L}_{D_2} = \mathbb{E}_{y^s \sim G(x)} D_2(y^s) - \mathbb{E}_{y^s \sim P_{real}} D_2(y^{real}) + \beta_2 \mathbb{E}_{y^s \sim P_i} (\Delta_{y^i} D_2(y^i) - 1)^2$$

其中  $D_2(y)$  代表鑑別器預測的分數的平均，而  $y^i$  則是由  $y^s$  與任意  $y^{real}$  內插而來。 $\mathcal{L}_{D_2}$  鼓勵  $D_2$  盡早鑑別出它的輸入是人類寫的摘要或者生成器產生的，因為一旦在某個時間點鑑別出  $y$  來自於生成器， $D_2$  就能將此時間點後的分數都降低，也就是說  $D_2(y)$  能夠變得更低。

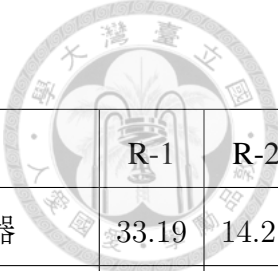
而生成器則是用強化學習中的策略梯度來做學習，首先定義第  $i$  個時間點來自於  $D_2$  的獎勵如下：

$$r_i^D = \begin{cases} s_i & \text{if } i = 1 \\ s_i - s_{i-1} & \text{otherwise.} \end{cases}$$

其中  $s_i - s_{i-1}$  代表以上個時間點的分數當做基準 (Baseline)，這個時間點的句子變好或變壞了多少，選擇以上一個時間的分數當作基準是因為整個句子可能只有一個詞是不合理的，但這個不合理的詞卻會讓之後時間點的詞分數跟著變低，因此如果以上個時間點當作基準就能夠更準確的評估句子是在哪個時間點產生不合理的詞。

生成器使用策略梯度來最大化來自於鑑別器的損失函數如下：

$$\mathbb{E}_{x \sim P_x} - \sum_{i=1}^N r_i^D \log(G(x)_i) \quad (3.7)$$



任務	標註數量	方法	R-1	R-2	R-L
(A) 監督式學習	3.8M	(A-1) 監督式學習的生成器	33.19	14.21	30.50
		(A-2) 專注式序列至序列 [17]	29.76	11.88	26.96
		(A-3) 卷積式專注式序列至序列 [18]	33.78	15.97	31.15
		(A-4) 選擇式編碼網路 [19]	<b>36.15</b>	<b>17.54</b>	<b>33.63</b>
(B) 簡單的標準方法	0	(B-1) 前 8 個詞為摘要	21.86	7.66	20.45
(C) 非平行式學習	0	(C-1) 預訓練的生成器	21.26	5.60	18.89
		(C-2) 霍氏對抗網路	28.09	9.88	25.06
		(C-3) 自我批判強化學習法	<b>28.11</b>	<b>9.97</b>	<b>25.41</b>
(D) 半監督式學習	10K	(D-1) 霍氏對抗網路	29.17	10.54	26.72
		(D-2) 自我批判強化學習法	<b>30.01</b>	<b>11.57</b>	<b>27.61</b>
	500K	(D-3) 離散語言壓縮 [20]	30.14	12.05	27.99
		(D-4) 霍氏對抗網路	32.50	13.65	29.67
		(D-5) 自我批判強化學習法	<b>33.33</b>	<b>14.18</b>	<b>30.48</b>
	1M	(D-6) 離散語言壓縮 [20]	31.09	12.79	28.97
		(D-7) 霍氏對抗網路	33.18	14.19	30.69
		(D-8) 自我批判強化學習法	<b>34.21</b>	<b>15.16</b>	<b>31.64</b>
(E) 遷移式學習	0	(E-1) 預訓練的生成器	21.49	6.28	19.34
		(E-2) 霍氏對抗網路	25.11	7.94	23.05
		(E-3) 自我批判強化學習法	<b>27.15</b>	<b>9.09</b>	<b>24.11</b>

表 3.1: ROUGE 分數在英文十億詞資料庫上。



## 3.3 實驗

### 3.3.1 資料介紹

我們評估我們的模型在三個不同的資料集上，分別是英文十億詞(English Gigaword)，中文十億字 (Chinese Gigaword) 以及有線電視日常信件 (CNN/Daily Mail)。

#### 英文十億詞


英文十億詞來自於語言資料聯盟 (Linguistic Data Consortium, LDC)，此資料庫收集了紐約時報 (New York Times, NYT)，英文新華社 (Xinhuan News English, XIE)，聯合世界潮流英文報導 (Associated Press Worldstream English, APW)，以及法國英文報導機構 (Agence France Press English, APW) 的新聞。由於原始的資料庫極為雜亂，如氏 (Alexander M. Rush) [17]對其做了預處理並且將其分割出380萬筆的訓練資料 (Training Set)，40萬筆的驗證資料 (Validation Set) 以及40萬筆的測試資料 (Testing Set)，為了能夠與前人的研究成果比較，我們使用先前文章所提供的2000筆測試資料來測試而非原來的測試資料。其中每筆資料都由成對的新聞第一句話以及其對應的標題所組成，因為它將長句壓縮成短句，因此是一個句子摘要(Sentence Summarization)的資料庫。

在做非平行式的訓練時，我們使用其中 190 萬篇文章以及 40 萬則人類寫的摘要做訓練，我們只取文章的前 50 個詞作為生成器的輸入，摘要的前 13 個詞作為範本摘要，並且設詞彙量為 1.5 萬詞。

#### 有線電視日常信件

有線電視日常信件的性質與中文十億詞相似都是長文摘要的資料庫，它由成對的





摘要以及文章所組成，每則摘要平均有3.75句話，每篇文章平均有781個詞。它由那氏 (Ramesh Nallapati) [21] 進行預處理，並且切成 29 萬筆訓練資料，一萬三千筆驗證資料以及一萬一千筆測試資料。在使用此資料庫做非平行式的訓練時，我們使用其中 15 萬筆文章做訓練，5 萬筆摘要作為範本摘要，並且只取文章的前 250 個詞作為生成器的輸入，摘要的前 50 個詞作為範本摘要，而詞彙則設量為 1.5 萬詞。


### 中文十億字

中文十億詞來自於語言資料聯盟，它是一個長文摘要的資料庫，由成對的文章以及其標題所組成，此資料庫收集了1991年到2002年間台灣中央社與中國新華社的新聞報導，其中中央社的新聞佔67%，其餘為新華社新聞。我們將長度小於20字的文章以及長度大於150字的文章去掉，再隨機取出 110 萬篇文章用做編碼器的訓練，20萬則標題當做鑑別網路的範本標題，1 萬筆資料用做驗證資料，1 萬筆資料用做測試資料。在使用此資料庫做非平行式的訓練時，我們取文章的前 60 個字作為生成器的輸入，摘要的前 15 個字作為範本摘要，並且設字彙量為 6 千字。

### 3.3.2 實做細節

#### 模型架構

生成器和重構器的模型架構是完全一模一樣的，除了輸入和輸出的長度，他們都是混合式指標網路，並且編碼器和解碼器都是一層有著 600 隱藏維度的長短期記憶體。而在章節 3.2.3 中霍氏對抗網路學習法中，鑑別器的參數為 4 層有著 512 隱藏維度的殘差網路；而在章節 3.2.3 中的自我批判學習法中，模型架構是一層 512 隱藏維度的長短期記憶體。



## 訓練細節

在非平行式訓練中我們設式 3.1 中的超參數  $\alpha$  為 25，在章節 3.2.3 中霍氏對抗網路學習法中，我們設式 3.5 中控制梯度懲罰的  $\beta_1$  為 10，並且使用訓練速率為  $1e-5$  的 RMSProp 優化器 (optimizer) 在生成器上，使用訓練速率為  $1e-3$  的 RMSProp 優化器在鑑別器上。

在章節 3.2.3 中的自我批判學習法中，我們設式 3.6 中控制梯度懲罰的  $\beta_1$  為 1，並且使用學習速率為  $1e-5$  的 RMSProp 優化器在生成器上，使用訓練速率為  $1e-3$  的 RMSProp 優化器在鑑別器上。

### 3.3.3 評量方法

我們使用 ROUGE (Recall-Oriented Understudy for Gisting Evaluation) [22]來作為主要的評分方法，ROUGE 是林欽佑博士 (Dr. Chin-Yew Lin) 在2004年時提出的一種自動摘要評分方法，現今大多自動摘要的論文都以此作為主要的評分方法，ROUGE 分數越高代表生成摘要的品質越佳。<sup>1</sup>

ROUGE 主要是在評量人類寫的參考摘要以及生成的摘要兩者間的重疊，它會先計算重疊的數目，再依此計算精確率 (Precision) 以及召回率 (Recall)，最後得出 F1 分數 (F1-score)，普遍來說，大多論文都以 F1 分數來當作 ROUGE 分數。ROUGE 依照需求的不同有數種不同的衡量的情境，像是 ROUGE-N (N=1,2,3,4) 或者 ROUGE-L，底下會再做詳細的介紹。

#### ROUGE-N

首先要介紹的是 ROUGE-N 的 F1 分數的計算方式，其中 N 代表計算參考摘要以

<sup>1</sup>我們使用 pyrouge 來衡量模型，並且用參數 -m -n 2 -w 1.2 來衡量所有的實驗。



及生成的摘要兩者間有多少 N 連文法 (N-Gram) 的重疊，在計算 F1 分數前，要先計算 ROUGE-N 的精確率如下：

$$R_{prec}^N = \frac{\sum_{x^{ref} \in X^{ref}, x^{sys} \in X^{sys}} Count_N(x^{ref}, x^{sys})}{\sum_{x^{sys} \in X^{sys}} |x^{sys}|} \quad (3.8)$$

其中  $Count_N(x^{ref}, x^{sys})$  代表著機器生成的摘要  $x^{sys}$  與人類寫的參考摘要  $x^{ref}$  有多少個 N 連文法是一樣的，而  $|x^{sys}|$  代表機器產生的摘要的長度。而 ROUGE-N 的召回率計算方式如下：

$$R_{rec}^N = \frac{\sum_{x^{ref} \in X^{ref}, x^{sys} \in X^{sys}} Count_N(x^{ref}, x^{sys})}{\sum_{x^{ref} \in X^{ref}} |x^{ref}|} \quad (3.9)$$

最後 F1 分數為：

$$R_{F1}^N = \frac{2 \times R_{rec}^N R_{prec}^N}{R_{rec}^N + R_{prec}^N} \quad (3.10)$$

## ROUGE-L

再來要介紹的是 ROUGE - L 的計算方式，在此 L 的意思為最長共同子序列 (Longest Common Subsequence, LCS)，ROUGE-L 的計算方式如下：

$$\begin{aligned} R_{prec}^L &= \frac{\sum_{x^{ref} \in X^{ref}, x^{sys} \in X^{sys}} LCS(x^{ref}, x^{sys})}{\sum_{x^{sys} \in X^{sys}} |x^{sys}|} \\ L_{rec}^L &= \frac{\sum_{x^{ref} \in X^{ref}, x^{sys} \in X^{sys}} LCS(x^{ref}, x^{sys})}{\sum_{x^{ref} \in X^{ref}} |x^{ref}|} \\ R_{f1}^L &= \frac{2 \times R_{rec}^L R_{prec}^L}{R_{rec}^L + R_{prec}^L} \end{aligned} \quad (3.11)$$

### 3.3.4 非平行式摘要用於英文十億詞

非平行式摘要的意思是使用大量沒有摘要的文章，以及少量摘要來做訓練，我們將訓練資料中的 190 萬篇文章用做自編碼器的訓練：生成器以文章為輸入，並且編碼為摘要，而重構網路要設法重構回原來的文章；40 萬則標題用於鑑別器的範本標題：鑑別器要設法鑑別它的輸入是來自於範本標題亦或是生成器。

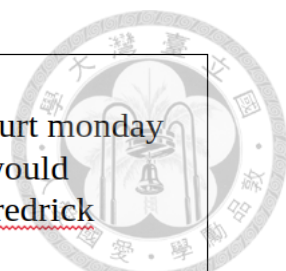


<b>文章:</b> global one communications will launch its global intranet <unk> -lrb- virtual private networks -rrb- service in new zealand by the end of the year , the new zealand infotech weekly reported monday .	
<b>人類寫的摘要:</b> international intranet service destined for new zealand	<b>(A-1)Supervised Result:</b> global one communications to launch global networks in new zealand
<b>(C-2)霍式對抗網路:</b> global communications launch global service in new zealand	<b>(C-3)自我批判強化學習法:</b> global communications launch global virtual private networks in new zealand
<b>(E-2)霍式對抗網路:</b> global one communications will launch its global networks -rrb- service	<b>(E-3)自我批判強化學習法:</b> global one communications will launch its global virtual networks

圖 3.4: 英文十億詞的例子。

實驗結果如表 3.1 所示，在任務 (A) 監督式學習中，模型使用成對的文章以及摘要來做訓練。在 (A-1) 中，我們將生成器  $G$  做監督式的訓練，這個結果可以被視為非平行式學習的表現的上限，在 (A-2) 中所使用的是使用專注式序列至序列網路所產生的結果，在 (A-3) 中則使用卷積式專注式序列至序列網路，它使用卷積網路作為編碼器，在 (A-4) 中使用的則是選擇式編碼網路，它提出一種新的訓練方式來選擇哪些資訊是重要的。由於我們所使用的生成器網路相對簡單，只是一層的長短期記憶體網路的編碼器以及一層長短期記憶體網路的解碼器，因此就監督式學習的表現而言我們所使用的模型沒有達到最好。

在任務 (B) 簡單的基準 (Simple Baseline) 方法中，我們使用文章的前八個詞作為摘要，會使用前八個詞的原因是摘要的平均長度大約是八個詞。在任務 (C) 非平行式的訓練是本篇論文的主要結果，(C-1) 是非監督式預訓練生成器的結果，



<b>文章:</b> former zambian president kenneth kaunda appeared in court monday on charges of holding an illegal rally , declaring that he would continue to fight the `` oppressive regime " of president <u>fredrick chiluba</u> .	
<b>人類寫的摘要:</b> former zambian president in court for illegal assembly	<b>(A-1)監督式訓練結果:</b> zambia 's kaunda in court over illegal rally
<b>(C-2)霍式對抗網路:</b> zambian kenneth kaunda in court charges of holding illegal rally	<b>(C-3)自我批判強化學習法:</b> former zambian kenneth kaunda in court on charges of holding illegal rally
<b>(E-2)霍式對抗網路:</b> he appeared in court he would continue to fight illegal rally	<b>(E-3)自我批判強化學習法:</b> former zambian president kenneth kaunda appeared in court on charges holding illegal rally

圖 3.5: 英文十億詞的例子。

由表中可以看出預訓練的生成器結果其實並不理想；在 (C-2) 中則是單單使用章節3.2.3 中的霍氏生成對抗網路來迫使生成器產生摘要，在 (C-3) 中則是使用章節3.2.3 我們所提出的強化學習演算法做生成對抗的學習。由表中可以發現相對於預訓練的生成器，使用本篇論文所提出的演算法能夠讓其結果有著明顯的進步，這也意味著我們所提出的方法是有效的；我們所提出的算法也比簡單的基準方法的結果好上許多，我們提供我們模型所產生的摘要在圖 3.4 以及圖 3.5中，以及更多的例子在圖3.7到圖3.12，例子中的方法的編號與表 3.1 中方法的編號是相互對應的。

### 3.3.5 半監督式摘要於英文十億詞

在半監督式摘要中，我們首先使用非常少量的配對資料來預訓練生成器，並

且在做非平行式的訓練時每隔若干個迭代就會使用配對的資料來做老師強迫 (Teacher Forcing)，以此來規範生成器在有標註的資料上的表現不會下降。

如表 3.1 任務 (D) 所示，在半監督式摘要中，我們分別使用 1 萬筆，50 萬筆以及 100 萬筆的訓練資料，並且分別每隔 25, 5, 3 個非平行式訓練的更新做一次老師強迫。由表中可以發現僅僅使用一萬筆的配對資料就能夠讓結果有著顯著的提昇，在使用 1 百萬筆的訓練資料結果甚至能夠比使用全部 380 萬筆資料的結果稍稍好些，可能的原因是生成對抗網路的訓練能夠鼓勵生成器學習到更好的摘要語言模型，也因此摘要的表現能夠更好。此外我們也與其他半監督式學習摘要的論文 (D-3) 做比較，在都使用 50 萬筆或者 100 萬訓練資料做訓練時，我們的模型表現均較佳。

### 3.3.6 遷移式學習於英文十億詞

然而，人類寫的摘要範本在一般的情況下可能不易取得，因此我們設法使用來自於不同資料庫的摘要以及範本摘要來做訓練，更具體來說我們使用英文十億詞的文章來作為自編碼器的訓練資料，並且使用有線電視新聞網的摘要來作為鑑別器的範本摘要，如此一來模型的訓練就不需要使用任何英文十億詞的摘要當作範本也能夠在英文十億詞上達成摘要的任務，我們把此訓練情境稱為遷移式學習。

然而，事實上有線電視新聞網的摘要和英文十億詞的摘要是極為不同的，因為英文十億詞的摘要只有一句話，而有線電視新聞網的摘要平均來說由將近四句話所組成，於是我們將有線電視新聞網的摘要中的每一個句子都視為一個獨立的範本摘要，並且濾除有太多詞沒有出現在英文十億詞的詞彙中的摘要。

遷移式學習的結果如表 3.1 (E) 部份，由表中可以發現相較於 (C) 部份，使用不同資料庫的摘要作為鑑別器的範本摘要使結果變得更差，這是因為每個資料庫

的摘要都有其特殊寫法以及者風格或者偏好使用的詞，因此如果讓生成器學習其他資料庫摘要的寫法會讓模型在目標的資料庫上表現較差。



### 3.3.7 非平行式摘要用於有線電視日常信件

方法		R-1	R-2	R-L
(A) 監督式學習	(A-1) 監督式學習的生成器	38.89	13.74	29.42
	(A-2) 混合式指標網路 [11]	39.53	17.28	36.38
(B) 前 3 句為摘要 [11]		40.34	17.70	36.57
(C) 非平行式學習	(C-1) 預訓練的生成器	29.86	5.14	14.66
	(C-2) 霍氏對抗網路	35.14	<b>9.43</b>	<b>21.04</b>
	(C-3) 自我批判強化學習法	<b>35.51</b>	9.38	20.98

表 3.2: ROUGE 分數在有線電視日常信件的資要庫上。

由於有線電視日常信件是現今最多人使用的摘要資料庫，因此我們亦衡量我們的模型在此資料庫上。在此資料庫的結果如表 3.2 所示，在監督式學習的實驗中 ((A) 部份)，由於我們使用較簡單的模型來做實驗，並且使用較短的摘要以及文章，因此模型的結果與原始作者的分數有一小段差距。而在簡單基準方法中 ((B) 部份)，我們使用前三個句子作為摘要，可以發現使用前三個句子作為摘要的結果甚至比監督式訓練的結果還好，這是因為新聞資料庫傾向於將最重要的資訊寫在前幾句話。

非平行式的摘要的結果在 (C) 部份中，由表中可以發現 (C-1) 預訓練的生成器非平行式訓練大幅的提升效能，然而相較於監督式學習的結果，可以發現 ROUGE - 1 的結果較佳，而 ROUGE - 2 的分數以及 ROUGE - L 的分數相對低很多，這意

<p><b>文章:</b>  <b>lrb cnn rrb civil unions between people of the same sex will soon be recognized in chile . the country joined several of its south american neighbors in allowing the unions when president michelle bachelet enacted a new law on monday . this is a concrete step in the drive to end the difference between homosexual and heterosexual couples , bachelet said . the new law will take effect in six months . it will give legal weight to cohabiting relationships between two people of the same sex and between a man and a woman . the chilean government estimates that around 2 million people will be able to benefit from the change .</b></p>
<p><b>人類寫的摘要:</b>  <b>president michelle bachelet signs law that will take effect in six months . chile joins several other south american nations that allow the unions .</b></p>
<p><b>(C-2)霍式對抗網路:</b>  <b>civil unions between people of the same sex will soon be recognized in chile . the country joined several of its south american neighbors in allowing the unions when president michelle enacted a new law on monday . this is a concrete step in the drive .</b></p>
<p><b>(C-3)自我批判強化學習法:</b>  <b>president michelle enacted a new law on monday . this is a concrete step in the same sex will soon be recognized in chile . the country joined several of its south american neighbors .</b></p>

圖 3.6: 有線電視新聞網的例子。

味著他雖然能夠抓到關鍵詞，然而它無法將其組成合文法的句子，因此這兩個分數會較低。事實上使用生成對抗網路去生成較長文句仍然是一個極為困難的問題，也因此在這個資料庫上產生的句子無法十分的通順並且合理，我們提供一個這個資料庫上的例子在圖 3.6 中。

### 3.3.8 非平行式摘要用於中文十億詞

在做中文十億詞的實驗時，生成器一個個產生的是中文的字而非詞，並且在衡量 ROUGE 分數時也是以字而非詞做計算。中文十億詞的結果如表 3.3 所示，由於是



方法		R-1	R-2	R-L
(A) 監督式學習的生成器		49.62	34.10	46.42
(B) 前 15 字為摘要		30.08	18.24	27.74
(C) 非平行式學習	(C-1) 預訓練的生成器	28.36	16.73	26.48
	(C-2) 霍氏對抗網路	38.15	24.60	35.27
	(C-3) 自我批判強化學習法	<b>41.25</b>	<b>26.54</b>	<b>37.76</b>

表 3.3: ROUGE 分數在中文十億詞資料庫上。

使用字來衡量分數，而字的數量因此相較於英文少很多，因此他的 ROUGE 分數相較於英文的資料庫會較高。在簡單基準方法中 ((B) 部份)，我們使用前 15 個字作為摘要，非平行訓練的結果相較於預訓練的生成器以及簡單標準方法也有明顯的進步。

### 3.4 本章總結

本章節介紹了如何使用生成對抗網路來使用人類可理解的語言作為自編碼器的潛在表徵，並且因此達成非平行式的摘要；此外，我們也探討如何使用生成對抗網路產生離散的語言，並且試著提出一種新的強化學習的方法來更有效地產生語言，在英文以及中文上摘要的結果也驗證了我們所提出的方法的可行性。



<b>文章:</b> south korea issued a stern warning monday against illegal labor disputes and campus protests and announced the arrest of ### radicals for violent weekend disturbances .	
<b>人類寫的摘要:</b> south korea issues stern warning against labor and campus activists	<b>(A-1)監督式訓練結果:</b> south korea issues stern warning against illegal labor disputes
<b>(C-2)霍式對抗網路:</b> south korea issued stern warning against illegal labor disputes	<b>(C-3)自我批判強化學習法:</b> south korea issued stern warning against illegal labor disputes campus arrest
<b>(E-2)霍式對抗網路:</b> south korea issued stern warning against illegal labor disputes and arrest	<b>(E-3)自我批判強化學習法:</b> south korea issued stern warning against illegal labor disputes campus protests

圖 3.7: 英文十億詞的例子。

<b>文章:</b> dutch police arrested monday ## environmentalists who were attempting to prevent the destruction of a <unk> -lrb- ##-acre -rrb- woods next to an airport used by nato forces , the anp news agency reported .	
<b>人類寫的摘要:</b> dutch police arrest ## environmental protesters	<b>(A-1)監督式訓練結果:</b> dutch police arrest ## environmentalists over nato destruction
<b>(C-2)霍式對抗網路:</b> dutch police arrested ## environmentalists attempting to prevent destruction	<b>(C-3)自我批判強化學習法:</b> dutch police arrested ## environmentalists attempting to prevent destruction of woods
<b>(E-2)霍式對抗網路:</b> dutch police arrested who were attempting to prevent destruction of a -lrb-	<b>(E-3)自我批判強化學習法:</b> dutch police arrested monday ## environmentalists who were attempting to prevent destruction woods

圖 3.8: 英文十億詞的例子。

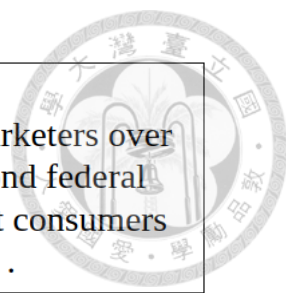


<b>文章:</b> the fbi has arrested a father and son with suspected links to al-qaeda in lodi , california , the los angeles times reported wednesday .	
<b>人類寫的摘要:</b> two men with suspected al-qaeda links arrested in california	<b>(A-1)監督式訓練結果:</b> fbi arrests father son with suspected links to al-qaeda
<b>(C-2)霍式對抗網路:</b> fbi arrested in father son with al-qaeda links	<b>(C-3)自我批判強化學習法:</b> fbi arrested father and son with suspected links to al-qaeda california
<b>(E-2)霍式對抗網路:</b> fbi has arrested father and son with suspected links to al-qaeda	<b>(E-3)自我批判強化學習法:</b> fbi has arrested a father and son with suspected links al-qaeda

圖 3.9: 英文十億詞的例子。

<b>文章:</b> the thai government will set up an independent committee to investigate the management and lending practices of the state-owned krung thai bank -lrb- ktb -rrb- , channel # , thailand 's state television station reported monday .	
<b>人類寫的摘要:</b> thailand to investigate state-owned bank	<b>(A-1)監督式訓練結果:</b> thai government to set up committee to investigate lending practices
<b>(C-2)霍式對抗網路:</b> thai set up independent committee to investigate management	<b>(C-3)自我批判強化學習法:</b> thai government set up independent committee to investigate management lending practices
<b>(E-2)霍式對抗網路:</b> the thai committee will set up an independent committee to investigate the management	<b>(E-3)自我批判強化學習法:</b> thai government will set up an independent committee to investigate

圖 3.10: 英文十億詞的例子。



<p><b>文章:</b> the bewildering fight between the government and telemarketers over the national do-not-call list took another turn when a second federal agency said it would enforce the program , promising that consumers would soon see some reduction in telephone sales pitches .</p>	
<p><b>人類寫的摘要:</b> fcc steps in to enforce do-not-call list ; bush signs new law to support program</p>	<p><b>(A-1)監督式訓練結果:</b> second federal agency vows to reduction telephone sales</p>
<p><b>(C-2)霍式對抗網路:</b> fight between government over national list took turn</p>	<p><b>(C-3)自我批判強化學習法:</b> fight between government over national list took turn second</p>
<p><b>(E-2)霍式對抗網路:</b> three stores and markets was forced to shut down</p>	<p><b>(E-3)自我批判強化學習法:</b> fight between the government over the national list took another turn second</p>

圖 3.11: 英文十億詞的例子。

<p><b>文章:</b> three stores and markets in beijing 's fengtai district have been forced to shut down and yesterday each was fined ####,### yuan -lrb- ##,### us dollars -rrb- for violating laws and regulations on fire prevention and control .</p>	
<p><b>人類寫的摘要:</b> stores markets punished for lack of fire controls</p>	<p><b>(A-1)監督式訓練結果:</b> three stores fined for violating on fire</p>
<p><b>(C-2)霍式對抗網路:</b> three stores markets in beijing 's district have forced to shut down yesterday</p>	<p><b>(C-3)自我批判強化學習法:</b> three stores markets in beijing 's district have forced to shut down</p>
<p><b>(E-2)霍式對抗網路:</b> three stores and markets was forced to shut down and was fined</p>	<p><b>(E-3)自我批判強化學習法:</b> three stores and markets in beijing 's district was fined</p>

圖 3.12: 英文十億詞的例子。

# 第四章 使用資訊生成對抗網路達成文章主題模型



## 4.1 任務簡介

首先要介紹的是何謂文章主題模型。文章主題模型是機器學習以及自然語言處理中一個很經典的問題，它的目標是希望能讓機器藉由閱讀大量未標註的文章來自動發現文章中的主題，並且幫助人類來更好的理解、分析這些文章，舉例來說，給予機器大量的新聞文章，我們會希望機器能自動將新聞歸類為政治類、體育類或者社會新聞。

然而，本論文中我們所希望機器發現的文章主題是和過去傳統的機率主題模型或者近年來研究者所提出的類神經網路主題模型稍有不同的。先前研究所期望發現的主題通常是較為瑣碎或者較小的主題，舉例來說在體育類的新聞中，他們會將體育這個主題分為許多不同的小主題，像是籃球、網球或者棒球等等較小的主題，但在本章中，我們希望機器能直接發現像是體育這種較明顯並且較貼近人類認知的主題。

那麼為什麼先前的文章主題模型不能發現這種較大較明顯的主題呢？其主要原因是因為這些類的模型都假設一篇文章是由若干主題的混合 (Mixture of Topics) 所產生的，意思是他們假設一篇文章必須要由若干個主題產生，如果不遵從這個假設，而是假設文章來自於一個主要的主題，他們將會無法去模擬文章與文章間的變異，並且同一個主題下的文章將會完全相同。

為了解決此問題，我們設法提出一種新的主題模型: 生成對抗主題模型 (Topic GAN)，生成對抗主題模型不再假設文章是由混合的主題所產生，而是假設文章

是由一個主要的主題，以及一個向量去模擬這個主題下的變異，也就是模擬這個主題下的次要主題，藉此我們成功地讓機器學習更為貼近人類認知的主題。

為了驗證我們方法的有效性，首先我們做非監督式文章主題分類的實驗在 6 個截然不同的資料庫上，並且發現我們模型的表現超越所有先前的主題模型，也超越非監督式分類 (Unsupervised Clustering) 的方法。我們也抽取各個主題的主題詞，並且透過主題一致性 (Topic Coherence) [23] 的量化分析，證明我們的方法能夠學習更為合理並且一致的主題。

值得一提的是，相較於先前的主題模型無法有效地產生合乎文法的文章，我們也提出一種新的訓練方式來讓機器產生各個主題下的文章，藉由產生大量各個主題下的文章，人類更能清楚的了解機器到底學習到了哪些主題。

## 4.2 訓練方法

### 4.2.1 方法簡介

我們所提出的生成對抗主題模型主要是建立在資訊生成對抗網路 (InfoGAN) [6] 上，我們假設文章是由一個離散的主題向量  $c$  以及一個連續的雜訊  $z$  所產生。 $c$  的每一個維度代表著一個主題，而  $z$  控制一個主題下的變異。因為直接產生序列的文字是極為困難的，並且也很難由其發現合理的主題，我們首先會將文章變成詞袋 (Bag-of-words) 向量。此外，我們發現直接套用資訊對抗網路上在文字的資料上無法取得很好的效果，我們也設法提出些有用的延伸去改善資訊生成對抗網路，這些延伸包括: (1) 限制類別損失的大小 (2) 將資訊生成對抗網路與自編碼器結合 (3) 使用霍氏生成對抗網路 (4) 使用預訓練的詞向量。

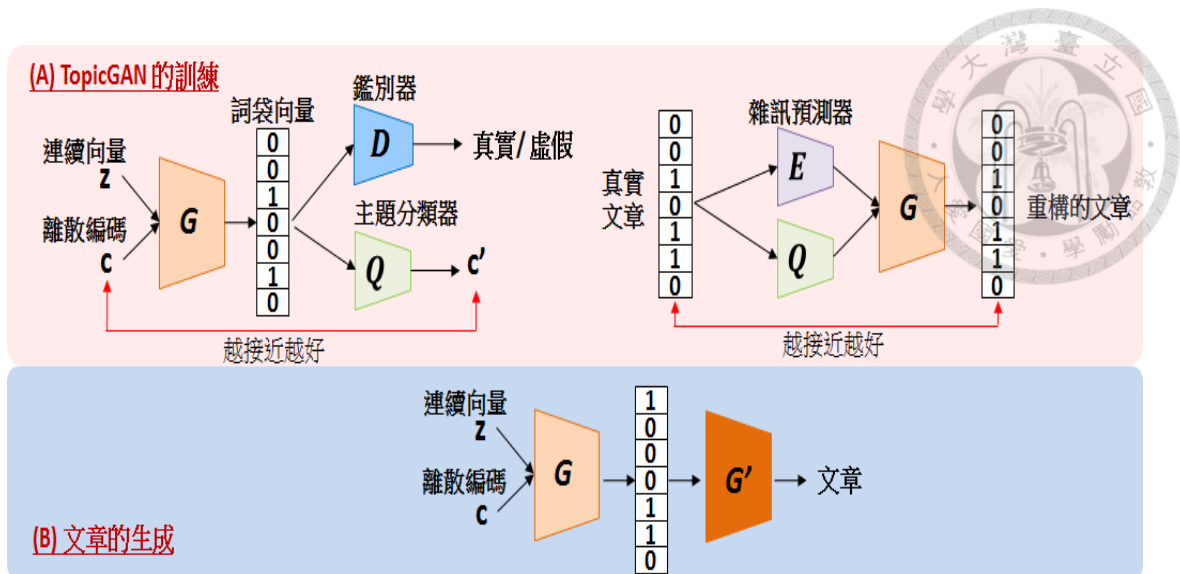


圖 4.1: 我們的模型的示意圖。(A)在左邊的部份中，生成器  $G$  以離散的文章主題分佈  $c$  以及連續的雜訊向量  $z$  為輸入來產生詞袋向量；鑑別器  $D$  以詞袋向量為輸入並且鑑別其是來自於人類或者生成器；主題分類器  $Q$  以生成的詞袋向量為輸入並且預測文章的隱藏主題。在(A)右邊的部份則是自編碼器的訓練，自編碼器的訓練以人類寫的文章的詞袋向量為輸入，其中雜訊預測器  $E$  以及主題分類器  $Q$  形成一個編碼器，而  $G$  則是解碼器，他們要設法重構輸入的詞袋向量。(B)則是文章的生成，首先  $G$  會先產生詞袋向量，再來  $G'$  設法根據輸入的詞袋向量並且設法產生文章。

#### 4.2.2 模型介紹

如圖 4.1 (A) 所示，生成對抗主題模型由四個模組所組成，分別是生成器  $G$ ，鑑別器  $D$ ，主題分類器  $Q$ ，以及一個雜訊預測器  $E$ 。

- 生成器  $G$

生成器  $G$  以一個離散的主題向量  $c$  以及一個連續的雜訊  $z$  為輸入，並且設法產生文章的詞袋向量  $G(c, z)$ ，其中  $G(c, z)$  是一個有著跟詞典大小一樣維度的向量，並且每個維度都是s型函數介於 0 到 1 之間的輸出，代表著這個詞



是否在文章之中。我們希望  $G(c, z)$  能夠有著  $c$  的主題資訊，並且跟人類所寫的文章的詞袋向量要是相似的， $G(c, z)$  會不做抽樣直接輸入  $D$  以及  $Q$ 。

- 鑑別器  $D$

鑑別器以詞袋向量為輸入，並且輸出一個機率，他要給來自於人類文章的詞袋向量  $x$  越高的機率越好，並且給來自於生成器的詞袋向量  $G(c, z)$  越低的機率越好，如果寫成式子， $D$  的損失函數  $\mathcal{L}_D$  如下：

$$\mathcal{L}_D = -\mathbb{E}_{x \sim P_{data}}[\log(D(x))] - \mathbb{E}_{z \sim P_z, c \sim P_c}[\log(1 - D(G(z, c)))], \quad (4.1)$$

其中  $P_{data}$  是真實資料的分佈， $P_z$  是雜訊的分佈， $P_c$  是主題的分佈。在接下來的實驗中我們使用常態分佈 (Normal Distribution) 做為  $P_z$ ，均勻分佈 (Uniform Distribution) 作為  $P_c$ ，由  $P_c$  抽樣的  $c$  是一個離散的並且只有一個維度會是 1 其他維度都是 0 的向量。

- 主題分類器  $Q$

給定一個詞袋向量向量为輸入， $Q$  會設法預測它輸入的主題分佈，我們訓練它設法預測生成器所產生的詞袋向量向量为  $G(c, z)$ ，我們稱其損失函數為類別損失，並且定義類別損失  $\mathcal{L}_Q$  如下：

$$\mathcal{L}_Q = \mathbb{E}_{z \sim P_z, c \sim P_c, c' = Q(G(z, c))}[\mathcal{L}_{ce}(c, c')], \quad (4.2)$$

- 雜訊預測器  $E$

它只被用於自編碼器的訓練，我們使用它來預測來自於人類所寫的文章的詞袋向量的雜訊。





### 4.2.3 模型的訓練

#### 資訊生成對抗網路的訓練

我們使用下式去訓練生成器  $G$ ，鑑別器  $D$  以及主題分類器  $Q$ :

$$\min_{G,Q} \max_D -\mathcal{L}_D + \lambda \mathcal{L}_Q. \quad (4.3)$$

其中  $\lambda$  是一個超參數，我們發現如果  $\lambda$  的值太大， $G$  為了最小化  $\mathcal{L}_Q$  會產生不合理的詞袋向量，因此我們設  $\lambda$  的值為 0.1。 $D$  試著最小化  $\mathcal{L}_D$ ， $Q$  試著最小化  $\mathcal{L}_Q$ ， $G$  試著最大化  $\mathcal{L}_D$  並且最小化  $\mathcal{L}_Q$ 。然而，很難直接使用資訊生成對抗網路在文字的資料上，因此在接下來的章節我們提出些額外的延伸來幫助訓練。

#### 限制類別損失的大小

在訓練時，我們發現模型在相同的主題下有很嚴重的模式塌陷 (Mode Collapse)，也就是說，給定一個相同的主題向量  $c$ ，生成器會忽視  $z$  並且一直產生相同的詞袋向量。會有這樣的原因是生成器最大化兩個離散資料  $c$  和  $G(c, z)$  的相互資訊的最佳解就是忽視  $z$  並且永遠輸出相同的  $G(c, z)$ 。為了解決此問題，我們限制式 4.2 中類別損失的大小不低於一個下限:

$$\mathcal{L}'_Q = \mathbb{E}_{z \sim P_z, c \sim P_c, c' = Q(G(z, c))} [\max(\mathcal{L}_{ce}(c, c'), \alpha)]. \quad (4.4)$$

這個式子讓當類別損失已經足夠低時它就會停止下降，這個門檻是由一個超參數  $\alpha$  所決定，如果設  $\alpha$  過大會妨礙  $Q$  去預測正確的  $c$ ，因此我們設一個稍微比零還大的值 0.15。值得一提的是批次的正規劃 (Batch Normalization) [24] 也能夠大幅的減緩模式塌陷的問題。



## 將資訊生成對抗網路與自編碼器結合

如同先前的文章所述，如果演算法設計夠好，將生成對抗網路與自編碼器結合並且交替訓練是十分有效的 [25,26]，因此我們也試著將兩者結合，這個方法可以被視為另外一種避免模式塌陷的方式，我們使用來自於人類寫的文章的詞袋向量去訓練自編碼器。

自編碼器的訓練方式如圖 4.1 (A) 的右半部所示，詞袋向量  $x$  由雜訊預測器  $E$  以及主題分類器  $Q$  所各自編碼為  $E(x)$  以及  $Q(x)$ ，也就是說這兩個模組形成一個編碼器，而在這個訓練中，生成網路  $G$  扮演的角色則是解碼器，負責將  $E(x)$  以及  $Q(x)$  重構回原來的  $x$ ，也就是說  $E, Q, G$  一起最小化重構損失：

$$\min_{G, Q, E} \mathbb{E}_{x \sim P_{data}, x' = G(Q(x), E(x))} [\mathcal{L}_{bce}(x, x')], \quad (4.5)$$

在其中二元交叉熵  $\mathcal{L}_{bce}$  被拿來當作重構損失函數。我們交替著訓練式 4.3 以及式 4.5。

## 使用霍氏生成對抗網路


由於使用生成對抗網路產生離散的資料是非常困難的，我們發現我們無法使用原先的生成對抗網路去成功地產生詞袋向量，因此我們使用霍氏生成對抗網路並且重寫式 4.1 為：

$$\mathcal{L}'_D = -\mathbb{E}_{x \sim P_{data}} [D(x)] + \mathbb{E}_{z \sim P_z, c \sim P_c} [D(G(z, c))]. \quad (4.6)$$

並且為了讓  $D$  滿足立氏連續，我們對  $D$  施以梯度懲罰。

## 使用預訓練的詞向量

先前的論文的實驗結果顯示將預訓練的詞向量像是詞轉向量(Word2vec) [27]與文章主題模型結合能幫助模型發現更為一致並且合理的文章主題 [28]，因此我們也



試著將我們的模型結合詞向量。我們將  $Q$  加入預訓練的詞向量來鼓勵它發現更一致的主題，當  $Q$  以詞袋向量為輸入時，他會先使用預訓練的詞向量將字做加權平均得到一個文章向量，加權平均的權重是由可訓練的參數而來。文章向量會再被輸入一個線性模型並且得出文章主題分佈，我們使用快速文字 (Fasttext) [29]來獲得預訓練的詞向量。

#### 4.2.4 由產生的詞袋向量產生文章

為了更進一步的解釋我們的模型學到了什麼，我們試著由我們模型所發現的主題來生成各個主題的文章，方法如圖 4.1 (B) 所示，給定一個離散的文章主題分佈  $c$ ，我們抽樣許多不同的  $z$  去產生不同的詞袋向量  $G(c, x)$ ，並且使用一個文章生成器  $G'$  去設法由此詞袋向量設法產生文章。

$G'$  的模型架構如下所述，首先詞袋向量會先輸入一個順向類神經網路，再用順向類神經網路的輸出去初始化一個長短期記憶體解碼器的初始狀態，接下來此解碼器會依據其初始狀態產生相對應的文章。 $G'$  可以由成對的詞袋向量以及其相對應文章來訓練，因為每篇文章都有其相對應的詞袋向量，我們可以獲得無數的此類訓練資料，此外為了讓模型更加穩定，我們會在輸入的詞袋向量加上一些雜訊，讓  $G'$  即使以有雜訊的詞袋向量為輸入亦能產生相對應的文章。

### 4.3 實驗

#### 4.3.1 資料介紹

我們衡量我們的模型在六個不同的資料庫上，包含

- 20新聞集合 (20NewsGroups)



20新聞集合是一個新聞資料庫，它收集了 20 個不同種類的新聞，總共有 18000 則新聞，其中 10659 則新聞用於訓練，其餘則用於測試。

- 雅虎問答集 (Yahoo! answers)

雅虎問答集由鄭翔等人 [30]所收集，每則資料都是由一個問題以及其回答所組成，其中共有 10 種不同的問題種類，總共有 140 萬筆訓練資料以及 6 萬筆測試資料。

- 資料庫百科項目分類 (DBpedia Ontology Classification)

資料庫百科項目分類由鄭翔等人 (Xiang Zhang et al.) [30]所收集，資料庫百科嘗試收集有結構性的維基百科 (Wikipedia) 資料，資料庫百科項目鑑別共有 14 種不同的項目，共有 56 萬筆訓練資料以及 7 萬筆測試資料。

- 程式設計問答標題分類 (Stackoverflow Title Classification)

程式設計問答標題分類由蘇嘉銘等人 (Jiaming Xu et al.) [31]所收集，其中共收錄 14 種不同種類的標題，有 16000 則標題被用來訓練，4000 則標題被用作測試。

- 艾基新聞 (AGnews)

艾基新聞由鄭翔等人 (Xiang Zhang et al.) [30]所收集，其中有 4 種不同種類的新聞，每則新聞由標題以及其內文所組成，共有 12 萬筆訓練資料，8000 筆測試資料。

- 新聞類別資料庫 (News-Category)

新聞類別資料庫收集 20 萬筆 2012 到 2018 賀夫新聞 (HuffPost) 的新聞，我們選擇其中頻率最高的 11 個種類的新聞，其中共有 58000 筆訓練資料以及 6600 筆測試資料。



### 4.3.2 模型架構與參數

在所有的資料上以及所有的實驗中，我們都使用相同的模型架構以及優化器。  $G$  的模型架構是一個有著 3 層維度為 1000 隱藏層的順向類神經網路，  $D$  的模型架構是一個有著 2 層維度為 500 隱藏層的順向類神經網路，  $Q$  的模型架構則是一個預訓練的詞向量以及一個線性模型，其中預訓練的詞向量維度為 100，  $E$  是一個有著 1 層維度為 500 隱藏層的順向類神經網路。其中  $G, D, E, Q$  都使用亞當優化器 (Adam Optimizer)，並且學習速率為 0.0005，  $\beta_1 = 0.5$  而  $\beta_2 = 0.999$ 。

### 4.3.3 非監督式文章分類


#### 實驗設置

當測試我們的模型時，我們將模型的主題數目(也就是  $c$  的維度)設成跟資料庫的類別數目相同，舉例來說在艾基新聞有 4 種不同種類的新聞，我們就設模型的主題數目為 4；而在所有的實驗中  $z$  的維度則被設為 200，如果將它的維度設為其他的數字像是 50 或 100 並不會影響模型的結果。

我們使用文章分類器  $Q$  來預測文章的隱藏主題分佈，並且指定文章的主題為機率最大的隱藏主題，然而我們並不知道每個隱藏主題所對應的真實主題，或者真實的類別，因此每個隱藏主題中的文章會用其來自於人類的真實類別去投票決定每個隱藏主題應該要被指定為哪個真實類別，在指定每個隱藏主題他真實的類別後，我們衡量其分類的精確度 (Accuracy) 來作為衡量文章主題模型好壞的依據。

#### 比較基準方法

由於我們的模型可以被視為一種自編碼式的主題模型，因此我們與兩個變分自



編碼器類的模型做比較，包含類神經變分文件模型 (Neural Variational Document Model ,NVDM) [32] 以及專家乘積潛藏狄氏雷模型 (ProdLDA) [33]，為了有公平的比較，這兩個模型使用與我們模型相同的詞典，以及相同的主題數。我們也亦與傳統的機率主題模型像是隱含狄氏分布模型 (LDA) [34] 做比較，在 ”LDA-少量主題” 中，我們設主題的數目與人類標註的類別數目相同，在 ”LDA + k-means” 中，我們設隱含狄氏分佈模型的主題的數目為 100，再將主題分佈做 k-平均演算法 (k-means) 來做非監督式的分類。

在非監督式文章表徵學習類的方法中，我們先設法編碼文章為一個文章向量，接著再將這些文章向量做k-平均演算法 (k-means) 來達成非監督式的分類，在 ”預訓練詞向量平均 +kmeans” 中，我們以預訓練詞向量的平均作為文章向量，在此預訓練的詞向量與我們模型所使用的預訓練詞向量是相同的，在 ”sent2vec+kmeans” 中，文章向量是由目前最好的非監督式文章抽取方法句到向量 (Sent2vec) [35] 所抽取。

## 結果以及討論

由表 4.1 中可以發現，與兩個變分式自編碼器類的方法以及隱含狄氏模型相比，我們的模型 TopicGAN 大幅地增加非監督式文章分類的準確率，不論變分式自編碼器類的方法或者隱含狄氏模型他們都假設文章是由混合的主題所產生，為了去模擬文章與文章間的變異，他們必須將一個大主題拆成數個不同的小主題，因此先前的模型需要將主題的數目設為較大的數目像是 50 或者 100，因為在我們所測試的資料庫中，每一篇文章都屬於一個單一的類別，假設文章來自於混合的主題是十分不合理的。

然而，由於我們所提出的模型能夠以一個雜訊向量來控制一個主題內的變

方法	20新聞	雅虎	資料百科	程式問答	艾基新聞	新聞類別
<b>TopicGAN</b>	<b>31.36</b>	<b>51.32</b>	<b>85.37</b>	<b>47.01</b>	<b>84.13</b>	<b>49.32</b>
NVDM	24.63	33.21	46.22	26.33	62.36	30.12
ProdLDA	30.02	39.65	68.19	25.13	72.78	38.62
LDA-少量主題	29.78	25.95	68.42	36.14	71.94	27.42
LDA + k-means	25.62	21.58	55.37	45.14	42.81	21.06
詞向量平均 + k-means	28.63	38.91	69.04	22.44	73.83	37.78
sent2vec+k-means	28.06	51.24	60.98	36.78	83.82	40.64

表 4.1: 非監督式文章分類準確度。

異，我們能夠直接假設文章由一個單一主要的主題所生成，這假設也與人類對於文章主題的認知較為一致，也因此我們的模型能夠發現與人類標註的類別一致的主題。

由於文章的主題也能夠由將數個小主題聚合成一個大主題來推得，因此我們也試著將隱含狄氏分布模型所學習的小主題做k-平均演算法，然而事實上這樣做反而得到更差的結果，這也證明了由這個方向去推得文章的主要主題是不可行的。另外一個方向是將文章向量做非監督式的分類來得到文章的主要主題，然而與這類的方法相比，我們所提出的方法仍然取得較佳的結果。可能的原因是因為我們試著最大化一個離散的分佈以及生成資料間的分佈，這鼓勵主題分類器  $Q$  去學習更具代表性的特徵並且因此更能將文章分類為不同的主題。

#### 4.3.4 主題一致性

在這個章節我們設法抽取出的可以描述每一個主題的主題詞的品質，我們實施定

方法	20新聞	雅虎問答	資料庫百科	英文十億詞
LDA	42.68	36.34	51.06	35.61
TopicGAN 有預訓練詞向量	43.01	<b>55.92</b>	<b>62.16</b>	<b>46.12</b>
TopicGAN 沒有預訓練詞向量	<b>45.22</b>	45.64	54.23	41.79
NVDM	42.36	47.02	49.95	37.22
ProdLDA	43.44	52.01	55.26	43.17

表 4.2: 主題一致性的分數，越高越好。

量分析 (Quantitative Analysis) 以及質性分析 (Qualitative Analysis)。

## 實驗設置

在這個章節，所有模型的主題數目與資料庫的類別數目相同，此外為了證明我們的模型不止能做在有標註的資料庫上，我們也做在未有類別標註的資料上，我們選擇英文十億字來衡量我們的模型，並且設主題數目在此資料集上為 10。

我們使用  $C_v$  分數 [36] 去定量衡量主題詞的品質，並且使用 560 萬筆的英文維基百科來作為外部的資料庫來計算  $C_v$  分數， $C_v$  主要是計算一個隱藏主題內的主題詞兩兩間的正規化的點對點間的相互資訊 (Normalized Pointwise Mutual Information, NPMI)，而字跟字之間的相互資訊則是由外部的資料庫而來，兩個詞  $w_i$  以及  $w_j$  之間的 NPMI 的計算方式如下：

$$NPMI(w_i, w_j) = \frac{\log \frac{P(w_i, w_j) + \epsilon}{P(w_i) \cdot P(w_j)}}{-\log(P(w_i, w_j) + \epsilon)} \quad (4.7)$$

其中  $\epsilon$  是為了避免  $\log$  中的值為 0。

## 文章主題詞的抽取

我們從主題分類器  $Q$  去抽取每個主題的主題詞， $Q$  由預訓練的詞向量以及一個線



性模型所構成。假設  $W_{V \times N}$  為預訓練的詞向量，其中  $V$  是詞彙量，而每一行都是一個維度為  $N$  的詞向量，再來假設線性模型的權重矩陣為  $M_{K \times N}$ ，其中  $K$  是主題的數目，我們讓  $C_{K \times V} = M \cdot W^T$ ，其中  $C_{k,v}$  代表著第  $v$  個詞對於第  $k$  個主題的重要性，因此在第  $k$  行中值最高的幾個詞就可以被視為第  $k$  個主題的主題詞。

## 結果以及討論

量化分析的結果如表 4.2 所示，由結果可以發現我們所提出的模型相較於其他模型都要來的好，這也說明了我們的模型能夠抽取出更合適一致的主題詞來代表每一個隱藏主題。

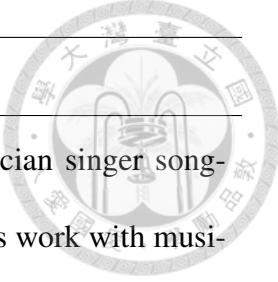
而至於質性分析，我們提供我們所產生的主題詞在表格 4.3，由表中可以發現我們所抽取的主題詞在每個主題中彼此都是高度相關的，此外我們也提供這些主題由章節 4.2.4 所產生相對應的文章在表格 4.4 中，由其中可以看出這些文章都是與其對應主題相關連的文章。

我們提供各種方法所學出的主題詞在表 4.8 到表 4.10 中，由表 4.8 中可以發現我們的方法所產生較為一致的主題詞，舉例來說在我們方法所產生的第一個隱藏主題的主題詞都與科學有關，第二個隱藏主題的主題詞都與電腦的操作有關而第三個主題都與政治有關。在表 4.9 中大部份的主題詞有都彼此一致，但是在像是倒數第二個隱藏主題中 "cousin", "do i" 以及 "bc" 這些看似不相關的詞就被放在同一個主題，在 NVDM 中更多不合理的例子可以被發現，像是在最後一個隱藏主題中 "diet" 還有 "movie" 就不該被放在同一個主題，在倒數第四個隱藏主題中 "immigrants" 還有 "cup" 就彼此不相關，而 LDA 所產生的主題詞品質又更差了，它甚至會抽取出一些功能詞像是 "does", "did" 或者 "dont"。



資料庫	主題編號	主題詞
資料庫百科	1	pianist, composer, singer, cyrillic, songwriter, romania, poet, painter, jazz, actress, musician, tributary
	2	skyscraper, building, courthouse, tower, historic, plaza, brick, floors, twostory, mansion, hotel, buildings, register, tallest, palace
	3	midfielder, footballer, goalkeeper, football, championship, league, striker, soccer, defender, goals, matches, cup, hockey, medals
英文十億詞	1	inflation, index, futures, benchmark, prices, currencies, output, outlook, unemployment, lowest, stocks, opec, mortgage
	2	sars, environment, pollution, tourism, virus, disease, flights, water, scientific, airports, quality, agricultural, animal, flu, alert
	3	polls, votes, elections, democrats, electoral, election, conservative, re-election, democrat, candidates, republicans, liberal, presidential

表 4.3: 由我們模型所發現的主題所產生的主題詞。在資料庫百科中主題 1 是有關於音樂，主題 2 是有關於建築而主題 3 是有關於運動。在英文十億詞主題 1 是有關於經濟，主題 2 是有關於疾病，而主題 3 是有關於政治。



資料庫	主題編號	生成的文章
DBpedia	1	james nelson is an american musician singer songwriter and actor he was a line of his work with musical career as metal albums in 1989
	2	the UNK is a skyscraper located in downtown washington dc district it was completed june 2009 and tallest building currently
	3	UNK born 3 january 1977 is a finnish football player who plays for west coast club dynamo he has won bronze medals at 2007
English Gigaword	1	oil prices fell in asia friday as traders fear of the world demand for biggest drop summer months figures
	2	the world health organisation has placed on bird flu in nigeria 's most populous countries virus , saying they are expected to appear
	3	the ruling party won overwhelming majority of seats in opposition 's battle for sweeping elections

表 4.4: 表 4.3 中的主題所產生的對應的文章。在相同資料庫的文章是由相同  $z$  但是不同的  $c$  所產生的。

### 4.3.5 切除分析 (Ablation Study)

#### 訓練的技巧

如表 4.5 所示，如果沒有限制類別的損失這個技巧，可以發現再大部份的資料上

方法	20新聞	雅虎	資料百科	程式問答	艾基新聞	新聞類別
TopicGAN	31.36	<b>51.32</b>	<b>85.37</b>	47.01	<b>83.85</b>	<b>49.32</b>
TopicGAN 無限制類別損失	30.12	45.92	83.32	40.99	83.66	47.42
TopicGAN 無自編碼訓練	29.14	43.07	78.76	31.60	81.62	45.12
TopicGAN 無預訓練詞向量	<b>41.01</b>	42.91	83.73	<b>64.46</b>	72.65	48.14
TopicGAN 有一隱藏層	36.89	42.14	71.26	46.14	69.78	47.32


表 4.5: 切除分析在非監督式文章分類上，表中的數字代表準確度。

訓練的結果會稍微差一些；如果除去自編碼器的訓練對於結果的影響較大，在大部份的資料庫上都有較大幅度的下降，這個結果也應證了我們所提出的額外的訓練技巧的有效性。

### 主題分類器的模型架構

我們發現主題分類器的模型架構未大幅地影響最後的結果，因此在表 4.5 中我們試了數種不同的架構，在第一行中原來的 TopicGAN 有使用預訓練的詞向量，可以發現跟沒有使用詞向量相比在大部份的資料庫上非監督式分類的準確率都有顯著的進步，同樣的現象在表 4.2 也可以發現，我們發現在使用預訓練的詞向量沒有進步的資料庫上他的訓練資料都較少，由於我們預訓練的詞向量是在每個資料庫上個別訓練的，因此在資料較少的資料庫上它無法訓練出有好的語意表徵。

此外我們也發現如果使用較為複雜的模型， $Q$  的模型的表現也會較差，在“沒有預訓練的詞向量中”我們沒有使用隱藏層， $Q$  只是一個單純的線性模型，可以發現與底下使用一層隱藏層的模型相比其結果較佳，可能是因為如果  $Q$  是一個極為複雜的模型，它可能會學習到很複雜但是沒有意義的表徵來將它的輸入映射



---

### Generated Text

---

UNK is a historic public square located in south bronx built in 1987

---

UNK is a french southwest hotel originally located in the of greece south carolina it was conceived by josef

---

UNK in historic district is a methodist church located in south african cape was added to national register of places 200

---

表 4.6: 由表 4.3 主題編號 2 所產生的文章，他們來自於相同的  $c$  但是不同的  $z$ 。

到目標的分佈上，也造成最後文章分類的結果不好。

### 4.3.6 分離式表徵

我們的模型一個很重要的假設是我們能夠學習到分離式的表徵，我們能夠將離散的文章主題分佈  $c$  以及其主題下的次要主題的資訊  $z$  分離，為了更進一步的解釋我們的模型所學習到的資訊，我們使用章節 4.2.4 中的方法去產生文章，由於我們想知道我們的模型是否能將  $c$  與  $z$  分離，在表格 4.4 中我們使用相同的  $z$  但是不同的  $c$  來產生文章，由表格中可以發現文章與文章間幾乎沒有重複的字，這代表著  $z$  所編碼的資訊與  $c$  是完全無關的。

我們也想知道  $z$  是否能控制一個主題下的變異，因此在表格 4.6 以及表格 4.7 中，我們使用相同的文章主題分佈  $c$  但是不同的  $z$  來產生文章，由表格可以發現所產生的文章很明顯的都來自於同一個主題，他們都是敘述建築的文章，但是因為  $z$  的不同因此他們產生不同有關於建築的文章，這個結果顯示  $z$  能夠控制在一個主題下次要主題的資訊，也就是主題下的變異，這個結果更加說明我們的模型能夠成功地學習到分離式的表徵。

## 4.4 本章總結

在這一章節我們提出一種新的非監督式學習的架構來探索文章主題模型的新方向，藉由學習分離式的離散的主題以及一個連續的雜訊向量來控制次要主題的資訊，我們的模型達成極為優異的非監督式文章分類的結果，並且能夠學習到與人類認知相當接近的文章主題，而抽取出的文章主題詞以及我們模型所生成的文章更加地說明我們的模型能夠學習可解釋的主題。



---

## Generated Text

---

british airports leaders plan to ban on one of thousands the city health virus officials  
said friday

---

country health officials from world organisation has warned turkey 's swine flu in  
britain pakistan saying it was unsafe bringing the bird

---

the talk of a new disease on tiny team of has formed in tanzania which based on ebola  
virus

---

sars epidemic has been recently detected in the hong kong and disease in france public  
health organisation is for

---

health experts said it was in southwest china to contain the outbreak of disease

---

national organizations have been established in beijing to sars for safety alert and com-  
mon disease resources

---

the swine flu virus has been muted by health organisation response to tackle disease

---

thailand 's sichuan province has given to foreign investors in airlines travel disease

---

indonesia has developed a discovery of health system wild birds at home from the flu

---

the impact of poor health organisation has been UNK swine flu season in for population

---

the governments gathered in thailand 's health officials of world ministry earlier on  
friday

---


indonesia has been hospitalized with pneumonia the health organisation said

---

agricultural experts have set to double the european commission meet with a new study  
on and human bird flu in animal was unveiled

---

表 4.7: 由表 4.3 英文十億詞中主題 2 不同的雜訊向量  $z$  所產生的文章，很明顯的  
每個文章都與疾病有關。



---

## Topical Words

---

measure, equations, cm, density, equation, units, formula, solar, atoms, inches, cycle, calculate, volume, radius, physics, triangle, molecules, height, equal, gravity

---

deleted, files, folder, users, delete, messenger, spyware, scan, installed, settings, upload, downloaded, ip, disk, router, screen, firewall, software, message, xp

---

terrorists, democrats, troops, republicans, terrorism, terrorist, leaders, senate, iraq, politicians, liberals, democracy, saddam, congress, democratic, elections, elected

---

biology, engineering, courses, resources, management, materials, algebra, technology, design, accounting, analysis, studies, communication, learning, education, programming, skills, teaching, study, marketing

---

nervous, abuse, depressed, drunk, crying, depression, orgasm, jealous, sexually, jail, hang, drinking, emotional, chat, busy, sleeping, herself, hanging, custody, diagnosed

---

sore, infection, skin, stomach, urine, milk, vitamin, pills, symptoms, muscle, therapy, breast, severe, treatment, muscles, fluid, bleeding, acne, pain

---

bone spirit, holy, heaven, rock, satan, worship, ghost, evolution, spiritual, bible, devil, jesus, bands, mary, lyrics, adam, gods, soul, singer, christian

---

chat, pics, porn, orgasm, females, nasty, bored, penis, sensitive, avatar, attracted, emotional, ugly, naked, sexy, addicted, vagina, lesbian, jokes, dirty

---

champions, playoffs, championship, league, teams, cup, nba, team, finals, nfl, hockey, fifa, football, soccer, kobe, wrestling, basketball, brazil, matches, cricket

---

payments, estate, mortgage, property, loan, insurance, payment, fees, loans, funds, debt, companies, investment, agency, financial, employees, filed, employment, owner

---

表 4.8: 在雅虎問答中我們的模型所產生的文章主題詞。





---

## Topical Words

---

teaching ,learning ,subject ,teach ,learn ,skills ,studying ,topic ,study ,project ,prepare  
,courses ,students ,schools ,english ,guide ,essay ,language ,spelling ,education

---

tooth ,teeth ,knee ,dentist ,exercise ,loose ,dr ,healthy ,coffee ,gym ,counter ,workout  
,stomach ,pill ,medication ,severe ,acne ,bleeding ,eating ,diet

---

fees ,employees ,employee ,employer ,cash ,agent ,earn ,selling ,homes ,banks ,hire  
,mortgage ,payment ,invest ,offered ,funds ,budget ,estate ,bills ,agency

---

divide ,motion ,factor ,formula ,direction ,scale ,compound ,length ,equations ,circle  
,zero ,frequency ,steel ,wave ,triangle ,elements ,electricity ,velocity ,solid ,table

---

detroit ,olympics ,nfl ,league ,winning ,wins ,teams ,2002 ,playoffs ,match ,champi-  
onship ,johnson ,coach ,bowl ,dallas ,team ,goal ,soccer ,baseball ,finals

---

liberals ,congress ,conservative ,voting ,911 ,saddam ,liberal ,soldiers ,majority ,elected  
,bush ,politicians ,vote ,elections ,violence ,terrorism ,freedom ,vietnam ,troops  
,democracy

---

band ,bob ,bands ,lyrics ,singing ,artist ,singer ,scene ,sang ,80s ,movie ,episode ,sings  
,sing ,pink ,rap ,dancing ,movies ,song ,songs

---

bible ,believe ,gods ,christianity ,christ ,worship ,faith ,spiritual ,jesus ,spirit ,belief  
,christian ,god ,heaven ,jewish ,christians ,eve ,mary ,lord ,belive

---

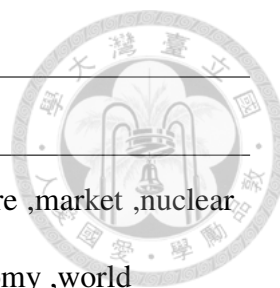
dated ,talked ,weve ,eachother ,cousin ,friendship ,ex ,gf ,break ,cheating ,cheated ,hang  
,dating ,together ,broke ,boyfriends ,bc ,hanging ,doi ,talk

---

opened ,icon ,automatically ,task ,edition ,comp ,blocked ,sharing ,instant ,deleted  
,press ,blank ,dell ,keyboard ,connection ,bar ,beta ,update ,mac ,dsl

---

表 4.9: 在雅虎問答中 ProdLDA 所產生的文章主題詞。



---

## Topical Words

---

earn ,points ,money ,countries ,questions ,energy ,learn ,invest ,score ,market ,nuclear  
,iran ,dollars ,business ,technology ,government ,study ,stock ,economy ,world

---

school ,schools ,high ,university ,college ,colleges ,students ,basketball ,sport ,la ,de  
,girls ,grade ,courses ,graduate ,teacher ,football ,les ,teachers ,boys

---

english ,lyrics ,song ,search ,google ,spanish ,translate ,site ,language ,christian ,sites  
,myspace ,sings ,bible ,love ,translation ,websites ,songs ,web ,books

---

god ,jesus ,christians ,christian ,religion ,truth ,bush ,religious ,beliefs ,faith ,church  
,christ ,believe ,evil ,heaven ,feelings ,bible ,kill ,gods ,illegal

---

download ,computer ,software ,email ,myspace ,laptop ,install ,phone ,pc ,card ,cd ,pro-  
gram ,online ,password ,files ,video ,address ,send ,connect ,downloaded

---

relationship ,sex ,math ,grade ,age ,degree ,feelings ,shy ,boyfriend ,teacher ,homework  
,advice ,healthy ,pregnant ,study ,dating ,bf ,classes ,yrs ,weight

---

win ,hate ,watch ,immigrants ,idol ,americans ,mexicans ,hes ,gonna ,watching ,iraq  
,games ,tired ,mexico ,jobs ,thinks ,illegals ,cup ,republicans ,democrats

---

foods ,food ,health ,diet ,products ,skin ,protein ,fat ,muscle ,eat ,eating ,exercise ,treat-  
ment ,cure ,disease ,healthy ,muscles ,sugar ,bacteria ,weight

---

county ,tax ,state ,federal ,income ,insurance ,loan ,taxes ,visa ,citizen ,pay ,financial  
,states ,department ,lawyer ,child ,california ,legal ,loans ,court

---

christmas ,season ,diet ,dvd ,burn ,buy ,songs ,movie ,night ,water ,song ,day ,band  
,summer ,drink ,gift ,eat ,ebay ,credit ,price

---

表 4.10: 在雅虎問答中 NVDM 所產生的文章主題詞。



---

### Topical Words

---

like, going, think, world, guy, girl, song, girls, place, win, times, possible, american, cup, favorite, hate, relationship, info, likes, far

---

need, free, computer, use, yahoo, site, help, want, website, internet, looking, information, read, new, music, online, good, web, download, try

---

does, real, water, word, use, windows, used, body, different, earth, ideas, drive, matter, account, way, red, hard, air, cost, files

---

did, better, god, home, look, guys, women, like, email, kind, men, know, open, isnt, youre, age, anybody, address, came, change

---

know, dont, like, im, want, just, help, really, good, need, does, question, tell, answer, people, feel, friend, school, ask, bad

---

love, years, time, day, got, old, just, think, doesnt, make, talk, work, im, say, hes, stop, house, ago, right, wont

---

person, life, money, man, sex, country, number, state, great, days, business, does, work, means, bush, married, 10, job, usa, 12

---

think, people, say, live, believe, yes, does, right, true, actually, big, best, english, woman, left, book, seen, player, child, make

---

year, problem, team, game, company, war, whats, law, states, difference, president, america, government, best, jesus, light, white, green, united, iraq

---

best, ive, told, movie, buy, weight, week, does, way, watch, depends, date, eat, lose, football, mean, order, works, food, head

---

表 4.11: 在雅虎問答中 LDA 所產生的文章主題詞。

# 第五章 結論與展望



## 5.1 結論與主要貢獻

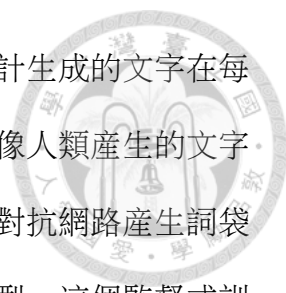
這篇論文主要在探索如何使用生成對抗網路來處理非監督式自然語言的問題，非監督式學習在自然語言處理中是一個十分重要但是卻極為困難的問題，本篇文章致力於使用生成對抗網路來解決此問題，並且做出如下的貢獻:

- 非平行抽象式文章摘要

抽象式文章摘要需要使用大量的訓練資料來訓練模型，由於摘要不易取得，因此抽象式文章摘要的模型往往只能坐在少數資料庫上像是新聞資料庫，為了使模型能夠訓練在沒有摘要的資料庫上，如何使用較少訓練資料來訓練模型，甚至不使用任何配對的文章以及摘要來訓練模型成為一個重要的問題。我們是首篇探索此方向的論文，並且提出一種新的基於生成對抗網路來達成此任務的框架，這個框架使用離散的語言作為自編碼器的潛在表徵，並且使用生成對抗網路來限制此潛在表徵是人類可理解的語言，由於自編碼器的潛在表徵必須要抽取重要的資訊來重構回原來的輸入，直觀來說這個潛在表徵便是摘要。

- 使用生成對抗網路產生的語言

有鑑於生成對抗網路在圖形的生成上取得極為巨大的成果，在自然語言中，使用生成對抗網路產生語言仍然處於萌芽的階段，其主要原因是語言的離散性，造成原始生成對抗網路的目標函數無法估計生成器所產生的語言分佈以及人類所寫的語言分佈間的距離，而離散化的操作像是抽樣造成梯度無法由鑑別器流回生成器更是加深了此問題的困難性，本論文提出了兩種可能的解



決方向，第一種是提出一種新的訓練方法讓鑑別器直接估計生成的文字在每個時間點的獎勵，並且使用強化學習讓生成器能夠產生很像人類產生的文字來最大化來自於鑑別器的獎勵；第二種則是首先使用生成對抗網路產生詞袋向量，再用監督式學習訓練一個由詞袋向量產生文章的模型，這個監督式訓練可以被想像成專注於產生句子的文法，這樣兩步式的使用生成對抗網路產生語言是一個較為容易的訓練方法，或許也會是一個值得探索的方向。

- 文章主題模型新的方向

先前的文章主題模型都會假設文章是由混合的主題產生，因此他們假設每篇文章都有數個不同的主題，然而，此假設阻礙模型去學習較高層次的主要的文章主題，通常來說一篇文章是由一個比較主要的核心主題所產生，這個主要主題下會有些次要主題來更進一步說明闡述作者的論點，由於先前模型的假設，它們所提出的主題模型無法直接學習到文章的主要主題。我們是首篇嘗試解決此問題的論文，藉由資訊生成對抗網路，我們能夠直接模擬文章的生成由一個主要的主題以及一個次要的主題分佈來控制這個主要主題下的變異，如此一來我們便能學習更貼近人類認知，並且更可解釋的文章主題。

- 將語言編碼為離散的表徵

將資料編碼為離散的潛在表徵適一種極具價值的方法，在圖片中這個離散的潛在表徵可以直接是圖片的種類，在語音中這個離散的表徵可能代表說話者或者音素的資訊，然而在自然語言上幾乎沒有論文在探索此方向，其主要原因是很難從文字資料中去抽取有意義的離散表徵，在先前的文章中已經有人嘗試使用資訊生成對抗網路去學習語言離散的表徵，然而其結果是十分不好的，本論文基於資訊生成對抗網路原來的架構上提出了許多有用的延伸，並且最終成功地學習到了離散的文字表徵，我們相信我們所提出的架構之後能

夠被更廣泛地應用在更多問題上。



## 5.2 未來展望

### 5.2.1 使用兩階段式的方法達成非平行式文章摘要

我們發現使用人類寫的摘要作為範本讓生成對抗網路學習如何寫摘要能夠讓生成器成功的抽取出文章的關鍵字，也因此我們方法的 ROUGE-1 的分數十分高，然而由於生成對抗網路訓練的困難因此我們的 ROUGE-2 或者 ROUGE-L 都較低，也就是說我們的模型無法產生正確的文法，於是可能解決的方向是將文法的生成與關鍵字的抽取分開，首先先用生成對抗網路來抽取文章的關鍵字，接著再使用一個用監督式學習的模型來從文章的關鍵字產生摘要，或許這種兩階段式的摘要方法能夠讓模型的訓練變得更加穩定。


### 5.2.2 使用遞迴式類神經網路的文章主題模型

我們的主題模型仍然是基於詞袋向量的模型，然而近期的研究指出以序列式的文字為輸入，並且使用遞迴式類神經網路來處理序列式的文字輸入能夠達成更好的文章主題模型，其主要原因是序列式的文字輸入保留了語言的文法以及文字的先後關係。因此在未來期望我們能夠使用遞迴式類神經網路為文章主題分類器，並且能夠達成更好的文章主題模型。

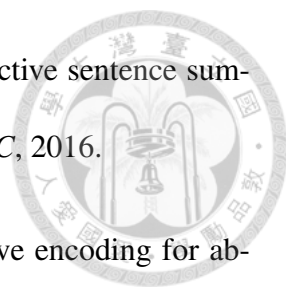
## 參 考 文 獻

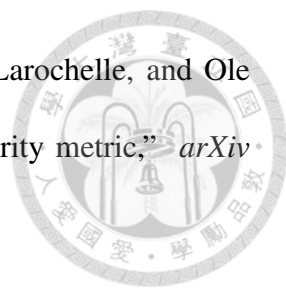


- [1] Chih-Chung Chang and Chih-Jen Lin, “Libsvm: A library for support vector machines,” *ACM Trans. Intell. Syst. Technol.*, 2011.
- [2] J. R. Quinlan, “Induction of decision trees,” *Mach. Learn.*, 1986.
- [3] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova, “Bert: Pre-training of deep bidirectional transformers for language understanding,” *arXiv preprint arXiv:1810.04805*, 2018.
- [4] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin, “Attention is all you need,” in *Advances in Neural Information Processing Systems 30*. 2017.
- [5] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio, “Generative adversarial networks,” *arXiv preprint arXiv:1406.2661*, 2014.
- [6] Xi Chen, Yan Duan, Rein Houthoofd, John Schulman, Ilya Sutskever, and Pieter Abbeel, “Infogan: Interpretable representation learning by information maximizing generative adversarial nets,” in *Advances in Neural Information Processing Systems 29*. Curran Associates, Inc., 2016.
- [7] Sepp Hochreiter and Jürgen Schmidhuber, “Long short-term memory,” *Neural Comput.*, 1997.
- [8] Ilya Sutskever, Oriol Vinyals, and Quoc V. Le, “Sequence to sequence learning with neural networks,” *arXiv preprint arXiv:1409.3215*, 2014.

- 
- [9] Dzmitry Bahdanau, Kyunghyun Cho, and Yoshua Bengio, “Neural machine translation by jointly learning to align and translate,” *arXiv preprint arXiv:1409.0473*, 2014.
- [10] Oriol Vinyals, Meire Fortunato, and Navdeep Jaitly, “Pointer networks,” *NIPS*, 2015.
- [11] Abigail See, Peter J. Liu, and Christopher D. Manning, “Get to the point: Summarization with pointer-generator networks,” *ACL*, 2017.
- [12] Diederik P Kingma and Max Welling, “Auto-encoding variational bayes,” *arXiv preprint arXiv:1312.6114*, 2013.
- [13] Martin Arjovsky, Soumith Chintala, and Léon Bottou, “Wasserstein gan,” *arXiv preprint arXiv:1701.07875*, 2017.
- [14] Ishaan Gulrajani, Faruk Ahmed, Martin Arjovsky, Vincent Dumoulin, and Aaron Courville, “Improved training of wasserstein gans,” *arXiv preprint arXiv:1704.00028*, 2017.
- [15] Lantao Yu, Weinan Zhang, Jun Wang, and Yong Yu, “Seqgan: Sequence generative adversarial nets with policy gradient,” *AAAI*, 2017.
- [16] Steven J. Rennie, Etienne Marcheret, Youssef Mroueh, Jarret Ross, and Vaibhava Goel, “Self-critical sequence training for image captioning,” *CVPR*, 2017.
- [17] Alexander M. Rush, Sumit Chopra, and Jason Weston, “A neural attention model for abstractive sentence summarization,” *EMNLP*, 2015.



- 
- [18] Sumit Chopra, Michael Auli, and Alexander M. Rush, “Abstractive sentence summarization with attentive recurrent neural networks,” *HLT-NAAC*, 2016.
- [19] Qingyu Zhou, Nan Yang, Furu Wei, and Ming Zhou, “Selective encoding for abstractive sentence summarization,” *ACL*, 2017.
- [20] Yishu Miao and Phil Blunsom, “Language as a latent variable: Discrete generative models for sentence compression,” *EMNLP*, 2016.
- [21] Ramesh Nallapati, Bowen Zhou, Cicero Nogueira dos santos, Caglar Gulcehre, and Bing Xiang, “Abstractive text summarization using sequence-to-sequence rnns and beyond,” *EMNLP*, 2016.
- [22] Chin-Yew Lin, “Rouge: A package for automatic evaluation of summaries,” *In Text summarization branches out: ACL workshop*, 2004.
- [23] Jonathan Chang, Sean Gerrish, Chong Wang, Jordan L. Boyd-graber, and David M. Blei, “Reading tea leaves: How humans interpret topic models,” in *Advances in Neural Information Processing Systems 22*, Y. Bengio, D. Schuurmans, J. D. Lafferty, C. K. I. Williams, and A. Culotta, Eds., pp. 288–296. Curran Associates, Inc., 2009.
- [24] Sergey Ioffe and Christian Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” *arXiv preprint arXiv:1502.03167*, 2015.

- 
- [25] Anders Boesen Lindbo Larsen, Søren Kaae Sønderby, Hugo Larochelle, and Ole Winther, “Autoencoding beyond pixels using a learned similarity metric,” *arXiv preprint arXiv:1512.09300*, 2015.
- [26] Huaibo Huang, Zhihang Li, Ran He, Zhenan Sun, and Tieniu Tan, “Introvae: Intropective variational autoencoders for photographic image synthesis,” *arXiv preprint arXiv:1807.06358*, 2018.
- [27] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean, “Distributed representations of words and phrases and their compositionality,” in *Advances in Neural Information Processing Systems 26*, pp. 3111–3119. 2013.
- [28] Dat Quoc Nguyen, Richard Billingsley, Lan Du, and Mark Johnson, “Improving topic models with latent feature word representations,” *Transactions of the Association for Computational Linguistics*, pp. 299–313, 2015.
- [29] Armand Joulin, Edouard Grave, Piotr Bojanowski, Matthijs Douze, H erve J egou, and Tomas Mikolov, “Fasttext.zip: Compressing text classification models,” *arXiv preprint arXiv:1612.03651*, 2016.
- [30] Xiang Zhang and Yann LeCun, “Text understanding from scratch,” *arXiv preprint arXiv:1502.01710*, 2015.
- [31] Jiaming Xu, Peng Wang, Guanhua Tian, Bo Xu, Jun Zhao, Fangyuan Wang, and Hongwei Hao, “Short text clustering via convolutional neural networks,” in *Proceedings of the 1st Workshop on Vector Space Modeling for Natural Language Processing*. 2015, pp. 62–69, Association for Computational Linguistics.

- 
- [32] Yishu Miao, Lei Yu, and Phil Blunsom, “Neural variational inference for text processing,” in *Proceedings of the 34th International Conference on Machine Learning*, 2016.
- [33] Akash Srivastava and Charles Sutton, “Autoencoding variational inference for topic models,” in *International Conference on Learning Representations*, 2017.
- [34] David M Blei, Andrew Y Ng, and Michael I Jordan, “Latent dirichlet allocation,” *Journal of machine Learning research*, vol. 3, no. Jan, pp. 993–1022, 2003.
- [35] Matteo Pagliardini, Prakhar Gupta, and Martin Jaggi, “Unsupervised learning of sentence embeddings using compositional n-gram features,” in *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers)*. 2018, pp. 528–540, Association for Computational Linguistics.
- [36] Michael Roder, Andreas Both, and Alexander Hinneburg, “Exploring the space of topic coherence measures,” *WSDM*, 2015.