

中華民國第 61 屆中小學科學展覽會 作品說明書

高級中等學校組 電腦與資訊學科

第二名

052502

可限制特徵之人臉生成器

學校名稱：臺北市立第一女子高級中學

作者： 高二 江宥嫻	指導老師： 陳怡芬
---------------	--------------

關鍵詞：生成對抗網路、人臉生成、限制特徵

摘要

本研究旨在發展一套可限制特徵之人臉生成器，能依據目擊者對嫌犯的特徵描述，使用真實人臉照片進行特徵生成，以生成嫌犯臉孔。本研究以生成對抗網路為中心，配合選擇性傳輸單元、編碼器與解碼器結構，發展出五官、毛髮、飾品、整體形象四大類別，共有 40 個特徵生成編輯種類。搭配友善的圖形使用者介面，讓使用者可將已相關度篩選後之真實人臉資料庫或是另行輸入之照片，因應不同的嫌犯臉孔描繪需求情境，對該圖片臉孔進行指定特徵之生成編輯。此技術除了可輔助刑案目擊者回憶嫌犯臉孔特徵，亦可應用於眼鏡業、醫學美容、美髮業等領域。

壹、 研究動機

偶然看到刑事相關案件之影集，劇中因嫌犯的影像證據不足，檢察官需請目擊者向專業畫師敘述嫌犯臉孔特徵，讓畫師依據其描述的特徵儘可能地繪出嫌犯臉孔。令人佩服的是，破案後比對畫像，常發現畫像與嫌犯實際臉孔相去不遠。雖然電影虛幻色彩居多，現今卻真實存在類似於此的畫師，如被號稱為世上最成功之法醫素描畫師 Lois Gibson (1950~)，在其為期三十多年的職業生涯中，共助警方解決一千多件刑事犯罪案。然而，人工繪圖方法雖然可行，但在目擊者與專業畫師來回的問答與試繪過程中，總是消耗不少時間，經常錯過追查嫌犯的黃金時期。因此，本研究擬研發一套可限制特徵之人臉生成器 (Generator)，利用真實人臉資料庫進行特徵生成，以輔助警方快速生成嫌犯臉孔。

貳、 研究目的

本研究旨在發展出一套可限制特徵之人臉生成器，透過與此系統使用者之間的問答，依據其特徵描述，利用真實人臉照片進行特徵生成編輯，輔助警方快速生成嫌犯臉孔。另外，考慮到嫌犯有偽裝的高可能性，因此需要增加可自行輸入圖片進行特徵生成編輯的功能，使用者可直接對嫌犯照片或相似臉孔進行特徵生成編輯，生成嫌犯作案時可能的臉孔特徵。

參、 研究工具：設備及器材

本研究的工具分為訓練平台以及軟體工具。訓練平台以高效能的硬體為主，以加速機器學習的速度，例如圖形處理器（GPU）、記憶體等；軟體工具指本研究使用的作業系統及軟體套件，包含驅動程式、機器學習套件、影像處理套件、圖形使用者介面套件等。

一、訓練平台

本研究需要大量的運算資源，因此選擇較佳的硬體與作業系統的資源排程都能增進模型訓練的效能。訓練平台規格的演進與效能的比較如表 1 及圖 1，表 1 以顏色深淺標記各訓練平台演進，同顏色代表使用相同規格，顏色愈深代表愈接近本研究最後平台選擇之規格。編號 1~5 為按照時間順序的平台演進，最後以編號 5 的規格做為本研究所需的訓練平台。

表 1 不同訓練平台規格與機器學習訓練效能比較

訓練平台	CPU	GPU	記憶體	作業系統	機器學習時間 (60 epochs)
編號 5	i5-9400F	NVIDIA RTX2060 super 8GB* (CUDA cores:2176)	16G DDR4	Ubuntu 20.04 Anaconda3 Python 3.6.10	需要訓練 20 小時
編號 4	i5-9400F	NVIDIA GTX1650 4GB (CUDA cores:896)	16G DDR4*	Ubuntu 20.04 Anaconda3 Python 3.6.10	需要訓練 84 小時
編號 3	i5-9400F*	NVIDIA GTX1650 4GB* (CUDA cores:896)	8G DDR4	Ubuntu 20.04* Anaconda3* Python 3.6.10*	需要訓練 180 小時
編號 2	i5-8250U	無	8G DDR4	Ubuntu 18.04*	需要訓練 720 小時
編號 1	i5-8250U	無	8G DDR4	Windows 10 Home	無法執行

*改變的部分




圖 1 不同訓練平台規格與機器學習訓練效能比較

二、軟體工具

為了建立機器學習與深度模型，本研究使用的開發環境與工具如圖 2，並以表 2 所示的

軟體做為本系統測試與開發環境，列舉如下。

- (一) 作業系統：Ubuntu 20.04
- (二) 驅動程式安裝：測試平台若要啟動 GPU 運算，需要先安裝 NVIDIA GTX1650 或 RTX2060 的驅動程式（顯示卡驅動程式為 NVIDIA 450.57 版本）。
- (三) GPU 工具軟體：NVIDIA CUDA toolkit 11.0
- (四) 機器學習套件：Tensorflow-gpu
- (五) 程式語言工具：Python 3.8 (Anaconda 3.8)
- (六) 圖形使用者介面套件：Tkinter
- (七) 影像處理套件：OpenCV, scikit-image, tqdm, oyaml 等。



圖 2 開發工具

表 2 測試環境

作業系統	程式語言	顯示卡驅動程式	GPU 工具軟體
Ubuntu 20.04	Anaconda 3 Python 3.6.10	NVIDIA 450.57	CUDA toolkit 11.0

肆、 研究方法與程序

本研究旨在研發一套可限制特徵之人臉生成器，以描繪嫌犯臉孔；而生成器的模型有許多種類與分支（圖 3），且各有優缺點。為了滿足描繪嫌犯臉孔的需求，研究者必須尋找適合當作可限制特徵之人臉生成器的模型，此模型考慮之條件為：1.可特徵擷取生成、2.生成效率高、以及 3.生成過程中圖片清晰。為了選擇合適的生成器作為模型，以下分別對各種生成器之優缺點進行說明。

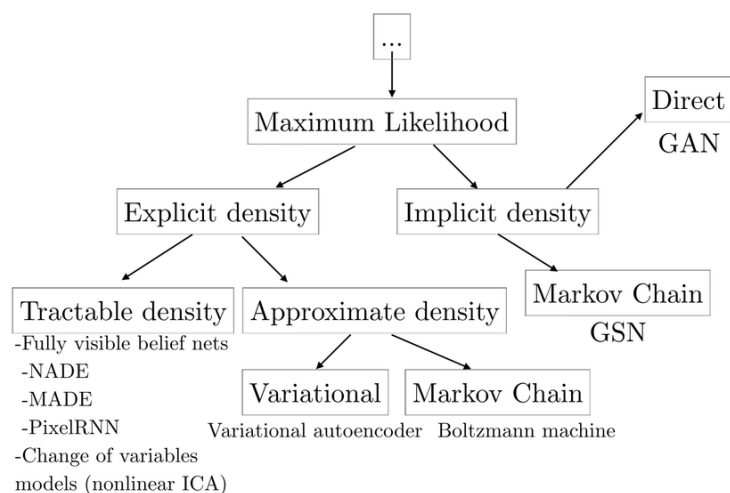


圖 3 生成器的種類

圖 3 資料來源：Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). *Generative adversarial networks*. arXiv preprint arXiv:1406.2661.

一、研究方法

(一) 生成器模型的選擇

本研究探討了如圖 3 所示之像素遞迴神經網路 (Pixel Recurrent Neural Network, PixelRNN)、變分自編碼器 (Variational Autoencoder, VAE)、波爾茲曼機 (Boltzmann machines)、生成隨機網路 (Generative Stochastic Networks, GSNs) 與生成對抗網路 (Generated Adversarial Network, GAN) 等生成模型及其優缺點，最後選擇 GAN 為本研究可限制特徵之人臉生成器的模型，說明如下。

1. PixelRNN

PixelRNN 主要是在遞迴神經網路中利用長短期記憶模型 (Long short-term memory, LSTM)，不斷地將某一個像素所學習的資訊往下傳遞，一次僅可產生一個像素，需要花費較多的時間；而 GAN 是一次產生一個樣本，因此在運行時間上，GAN 有最佳的運行效率。

2. VAE

VAE 在生成的設定是使生成時儘可能地模仿原圖片，造成生成圖片經常是自圖片資料集中的線性組合的結果，無法真正生成新的圖片；而 GAN 是透過鑑別器 (Discriminator) 不斷的學習並進行檢驗，因此如果鑑別器是理想情況，則生成器會完美的學習真實分布，所以 GAN 的對抗使鑑別器、生成器學習能力漸趨一致，而 VAE 會有偏差，因此 VAE 偏向表面的生成學習，而 GAN 屬於真正的生成學習。

3. Boltzmann machines 與 GSNs

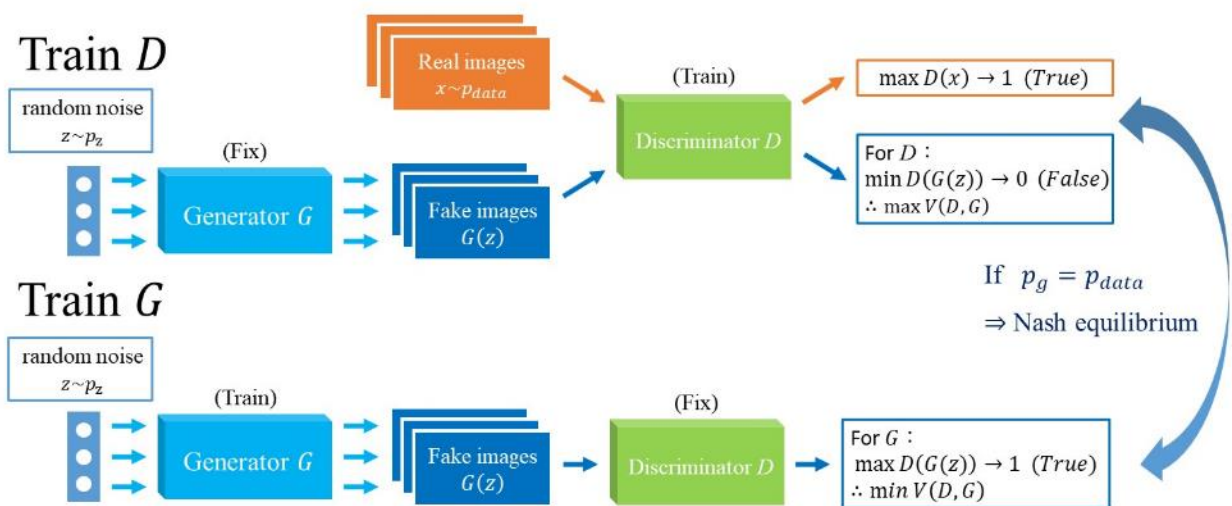
Boltzmann machines 與 GSNs 模型皆是不斷使用 Markov 鏈 (chain) 生成像素，與 GAN 一次性產生樣本相比，GAN 效率較高。

4. GAN

GAN (Goodfellow 等, 2014) 是由兩個模型互相對抗所構成，訓練模型時，生成器 (G) 以及鑑別器 (D) 同時訓練。 D 負責辨識圖片是真或假 (此定義訓練圖庫中的圖片為真， G 產生的圖片為假)；其中 G 的輸入為隨機雜訊 (random noise)， G 要在與 D 的對抗學習中將隨機雜訊生成相似圖片訓練庫的影像，目標是混淆 D 將生成的圖誤認為圖片訓練庫的影像。

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}} [\log D(x)] + \mathbb{E}_{z \sim p_z} [\log (1 - D(G(z)))]$$

以上式和圖 4 表示， V 代表 G 、 D 對抗過程， $G(z)$ 為 G 生成的圖片， p_{data} 表示真圖的分布， p_z 表示 z 的分布， p_g 為 $G(z)$ 的分布， $D(x)$ 、 $D(G(z))$ 分別代表 D 判斷 x 、 $G(z)$ 是否為真圖之分數。 x 是真圖，所以 $D(x)$ 應接近真值 1。 $G(z)$ 是假圖，所以對 D 而言， $D(G(z))$ 應愈接近假值 0，而此時 $V(G, D)$ 趨近於最大； G 要試圖使 $D(G(z))$ 愈接近真值 1，此時 $V(G, D)$ 會趨近於最小。 G 、 D 來來回回的對抗學習下，理論上達到納許均衡 (Nash equilibrium) 時即為最佳化 ($p_g = p_{data}$)。



4 生成器及鑑別器之間的對抗學習關係

綜合上述考量，本研究發現 GAN 在時間效率或模型穩定性方面優於其他生成器，甚至在較為複雜的圖片生成中，GAN 都具有較佳的成果。因此本研究最終以 GAN 當作可限制特徵之人臉生成器的模型。

然而 GAN 往往會有無法收斂、穩定性不足、模式崩潰等問題，因此本研究後續研究即針對此進行改良；另外，因為本研究的可限制之人臉生成器需要針對特徵生成，且需有分類特徵與特徵篩選功能之生成，所以還需進一步選擇合適的 GAN 模型。

(二) GAN 改良模型的選擇

如前面所述，GAN 往往會有訓練困難的問題，其中 Wasserstein GAN (WGAN) (Arjovsky, Chintala, & Léon Bottou, 2017) 與 Wasserstein GAN gradient penalty (WGAN-GP) (Gulrajani 等, 2017) 改變計算兩個機率分布間的距離，解決了 GAN 訓練困難、容易崩潰的問題。另外針對特徵生成的部分，Attribute GAN (AttGAN) (He 等, 2019) 雖成功進行影像特徵生成，結果卻不理想，於是 Liu 等 (2019) 改良其模型為 Selective Transfer GAN (STGAN)。最後根據各種模型測試之成果，本研究選擇以 STGAN 為主要模型，過程如下所述。

1. WGAN 與 WGAN-GP

原始 GAN 所採用 KL 散度 (Kullback–Leibler divergence) 與 JS 散度 (Jensen-Shannon divergence) 分別計算鑑別器與生成器兩個機率分布間的距離，而 WGAN (Arjovsky, Chintala, & Léon Bottou, 2017) 發現此二種方法皆不適用於 GAN，仍有無法收斂、穩定性不足、模式崩潰等問題；WGAN 改採用 W 距離 (Wasserstein distance) 後便成功解決問題。

但是 WGAN 的生成成果品質不佳，於是之後的 WGAN-GP (Gulrajani 等, 2017) 在限制其為 Lipschitz 函數時，不使用 WGAN 原本使用的權重修剪，而是採取梯度約束 (Gradient Penalty, GP)，以減少梯度消失或梯度爆炸所造成效果不佳的問題。此時將 D 被限制在 Lipschitz 函數 ≤ 1 ，以下式表示：

$$\min_G \max_{\|D\|_L \leq 1} \mathbb{E}_{x \sim p_{data}} [D(x)] - \mathbb{E}_{z \sim p_z} [D(G(z))]$$

本研究進行特定特徵生成，需要類似標籤的生成，但是迄今 WGAN-GP 還未有此功能；而後，Auxiliary Classifier GAN (ACGAN) (Odena, Olah, & Shlens, J, 2017)、Information maximizing GAN (InfoGAN) (Chen 等, 2016) 利用輔助分類器 (auxiliary classifier) 及迴歸器 (repressor)，將生成的圖像轉製成生成條件的訊號，可以針對具有給定特徵或類似標籤的條件生成，但是效果仍有進步空間，於是 He 等 (2019) 受此啟發建立新模型 AttGAN，其改進處是生成的圖像不參與輔助分類器的訓練。

2. AttGAN

編碼器 (encoder) 是接收輸入/輸出特徵陣列的網路，而這些特徵陣列便是代表輸入的特徵，會進行資訊壓縮的過程。解碼器 (decoder) 通常與編碼器是相同的網路結構，但是方向相反，解碼器從編碼器獲取特徵陣列，還原輸出與實際輸入或預期輸出最近似的結果，類似於產生器，如圖 5。AttGAN 利用跳躍連接削弱特徵生成的彼此影響，以提升生成效果。




圖5 編碼器與解碼器結構

Liu 等 (2019) 認為 AttGAN 中的編碼器與解碼器結構之間若是通過添加多個跳過連接層 (skip connection)，會嚴重影響品質(圖 6)。因此，提出 AttGAN 的改良模型——STGAN。

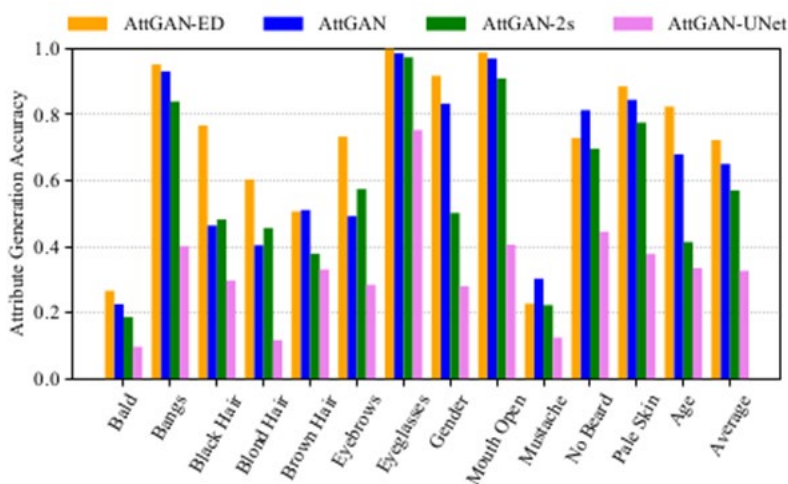


圖 6 不同跳過連接數量之結果

STGAN 使用選擇性傳輸單元 (Selective Transfer Units, STU) 選擇轉換編碼器之特徵，使編碼器與解碼器特徵兼容並且互補(圖 7)；而不是透過跳躍連接層削弱特徵生成的彼此影響。本研究經由對各模型的測試與 Liu 等 (2019) 實驗結果發現，STGAN 生成效果比原本 AttGAN 的效果更佳。

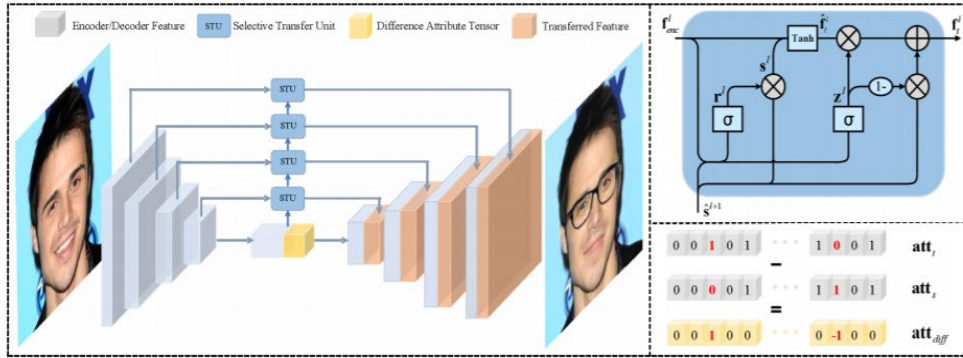


圖 7 STU 結構

AttGAN (He 等, 2019) 或是 StarGAN (Choi 等, 2018) 都是將目標生成陣列 (att_t) 和原圖輸入到生成器，但是從 Liu 等 (2019) 的結論得知，使用完整的特徵陣列是多餘的，有很大的機率會對編輯結果有負面影響，以性別轉換為例，除了臉部五官、頭髮長度的改變，發現也會影響髮色；此是因為 AttGAN 和 StarGAN 輸入完整的特徵陣列，便錯誤牽動不需要更改的特徵，此為使用者不希望發生的結果；於是，STGAN 將「差異特徵陣列 att_{diff} 」作為輸入 ($att_{diff} = att_t - att_s$) (att_s 是原圖標記的特徵陣列)，如圖 7 之右。因此， att_{diff} 比 att_t 更有意義，且可代表生成時模型可分辨是欲增加特徵還是消除特徵，使模型更容易訓練。

(三) 研究設計

本研究預先進行模型測試，結果發現使用 STGAN 模型結構效果最佳，與 Liu 等 (2019) 的研究結果相符，如圖 8 所示。因此本研究的可限制特徵之生成器所參考的模型為 STGAN。而 AttGAN (He 等, 2019)、STGAN (Liu 等, 2019) 研究成果只可生成 13 個特徵，無法滿足生成最相近嫌疑犯臉孔之需求，因此本研究再擴增更多特徵生成種類，分為五官、毛髮、飾品、整體形象改變四大類，共 40 個特徵。

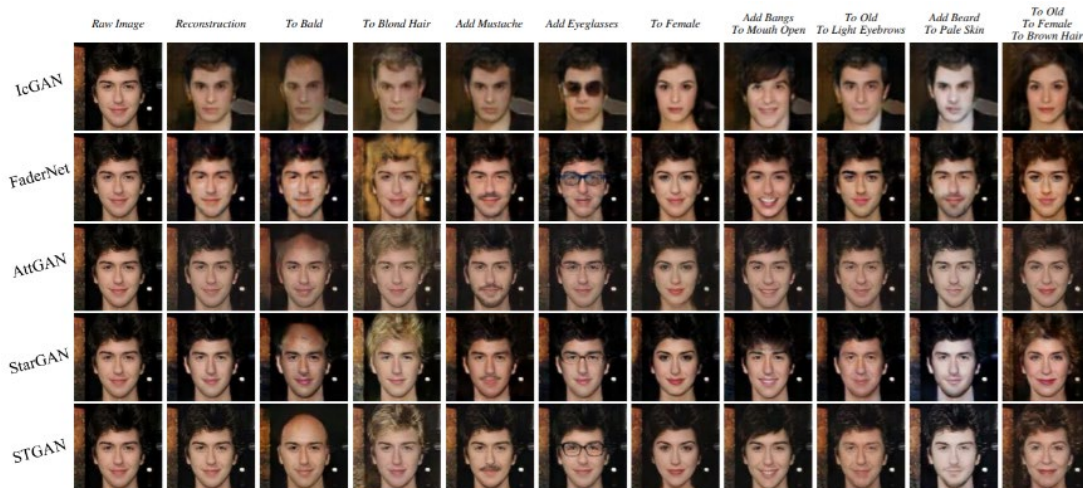


圖 8 不同模型的結果展示

圖 6、7、8 資料來源：Liu, M., Ding, Y., Xia, M., Liu, X., Ding, E., Zuo, W., & Wen, S. (2019). *STGAN: A unified selective transfer network for arbitrary image attribute editing*. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 3673-3682).

二、研究程序

(一) 研究資料集

本研究使用之影像資料集取自 CelebA。以其訓練集 (train set) 147,729 張與測試集 (test set) 54,870 張，共為 202,599 張，如圖 9 所示。



圖 9 影像資料集 (部分)

避免訓練及測試模型的資料庫差異太大，因此需要圖片規格標準化，目的是為了達成圖片的尺寸規格化以及固定五官位置。流程圖如圖 10。

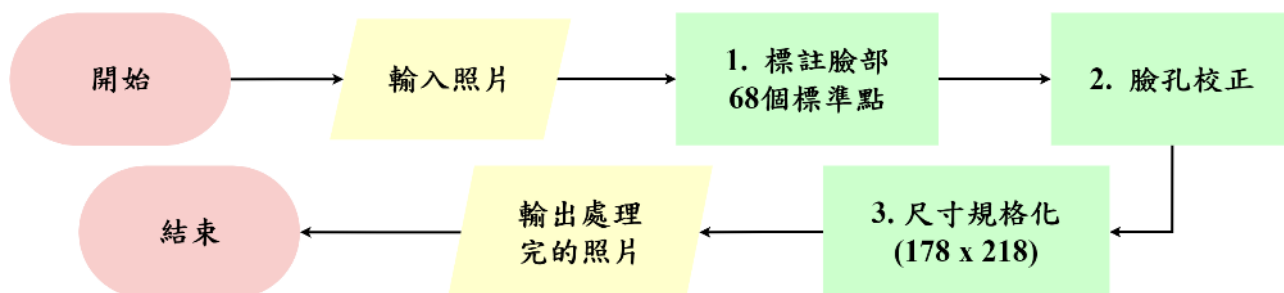


圖 10 圖片規格標準化流程圖

1. 標記臉上五官的 68 個標準點 (Facial landmarks)

為了控制特徵訓練的位置準確度，首先將照片進行標點動作，讓訓練及測試時可以在正確的特徵位置上，如圖 11、12 所示。此處使用環境：dlib, OpenCV, 及 Python3.6 版本。



圖 11 原圖。資料來源：Reuters。



圖 12 已標記、紀錄 68 標準點的圖

2. 臉孔校正 (Facial alignment)

臉孔校正是辨識數字圖像中的臉孔幾何結構後，再使用平移、縮放和旋轉矩陣，以固定五官位置 (圖 13、14)。調整後的圖必須要符合照片置中、眼睛平視與縮放比例的三項條件，以達到圖片標準化。本研究此處使用環境為：dlib, OpenCV, 及 Python3.6 版本。



圖 13 臉孔未校正前



圖 14 臉孔校正後

3. 裁剪圖片成相同尺寸並補平空區 (Crop)

為了使訓練能力提升以及讓訓練時間縮減，於是將每張圖裁剪成 178×218 畫素。另外因為可能在旋轉並裁切的過程有圖片空缺的問題，因此將其延伸進行補平，再進行裁剪(圖 15)。



圖 15 裁減補平

本研究旨在嫌犯臉孔生成，是依真實人臉圖片為底圖進行特徵生成編輯，於是需要多個

特徵生成種類，而資料前處理是要將對圖片的特徵標記輸出成特徵陣列。本研究使用的特徵共為 40 種，又可分為五官、毛髮、飾品、整體形象改變共四大類。

1. 人工挑選有該特徵的照片

以訓練「凶惡」的特徵為例。複製資料庫後，若擁有凶惡特徵的照片則留下，無則刪去（圖 16）。全部挑選後，再將留下的照片之特徵陣列中「凶惡」特徵標記為 1；反之，即沒有「凶惡」特徵，為-1。




圖 16 「凶惡」特徵影像挑選（部分）

2. 輸出成特徵陣列形式

此目的為將各圖片特徵標記輸出成特徵陣列形式（list_attr_celeba.txt），有該特徵為 1；反之，為-1。之後再將其輸入模型進行訓練，以限制特徵生成（圖 17）。CelebA 已使用深度學習標示特徵，但嫌犯臉孔描繪需要「凶惡」特徵，凶惡特徵難以用深度學習標記，本研究因此採用人工標記的方式。

```
000001.jpg -1 1 1 -1 -1 -1 -1 -1 -1 -1 -1 1 -1 -1 -1 -1 -1 -1 1 -1 1 -1 -1 -1 -1 -1 1 1 -1 1 -1 -1 -1 -1 -1 -1 1 1 -1 1 -1 -1 -1 1
000002.jpg -1 -1 -1 1 -1 -1 -1 1 -1 -1 -1 1 -1 -1 -1 -1 -1 -1 1 -1 1 -1 -1 -1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
000003.jpg -1 -1 -1 -1 -1 -1 1 -1 -1 -1 1 -1 -1 -1 -1 -1 -1 1 -1 -1 1 1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
000004.jpg -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
000005.jpg -1 1 1 -1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
000006.jpg -1 1 1 1 -1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 1 -1 -1 1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1 -1
```

圖 17 特徵陣列形式（list_attr_celeba.txt）（部分）

本研究模型是以生成對抗網路為中心，搭配選擇性傳輸單元與編碼器與解碼器特徵兼容、互補。訓練資料集為生成對抗網路的學習來源；特徵陣列是各圖片之特徵標記，使編碼器與解碼器可依據差異特徵進行限制特徵生成，而不使特徵彼此牽動。模型訓練過程是將已進行圖片前處理之訓練資料集、特徵陣列一同輸入於模型中進行訓練（流程圖如圖 18）。本研究在模型中擴增更多特徵生成種類，分為五官、毛髮、飾品、整體形象，共 40 個特徵。

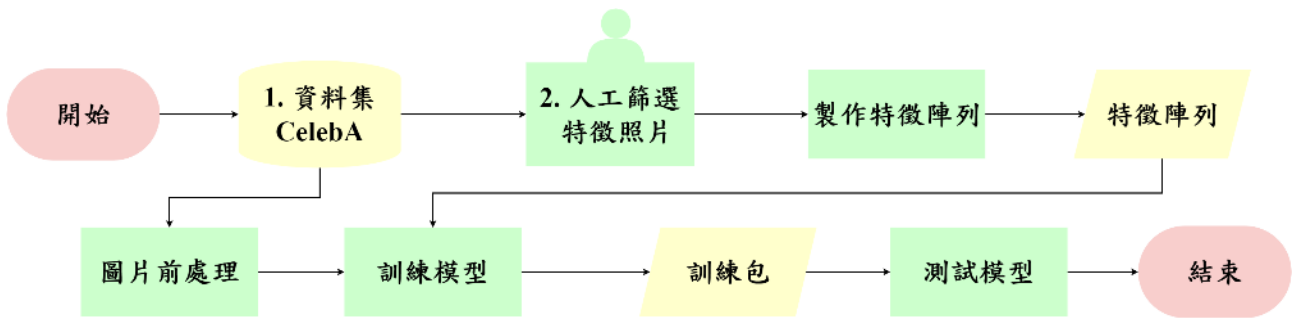


圖 18 模型訓練流程圖

(五) 模型測試

為了讓使用者使用便利，本研究將模型測試開發成圖形使用者介面 (Graphical User Interface, GUI)，用一連串標準流程，將可限制特徵之人臉生成器迅速呈現在使用者面前，流程如圖 19。

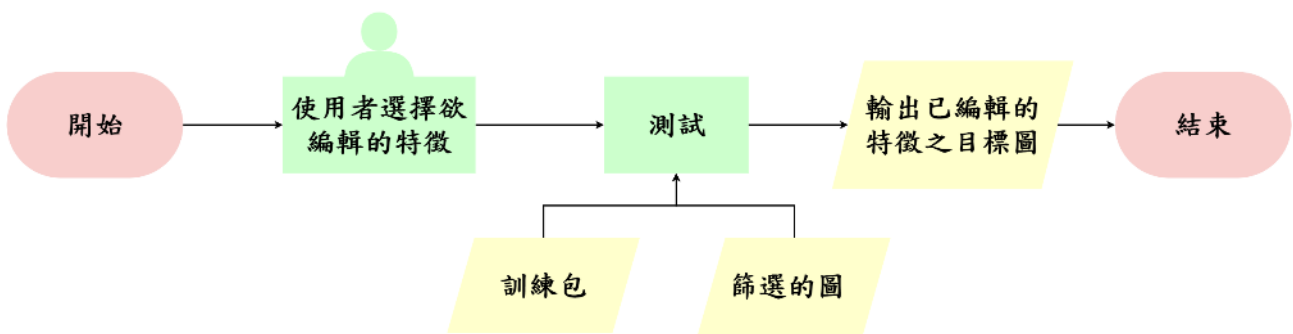


圖 19 模型測試流程圖

為了方便使用者運用，本研究使用 Tkinter 製作圖形使用者介面，用一連串標準流程，將可限制特徵之人臉生成器之測試流程包裝，讓使用者方便使用以產生最接近嫌疑犯的臉孔；而使用真實人臉資料庫，是為了讓目擊者可以藉由觀看真實照片以回想記憶，不是憑空想像。

圖 20 將結果進行顯示與比較，第一行與第三行是根據文獻指出警方請畫師手繪的嫌犯臉孔，而第二行與第四行為本研究產出的圖；由圖觀看可明顯得知，貼近真實的人臉照片比手繪更符合現實，且較有公信力。圖形使用者介面分成兩個分頁，即「指定特徵」與「自行輸入」；前者是自資料庫篩選照片後進行後續的特徵生成編輯，後者是自行輸入照片至可限制特徵之人臉生成器進行特徵生成編輯。

一 二 三 四



圖 20 圖形使用者介面封面圖

「指定特徵」是由使用者在介面上勾選特徵，系統會分別計算出影像資料集中每一張圖片的特徵與已勾選特徵之相關度，即算出兩者有相同特徵之數量，再依據相關度的數值由大到小重新排列影像資料集，並以每 24 張為一頁顯示於視窗上，相關度排列即如果使用者選擇五個特徵，介面會先顯示在影像資料集中同時符合五個特徵的圖片，再依序顯示符合四個特徵、三個特徵等，以此類推。使用者若擬特別針對某圖進行特徵生成編輯，可直接點選其圖進行編輯；若無，可將此視窗呈現的 24 張圖一併進行特徵生成編輯。最後圖形使用者介面會將編輯後的照片顯示於介面上。如此，使用者便有高度機會因為看到真實照片進行記憶回想，而非憑空想像；再藉由本程式，逐步繪出目擊的嫌犯臉孔。流程圖如圖 21 所示。

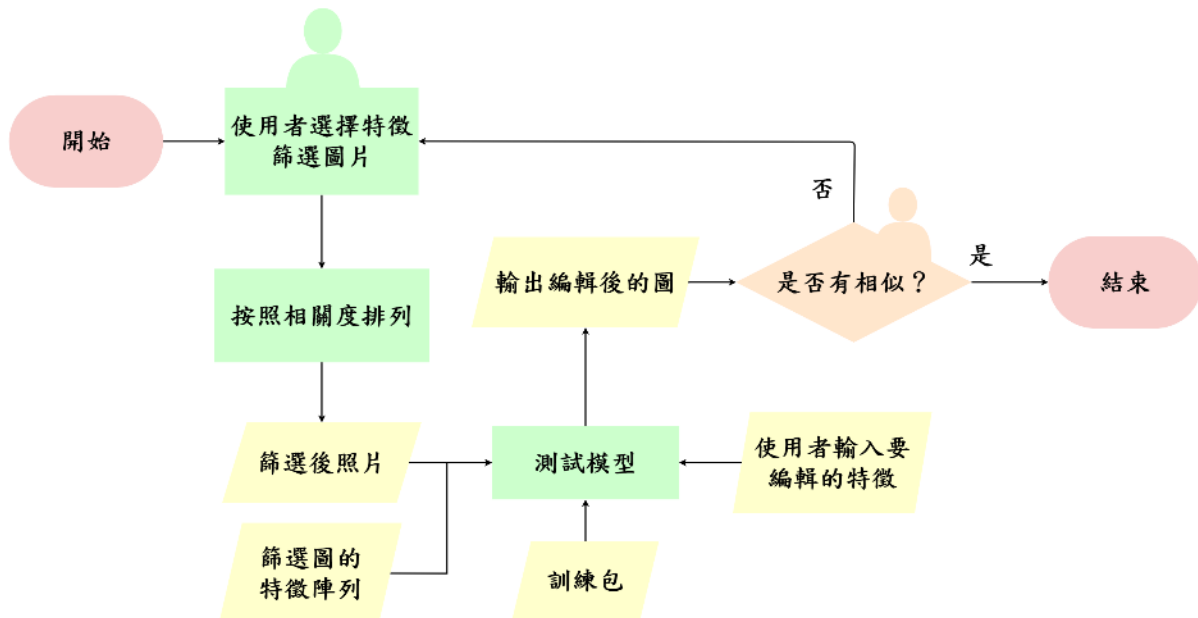


圖 21 指定特徵流程圖

「自行輸入」指可以自行輸入照片進行特徵生成編輯。在介面中，當使用者輸入電腦中照片至系統，系統會經過標準程序進行圖片規格化，之後使用者可藉由介面的多選框，勾選

欲生成的特徵後，系統會自動輸入至可限制特徵之人臉生成器進行特徵生成編輯，達到繪製嫌犯臉孔的效果。這個功能的設定建立在嫌犯有偽裝的情形，可輸入嫌犯照片至生成器生成嫌犯作案時可能之特徵，流程圖如圖 22。

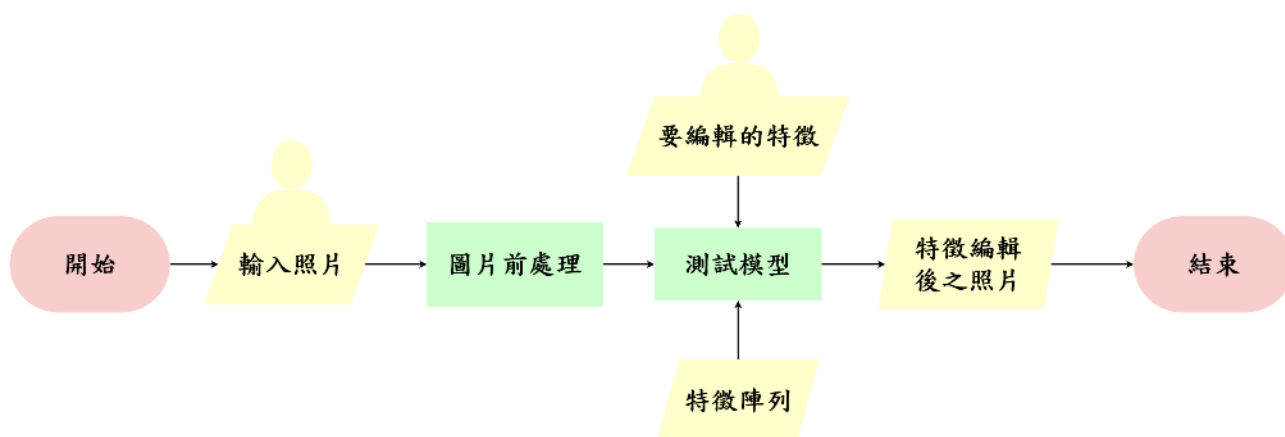


圖 22 自行輸入照片流程圖

1. 指定特徵

假設目擊者所目擊的嫌犯為圖 23，使用者欲利用圖形使用者介面的選單功能繪畫出其輪廓。使用者要先開啟頁面，勾選欲從資料庫篩選的圖片特徵，如圖 24。此設計是建立在使用者的記憶中對嫌疑犯的某些特徵十分肯定。勾選結束後，系統會分別計算出影像資料集中每一張圖片的特徵與已勾選特徵之相關度，即算出兩者有相同特徵之數量，再將依據相關度的數值由大到小重新排列影像資料集，介面排版方式為由左至右、由上而下，每 24 張為一頁顯示（如圖 25 所示，此處勾選欲篩選出男性與鬍子特徵的圖片）。若使用者不滿意，可以點選「下一頁（Next Page）」，圖形使用者介面將顯示經相關度排序之下一批 24 張照片（圖 26）。之後會再請使用者選擇特徵進行特徵生成編輯。



圖 23 假設目擊者所目擊之嫌犯

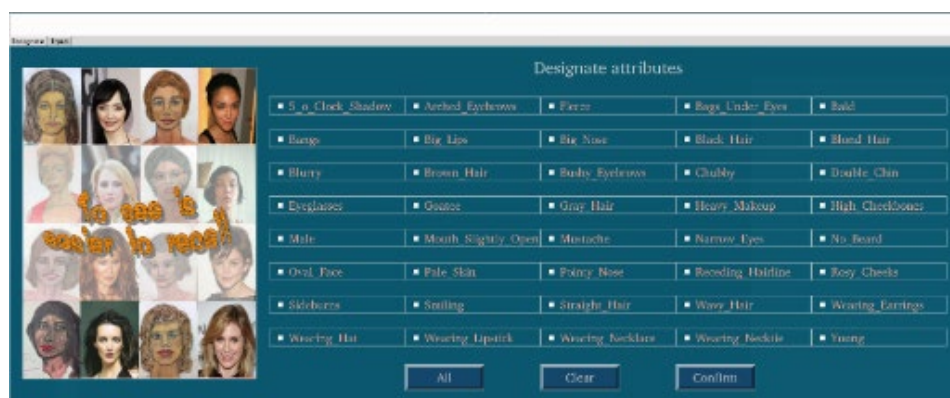


圖 24 挑選男性、鬍子的頁面

若是使用者對嫌犯的特徵印象模糊，無法勾選出特徵使系統顯示相關圖片，可以直接選擇「確認 (Confirm)」，而系統便會隨機挑選 24 張圖片顯示。圖中的「全選 (All)」、「清除 (Clear)」，是為了讓使用者在選多項特徵時方便使用。

若於頁面的24張圖沒有特定圖編輯的需求，可點擊「確認 (Confirm)」，即將對該頁的24張圖一併進行特徵生成編輯。點選之後會顯示可讓使用者點選之多選框 (圖27)，為可編輯的40個特徵生成種類，系統會依據使用者勾選之欲生成的特徵，使可限制特徵之人臉生成器對其24張生成已選特徵。再點選「確認 (Confirm)」後，使用者選擇之欲生成的特徵會轉成陣列，並顯示在上方對話框。此時可限制之人臉生成器已於系統中進行特徵生成，需要一點時間，介面會顯示進度條 (progress bar) 告知使用者生成進度，如圖28。




圖 25 相關度排名 1~24 名



圖 26 相關度排名 25~48 名

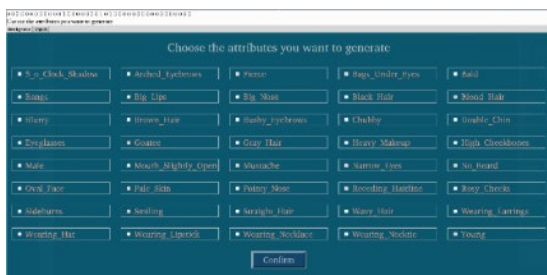


圖 27 可編輯的 40 個特徵選單

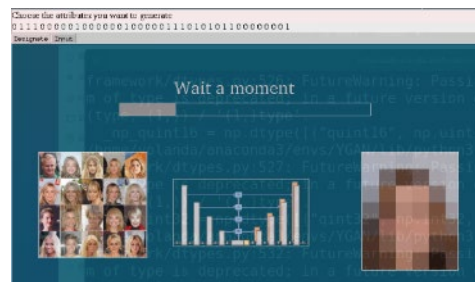


圖 28 使用者選擇的特徵陣列、進度條




圖 29 特徵生成完的成果

系統完成處理後，特徵生成後的圖會一併顯示於介面，圖 29 中每一對圖的左圖為原圖，右圖為編輯後的新圖，此圖為經由圖 24~28 流程之成果，其特徵選擇為生成凶惡、眼袋、金髮、細眼、髮際線後退、白膚、微笑、年輕、(消除)鬍子、(消除)山羊鬍、(消除)落腮鬍。

若是使用者於圖 25 或 26 之畫面欲對特定圖進行特徵生成編輯，在顯示已篩選的 24 張圖片時，直接點擊特定圖即可；而該圖檔名便會顯示在上方對話框，之後特徵生成編輯流程與圖 27、28 同。圖 30 所示為點擊圖 25 之第五行第一張的特徵生成成果，特徵生成選擇生成凶惡、眼袋、金髮、細眼、髮際線後退、白膚、微笑、年輕、(消除)鬍子、(消除)山羊鬍、(消除)落腮鬍特徵。由圖可知，繪畫結果與假設目擊者所目擊之嫌犯(圖 23)相似，因此本研究已達到繪畫嫌犯臉孔之功效；而且經過 130 筆大眾問卷調查中，68 筆訪問紀錄肯定此嫌犯生成臉孔與假設嫌犯相似，此也可表示本研究之嫌犯臉孔繪畫結果具有相當的可信度。



圖 23 假設目擊者所目擊之嫌犯

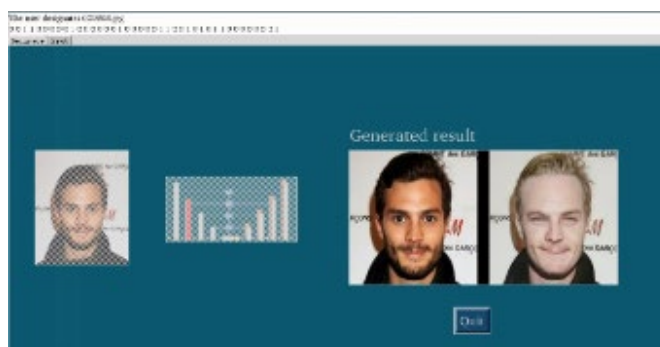


圖 30 對特定圖進行特徵生成之結果

2. 自行輸入

考慮嫌犯有偽裝的可能，可以輸入嫌犯的平時照片，再生成編輯其成偽裝後的照片，達到生成嫌疑犯容貌的效果。圖 31 為自行輸入之開啟畫面，當使用者點「輸入照片 (Input the image)」，系統會開啟尋找照片路徑的視窗，使用者可以從電腦中選取照片，介面便會獲取照片路徑(圖 32)。選完之後，系統會將輸入之照片顯示在介面上(圖 33)，當使用者確認照片無誤，按下「確認 (Confirm)」，系統便會對輸入照片進行臉孔規格標準化的動作(圖 34)。

當使用者點選圖 34「確認 (Confirm)」後，系統會進入特徵選擇的畫面(如圖 35 所示，圖中顯示為選擇眼鏡、腮紅、微笑的特徵)。使用者選擇之欲生成的特徵會轉成陣列，並顯示在上方對話框(圖 36)。

系統完成處理後，特徵生成後的圖會顯示於介面，生成的一對圖之左圖為原圖，右圖為編輯後的新圖。圖 37 所示為經由圖 31~36 流程之成果，是選擇眼鏡、腮紅、微笑的特徵。



圖 31 自行輸入開啟畫面

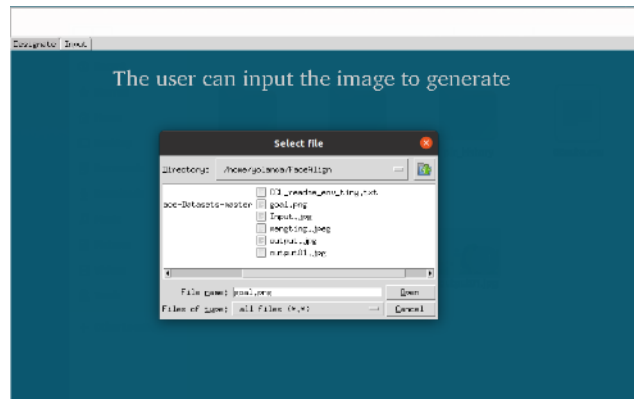


圖 32 選取照片

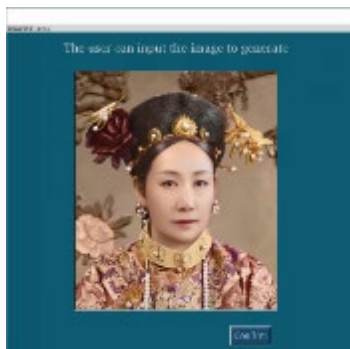


圖 33 顯示輸入原圖

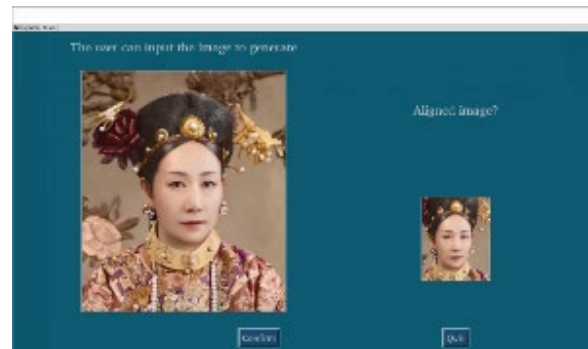


圖 34 顯示圖片規格化後之圖

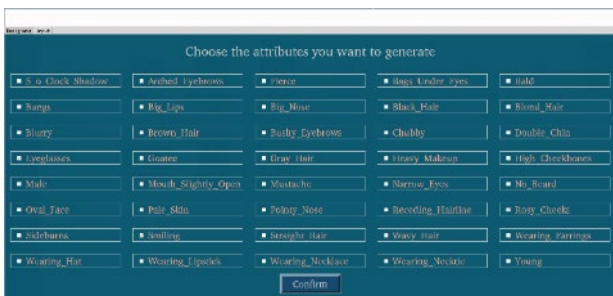


圖 35 特徵選擇畫面

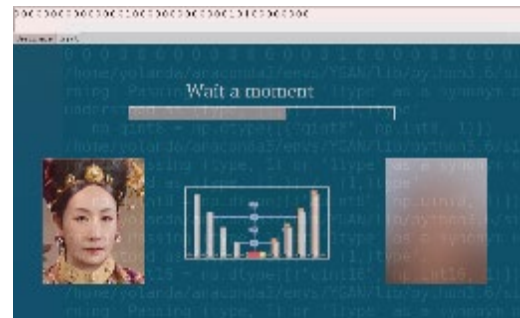


圖 36 生成等待畫面

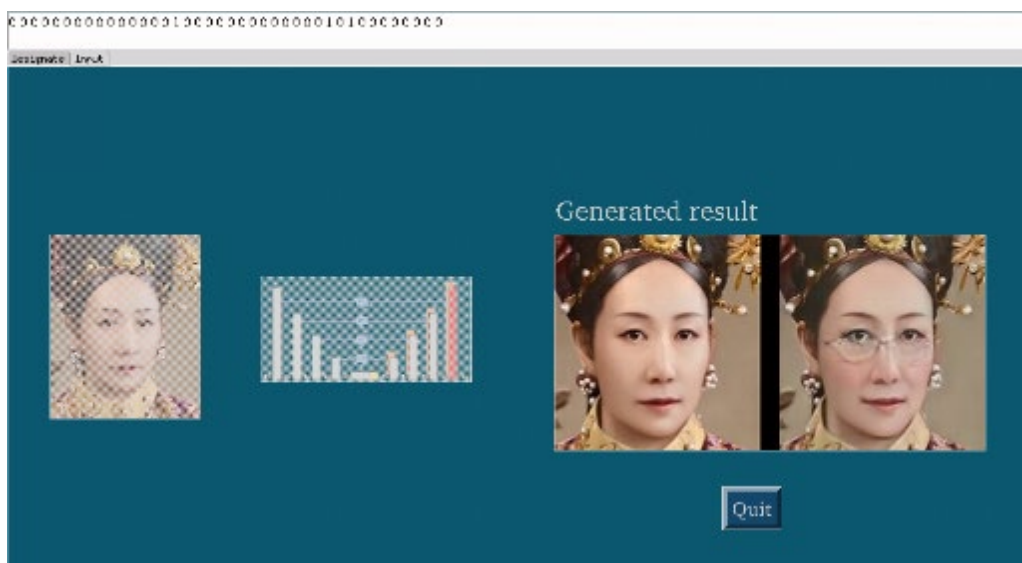


圖 37 輸入照片之特徵生成成果

伍、 研究結果

本研究總共有 40 個可編輯特徵，可多選特徵進行生成，也就是有 2^{40} 種編輯可能，是彈性非常高的編輯，可使檢警調描繪相近，甚至與嫌犯相同的臉孔。圖 38、40、42、44；圖 39、41、43、45 為經由本研究之人臉生成器所生成的嫌犯臉孔，其每張圖之右圖為以左圖當作底圖的嫌犯臉孔描繪成果。40 個特徵成果將於後續的討論說明。



圖 38
假設嫌犯 1



圖 39 左圖為原圖，右圖
為生成器生成的嫌犯 1 描繪



圖 40
假設嫌犯 2



圖 41 左圖為原圖，右圖為
生成器生成的嫌犯 2 描繪




圖 42
假設嫌犯 3



圖 43 左圖為原圖，右圖
為生成器生成的嫌犯 3 描繪



圖 44
假設嫌犯 4



圖 45 左圖為原圖，右圖為
生成器生成的嫌犯 4 描繪

陸、 討論

一、 參數設定

本研究大部分以訓練 epoch 參數為 140 的成果圖為主，實際上是根據各 epoch 參數的訓練結果發現：大部分特徵在 epoch 參數為 140 時有最好的結果，當 epoch 參數提高為 200 時，反而因為過度擬合而造成效果不佳；但是並非每種特徵皆如此，每種特徵都有屬於自己最佳的 epoch 參數，於是本研究之後希望能夠為每種特徵找出最佳的 epoch 參數值，並分別儲存訓練模型。

二、 特徵生成數量提升

由於研究時程很短，還未能有效地進行標記，若要更能達到嫌犯生成的正確率以及辨識度，需要更多的特徵生成種類，因此有效地標記是非常重要的環，未來可以針對例如傷疤、

刺青等更具代表性的特徵進行特徵標記與生成。

三、編輯特徵結果

本研究可限制特徵之人臉生成器的設定：若原本沒有該特徵，則添加其特徵；若原本有，則使該特徵消除。而本研究的標準為「成功改變該特徵，且沒有牽動到其他特徵」，根據此標準，研究者分別對 40 個可編輯特徵的結果進行討論，而此 40 個不同特徵共可分為五官、毛髮、飾品、整體形象改變四大類。另外，本研究也分別為 40 個特徵的增加與消除效果分成四等第，即：非常顯著、顯著、不顯著、非常不顯著。

(一) 五官特徵

1. 眉毛特徵——濃眉、拱眉

增加「濃眉」效果非常顯著（圖 46、47）；增加「拱眉」特徵在大部分的測試結果也皆非常顯著（圖 48）；但有少許例外，尚待進一步研究，例如圖 49 的眉毛僅有微幅改變，眼睛卻有明顯變動。濃眉與拱眉的消除效果非常不顯著。



圖 46 濃眉特徵生成成果（非常顯著）



圖 47 濃眉特徵生成成果（非常顯著）



圖 48 拱眉特徵生成成果（非常顯著）




圖 49 拱眉特徵生成成果（例外）

2. 眼睛特徵——細眼、眼鏡、眼袋

增加「細眼」特徵效果非常顯著（圖 50、51）；消除細眼特徵效果非常不顯著。增加「眼鏡」特徵效果非常顯著（圖 52、53），且每一張圖根據訓練庫學習所生成的眼鏡形式不同，可應用於眼鏡業；而消除的效果大部分顯著（圖 54），但若是眼鏡有明顯外框或是墨鏡，則消除效果不顯著（圖 55）。「眼袋」的增加特徵效果非常顯著（圖 56）；消除眼袋特徵（圖 57）效果顯著。



圖 50 細眼特徵生成成果（非常顯著）



圖 51 細眼特徵生成成果（非常顯著）



圖 52 眼鏡特徵生成成果（非常顯著）



圖 53 眼鏡特徵生成成果（非常顯著）




圖 54 消除眼鏡生成成果（顯著）



圖 55 消除眼鏡生成成果（不顯著）



圖 56 眼袋特徵生成成果（非常顯著）



圖 57 消除眼袋生成成果（顯著）

3. 鼻子——尖鼻、大鼻

「尖鼻」效果非常顯著（圖 58、59）；消除尖鼻的效果非常不顯著。生成「大鼻」特徵效果非常顯著（圖 60、61）；消除大鼻效果非常不顯著，但可用「尖鼻」的特徵生成效果代替。



圖 58 尖鼻特徵生成成果（非常顯著）



圖 59 尖鼻特徵生成成果（非常顯著）




圖 60 大鼻特徵生成成果（非常顯著）



圖 61 大鼻特徵生成成果（非常顯著）

4. 嘴巴—厚唇、嘴巴微張、微笑、塗口紅

「厚唇」增加特徵效果不顯著（圖 62、63）；消除特徵效果非常不顯著。「嘴巴微張」的增加特徵（圖 64）與消除（嘴巴闔上）效果皆非常顯著（圖 65）。「微笑」的增加特徵效果（圖 66）與消除特徵（不笑）的效果（圖 67）都非常顯著。「塗口紅」特徵效果非常不顯著；消除口紅效果非常顯著（圖 68），甚至像消除妝感，推測因為被標註塗口紅的照片，通常有化妝。



圖 62 厚唇特徵生成成果（不顯著）




圖 63 厚唇特徵生成成果（不顯著）



圖 64 嘴巴微張生成成果（非常顯著）



圖 65 嘴巴闔上生成成果（非常顯著）



圖 66 微笑特徵生成成果（非常顯著）




圖 67 消除微笑生成成果（非常顯著）



圖 68 塗口紅特徵生成成果（非常顯著）

（二）毛髮

1. 鬍子—鬍渣、鬍子、山羊鬍、落腮鬍、剃鬍

生成增加「鬍渣」的特徵效果顯著，卻有時會牽動其他特徵；由圖 69、70 發現，除了增加鬍渣外，亦可能改變了開口大小（圖 69）、唇色（圖 70）；圖 71、72 為鬍渣消除，效果不顯著，僅有淡化效果。「鬍子」特徵位於人中處，效果非常顯著（圖 73、74）；特徵消除效果

非常不顯著。「山羊鬍」效果非常顯著（圖 75）；消除效果不顯著（圖 76）。「落腮鬍」的效果非常顯著（圖 77），但消除落腮鬍特徵的效果不顯著（圖 78）。「剃鬍」效果非常顯著（圖 79）；消除效果為長鬍，效果顯著，相似於「鬍子」生成特徵，但鬍量較少（圖 80）。



圖 69 鬍渣特徵生成成果（顯著）



圖 70 鬍渣特徵生成成果（顯著）



圖 71 消除鬍渣生成成果（不顯著）



圖 72 消除鬍渣生成成果（不顯著）



圖 73 鬍子特徵生成成果（非常顯著）



圖 74 鬍子特徵生成成果（非常顯著）



圖 75 山羊鬍特徵生成成果（非常顯著）




圖 76 消除山羊鬍生成成果（不顯著）



圖 77 落腮鬍特徵生成成果（非常顯著）




圖 78 消除落腮鬍生成成果（不顯著）




圖 79 剃鬍特徵生成成果（非常顯著）




圖 80 長鬍生成成果（效果顯著）

2. 髮色—黑髮、金髮、棕髮、銀髮

髮色特徵生成效果皆非常顯著（圖 81~86），連禿頭特徵照片也有增髮效果（圖 82）。



圖 81 黑髮特徵生成成果（非常顯著）



圖 82 黑髮特徵生成成果（非常顯著）




圖 83 金髮特徵生成成果（非常顯著）




圖 84 棕髮特徵生成成果（非常顯著）



圖 85 銀髮特徵生成成果（非常顯著）




圖 86 銀髮特徵生成成果（非常顯著）

3. 髮型—瀏海、髮際線後退、禿頭、直髮、捲髮

「瀏海」的生成效果差異大（大部分效果非常顯著如圖 87、88），推論是根據其頭髮延伸，若原圖的髮際線較後面則效果不顯著（如圖 89）；消除瀏海特徵效果顯著（圖 90），但不完全。「髮際線後退」效果非常顯著（圖 91），而與「禿頭」成果（圖 92）比較，可以發現頭禿的範圍明顯不同；消除髮際線後退的生成效果非常不顯著，但是可以用「瀏海」或是髮色系列特徵生成的效果代替。「禿頭」的特徵在男性的生成效果非常顯著（圖 93），推論因為男性大多沒有瀏海遮蔽額頭輪廓，且禿頭的訓練集大多為男性，因此女性禿頭特徵生成效果較不顯著（圖 92）；消除禿頭生成出來後僅添加些許的毛髮（圖 94），效果顯著。「捲髮」的特徵效果不顯著，僅發現頭髮與陰影的對比度提高（圖 96）；消除捲髮（直髮）（圖 98）效果不顯著。「直髮」效果顯著（圖 97）；但消除直髮（捲髮）的效果非常不顯著。另外，理論上消除捲髮（直髮）（圖 98）效果應與「直髮」（圖 97）相同，但是比較後發現，「直髮」效果較顯著，從圖 97、98 的左方頭髮處觀察可知。



圖 87 瀏海特徵生成成果（效果非常顯著）



圖 88 瀏海特徵生成成果（非常顯著）



圖 89 瀏海特徵生成成果（不顯著）



圖 90 消除瀏海生成成果（顯著）



圖 91 髮際線後退生成成果（非常顯著）



圖 92 禿頭生成成果（女）（非常顯著）




圖 93 禿頭生成成果（男）（非常顯著）



圖 94 消除禿頭生成成果（顯著）



圖 95 禿頭生成成果（女）（非常顯著）



圖 96 捲髮特徵生成成果（不顯著）



圖 97 直髮特徵生成成果（顯著）



圖 98 消除捲髮生成成果（不顯著）

（三） 飾品——戴耳環、戴帽子、戴項鍊、領帶

「耳環」的特徵效果不顯著，僅在耳朵下方有白色小區塊（圖 99），應是耳環生成的痕跡；消除耳環的特徵效果不顯著，僅有類似於塗抹之痕跡（圖 100）。「帽子」的生成成果在

epoch 參數為 140 時效果顯著，僅有帽緣特徵（圖 101、102）；經 epoch 參數設定為 200 訓練後的效果非常顯著（圖 103）；消除帽子效果非常不顯著。「戴項鍊」、「領帶」特徵無論是消除或是添加的效果都非常不顯著，推論是因為經過圖片尺寸規格化後的項鍊特徵都被剪去。



圖 99 戴耳環特徵生成成果（不顯著）




圖 100 消除耳環生成成果（不顯著）



圖 101 帽子生成成果（顯著）



圖 102 140 epochs 成果



圖 103 200 epochs 成果

（四） 整體形象改變

1. 臉型—鵝蛋臉、雙下巴、高顴骨

「鵝蛋臉」生成不顯著（圖 104、105）；特徵消除效果非常不顯著。「雙下巴」特徵生成使嘴巴附近的臉部線條變得較為明顯（圖 106、107），效果不顯著；消除雙下巴特徵效果非常不顯著。「高顴骨」的特徵生成（圖 108）與特徵消除皆非常顯著（圖 109）。



圖 104 鵝蛋臉生成成果（不顯著）



圖 105 鵝蛋臉生成成果（不顯著）



圖 106 雙下巴特徵生成成果（不顯著）



圖 107 雙下巴特徵生成成果（不顯著）



圖 108 高顴骨特徵生成成果（非常顯著）



圖 109 消除高顴骨生成成果（非常顯著）

2. 整體氣質、形象——凶惡、男性、年輕、微胖、模糊、白膚、臉色紅潤、化妝

「凶惡」的特徵效果非常顯著，主要針對眉間、眼神的部份進行調整（圖 110、111）；凶惡特徵的消除效果非常不顯著。「男性」為性別轉換，生成指的是女性轉換成男性（圖 112），效果非常顯著；消除則是男性轉換女性（圖 113），效果顯著。「年輕」生成為年輕化（圖 114）以及變老（圖 115）之功能；結果發現，年輕化的效果較好，但都效果非常顯著。「微胖」特徵生成結果發現，主要是照片色調調亮，與原先認知的臉龐改變有差異（圖 116、117），效果不顯著；微胖特徵消除效果非常不顯著。「模糊」的特徵是建立在使用者是遠距離目擊嫌犯，因此對其臉龐的視覺印象屬於模糊，因此可能對使用者而言，模糊比清晰照更能讓使用者回想。模糊效果非常顯著（圖 118）；反模糊（清晰）生成效果不顯著（圖 119）。「白膚」的生成（圖 120）及消除（膚色調黑）（圖 121）效果皆非常顯著。「臉色紅潤」的效果非常顯著，卻有時會牽動唇色（圖 122），推論是因為通常被標記為臉色紅潤之照片是化妝時有塗抹腮紅，同時也會塗抹口紅；消除臉色紅潤效果也非常顯著（圖 123）。「化妝」生成效果變動的特徵是眼睛，有稍微放大的效果（圖 124），效果顯著；而卸妝的生成效果顯著（圖 125）。



圖 110 凶惡特徵生成成果（非常顯著）



圖 111 凶惡特徵生成成果（非常顯著）



圖 112 女變男特徵生成成果（非常顯著）



圖 113 男變女特徵生成成果（顯著）



圖 114 年輕特徵生成成果（非常顯著）




圖 115 變老特徵生成成果（非常顯著）



圖 116 臉部微胖生成成果（不顯著）




圖 117 臉部微胖特徵生成成果（不顯著）



圖 118 模糊特徵生成成果（非常顯著）




圖 119 清晰生成成果（不顯著）



圖 120 白膚生成成果（非常顯著）



圖 121 膚色調黑生成成果（非常顯著）



圖 122 臉色紅潤生成成果（非常顯著）



圖 123 消除臉色紅潤成果（非常顯著）



圖 124 化妝特徵生成成果（效果顯著）



圖 125 卸妝生成成果（顯著）

四、特徵生成、標準探討

GAN 是無監督學習，研究者其實難以對其進行學習的完全限制，而訓練後也無法知道 GAN 學習的細項，因此要改變特定特徵而不牽連其他特徵是困難的；雖然本研究之模型僅以編碼器與解碼器結構、選擇性傳輸單元限制生成，很幸運地，大部份都有不錯的成果，但是也有不佳的結果，因此在訓練的方法、資料前處理等限制生成方面，未來還需要多做些改良。

本研究可限制特徵之人臉生成器的設定：若原本沒有該特徵，則添加其特徵；若原本有，則使該特徵消除。表 3 是根據 40 個特徵生成編輯總類分成四類進行生成成果評價與整理，統計後發現，大部分消除特徵的效果不彰，未來亦可朝這方面的原因去探討與改良邁進；而根據四大類的生成成果可以發現，五官、毛髮、整體形象改變的特徵效果都算顯著，僅除了飾品的生成以外，而此結果推論與剪裁的範圍有關，因此日後可以加以改良。

表 3 40 個特徵種類效果總整理（單位：個）

特徵	效果							
	非常顯著		顯著		不顯著		非常不顯著	
五官 (11)	9	3*	0	2*	1	0*	1	6*
毛髮 (14)	11	0*	2	3*	1	4*	0	7*
飾品 (4)	0	0*	1	0*	1	1*	2	3*
整體形象 (11)	7	4*	1	2*	3	1*	0	5*
合計	27	7*	4	7*	6	6*	3	21*



*消除特徵的數量

五、 成果評估

本研究曾對生成成果進行多種評估試驗，例如平均雜湊演算法 (Average hash algorithm)、感知雜湊演算法 (Perceptual hash algorithm) 等圖片相似度演算法，然而實際驗證發現，由於其考慮背景之比重過大且無聚焦於臉部特徵進行評分，因此不試用於本研究；另外本研究也使用線上各種不同的人臉比對系統進行評分，但成效不佳，與曾經進行的問卷調查（問卷數 130 筆）之結果相差甚遠。

最後本研究對各生成成果的自動比對評分採取先將照片轉為灰階，使用 VGG16 模型萃取出二維特徵向量，再用餘弦相似度 (Cosine similarity, $\cos \theta = \frac{A \cdot B}{\|A\| \|B\|}$) 計算目標嫌犯照片與生成照片的相似度，最大值為 1，而平均成果評分為 0.55，與問卷調查之結果比較如表 4（為了比較，因此將問卷原本認為有相似的百分比換算成小數，使單位相同）。

表 4 生成成果評估

生成成果	自動比對評分	問卷調查分數
	.579	.562
	.570	.523

本研究實施的問卷調查中，共有 130 位受訪者，身分包含學生、工程師、律師等，有 81.5%

的受訪者認為本研究可以協助畫出嫌犯臉孔（79.2%完全肯定，2.3%認為有幫助），而 18.5% 的受訪者認為仍需改進或難以達到效果，如圖 126。




圖 126 問卷調查結果

柒、 結論

本研究成功地發展出可限制特徵之人臉生成器，可透過與使用者之間的問題，依據其特徵描述，利用真實人臉照片進行特徵生成編輯。本研究總共有 40 個可編輯特徵，而各特徵之效果皆有於前面陳述，可多選特徵進行生成，也就是有 2^{40} 種編輯可能，是彈性非常高的編輯，可使檢警調描繪出相似、甚至相同的嫌犯臉孔。在自動比對的成果評估中，最大值為 1 時，成果評估平均為 0.55；另外對於嫌犯臉孔生成結果評估初步進行問卷調查，有 82% 的受訪者正向認為本研究可以協助畫出嫌犯臉孔，讓大眾更容易認出嫌犯。

本研究發展出的可限制特徵之人臉生成器，也可應用於整型、美容、眼鏡業與娛樂用途。例如：整型前可以輸入客人的圖片，在系統中點選欲改變的特徵，進而生成改變後的照片；美髮業可於系統中，輸入客人的圖片，點選欲改變的髮色與特徵，事先合成改變後的模樣，再讓客人決定最符合自己的樣式；由於「眼鏡」的特徵每張照片所配的眼鏡樣式都不一樣，是依據訓練庫學習的成果，可以將此應用到眼鏡業，使得欲配戴眼鏡的使用者尋找出適合自己的款式。另外，近年來變臉的手機娛樂應用程式很流行，尤其是性別轉換以及年齡轉換，然而本研究特徵與功能更多，更能滿足娛樂用途，未來可以開發相關應用程式。

捌、 參考文獻資料

- Arjovsky, M., Chintala, S., & Bottou, L. (2017, July). *Wasserstein generative adversarial networks*. In *International conference on machine learning* (pp. 214-223). PMLR.
- Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). *Segnet: A deep convolutional encoder-decoder architecture for image segmentation*. *IEEE transactions on pattern analysis and machine intelligence*, 39(12), 2481-2495.
- Chen, X., Duan, Y., Houthoofd, R., Schulman, J., Sutskever, I., & Abbeel, P. (2016). *Infogan: Interpretable representation learning by information maximizing generative adversarial nets*. arXiv preprint arXiv:1606.03657.
- Chen, Y., Tao, J., Wang, J., Chen, X., Xie, J., Xiong, J., & Yang, K. (2019). *The novel sensor network structure for classification processing based on the machine learning method of the ACGAN*. *Sensors*, 19(14), 3145.
- Choi, Y., Choi, M., Kim, M., Ha, J. W., Kim, S., & Choo, J. (2018). *Stargan: Unified generative adversarial networks for multi-domain image-to-image translation*. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8789-8797).
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). *Generative adversarial networks*. arXiv preprint arXiv:1406.2661.
- Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. (2017). *Improved training of wasserstein gans*. arXiv preprint arXiv:1704.00028.
- He, Z., Zuo, W., Kan, M., Shan, S., & Chen, X. (2019). *Attgan: Facial attribute editing by only changing what you want*. *IEEE Transactions on Image Processing*, 28(11), 5464-5478. doi: 10.1109/TIP.2019.2916751.
- Liu, M., Ding, Y., Xia, M., Liu, X., Ding, E., Zuo, W., & Wen, S. (2019). *STGAN: A unified selective transfer network for arbitrary image attribute editing*. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 3673-3682).
- Liu, Z., Luo, P., Wang, X., & Tang, X. (2015). *Deep learning face attributes in the wild*. In *Proceedings of the IEEE international conference on computer vision* (pp. 3730-3738).
- Odena, A., Olah, C., & Shlens, J. (2017, July). *Conditional image synthesis with auxiliary classifier gans*. In *International conference on machine learning* (pp. 2642-2651). PMLR.
- Rosebrock, A. (2017, April 3). *Facial landmarks*. Retrieved from PyImageSearch Web site: <https://www.pyimagesearch.com/2017/04/03/facial-landmarks-dlib-opencv-python/>.
- Rosebrock, A. (2017, May 22). *Facial alignment*. Retrieved from PyImageSearch Web site: <https://www.pyimagesearch.com/2017/05/22/face-alignment-with-opencv-and-python/>.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., Manzagol, P. A., & Bottou, L. (2010). *Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion*. *Journal of machine learning research*, 11(12).

【評語】 052502

此作品以生成對抗網路為核心，發展一套可限制特徵之人臉生成器，可運用於嫌犯圖像產生，應用新穎，具實用價值，研究程序嚴謹。建議實驗部分，可以分析若無法找到與嫌犯相近的底圖時，所產生之影像與嫌犯的相似度，讓實驗結果更為完善。

作品簡報


可限制特徵之 人臉生成器

組別：高級中等學校組

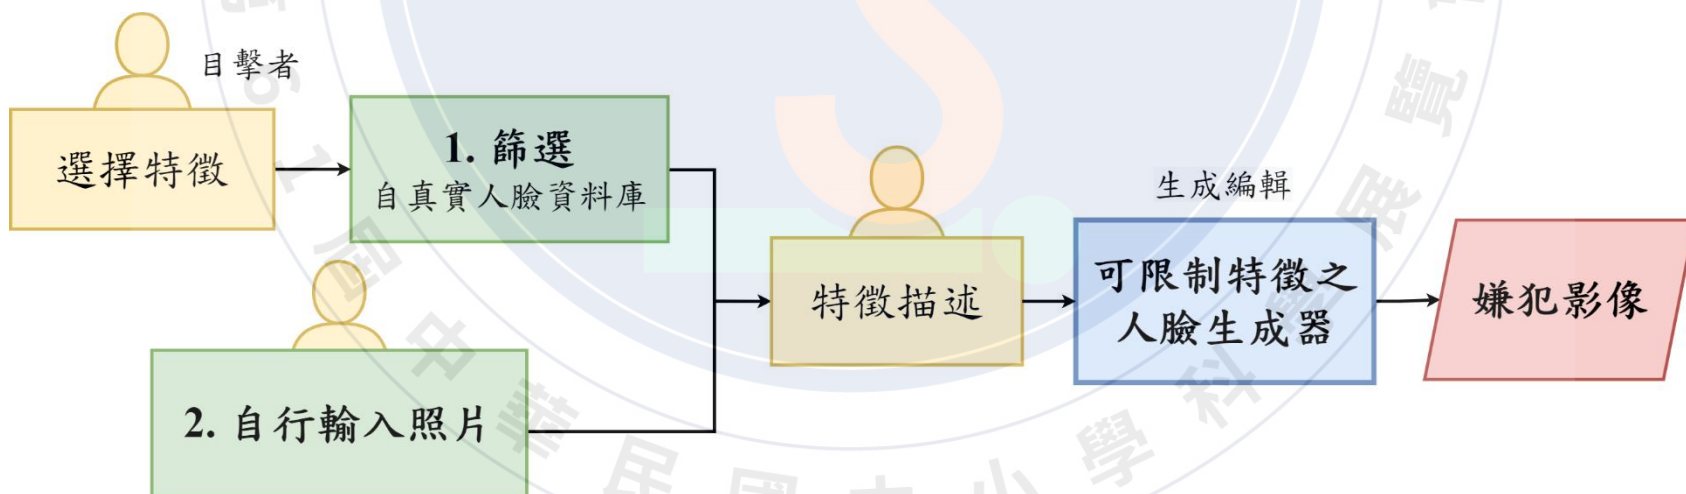
科別：電腦與資訊學科

壹、研究動機與目的

動機



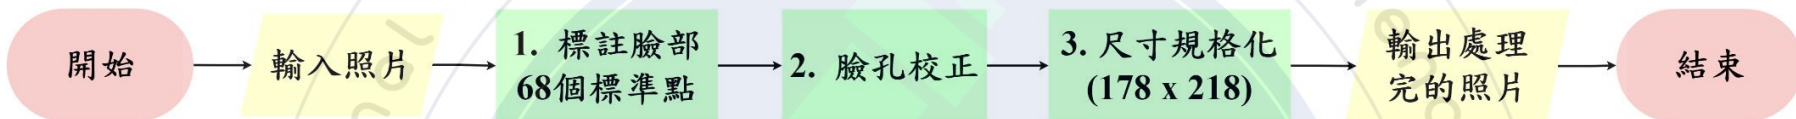
目的：生成嫌犯影像



貳、研究過程及方法

資料集前處理

圖片規格標準化



1. 標註68點

2. 臉孔校正

3. 尺寸規格化

完成

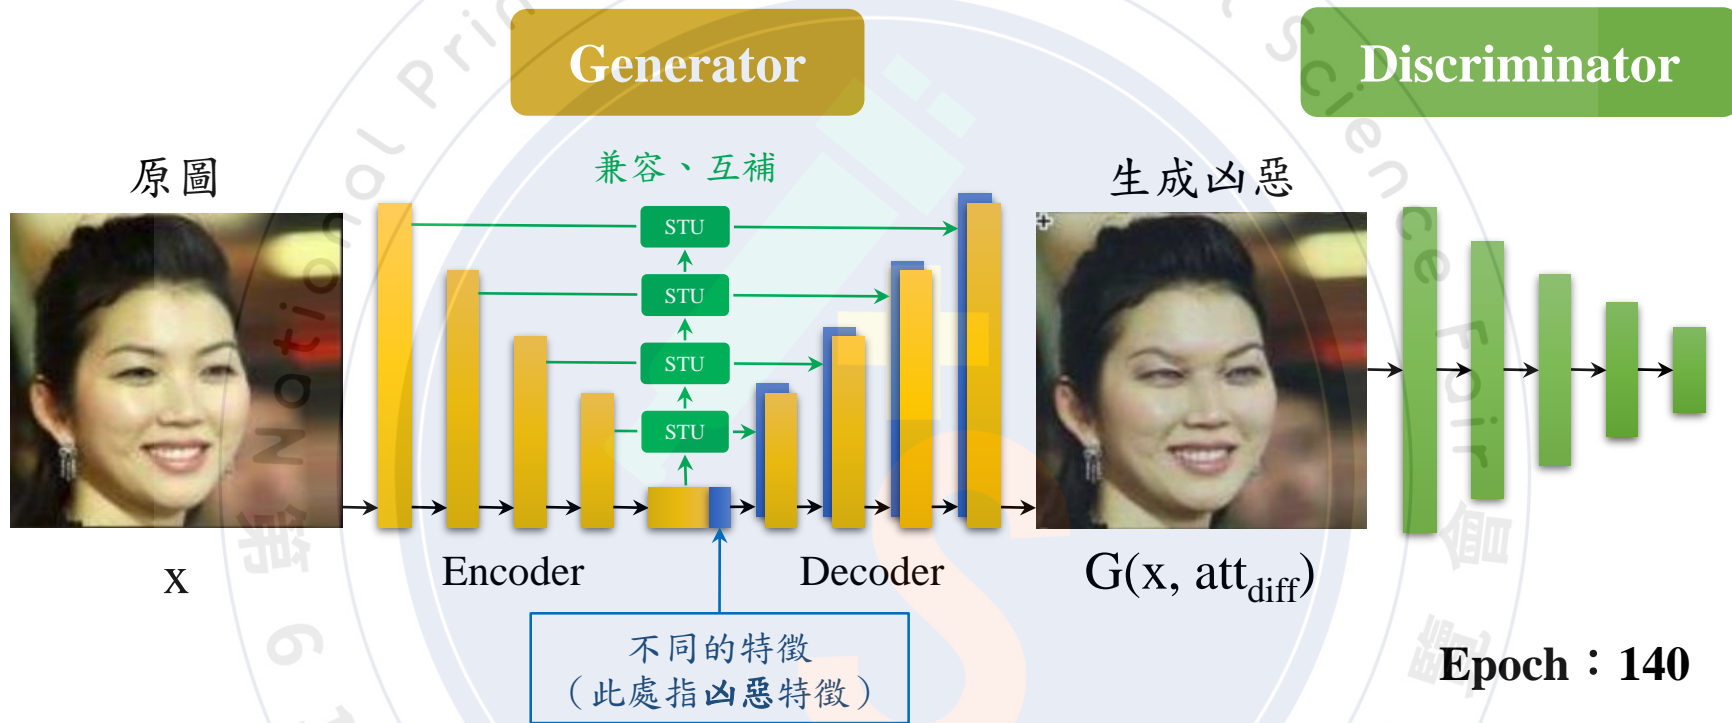
特徵生成 ⇒ 標記特徵

1. 人工挑選照片
2. 輸出 特徵陣列 (共40個特徵)

真實人臉資料庫

CelebA 共為202,599張
訓練集：147,729張
測試集：54,870張

貳、研究過程及方法 模型訓練、測試



以GAN為中心，搭配STU與編碼器與解碼器。(參考STGAN)
13個特徵 → 擴增至40個特徵。
可自行輸入照片生成編輯。

貳、研究過程及方法

模型改良

可於GUI中選擇，且可自行輸入照片。(共40個特徵)

生成器的設定：原本沒有其特徵→ 增加生成；有其特徵→ 消除生成。

11 五官

濃眉 拱眉
眼鏡 細眼
眼袋 大鼻
尖鼻 微笑
厚唇 塗口紅
嘴巴微張

14 毛髮

鬍渣 棕髮
鬍子 黑髮
山羊鬍 金髮
落腮鬍 銀髮
剃鬍 瀏海
直髮 禿頭
捲髮 髮際線後退

11 整體形象

凶惡 年輕
微胖 男性
鵝蛋臉 白膚
雙下巴 高顴骨
模糊 化妝
臉色紅潤

4 飾品

帽子
項鍊
耳環
領帶


參、研究結果

生成成果

繪畫目標



生成編輯結果



底圖

真實罪犯



生成編輯結果

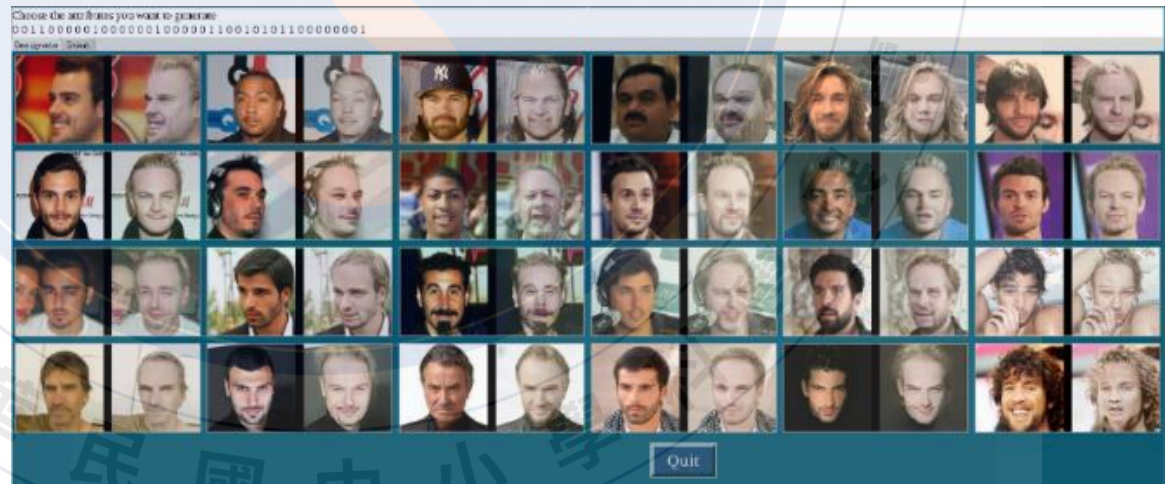


底圖

Tkinter 製作 GUI 程式

包裝嫌犯描繪流程

1. 指定特徵篩選
2. 自行輸入照片




參、研究結果

成果討論

特徵	效果							
	非常顯著		顯著		不顯著		非常不顯著	
五官 (11)	9	3*	0	2*	1	0*	1	6*
毛髮 (14)	11	0*	2	3*	1	4*	0	7*
飾品 (4)	0	0*	1	0*	1	1*	2	3*
整體形象 (11)	7	4*	1	2*	3	1*	0	5*
合計	27	7*	4	7*	6	6*	3	21*

*為消除特徵



消除微笑
(效果非常顯著)

凶惡
(效果非常顯著)

大鼻
(效果非常顯著)

直髮
(效果顯著)

認定標準參考：變動明顯程度、是否成功改變該特徵且沒有牽動到其他特徵。

參、研究結果



自動比對成果評分




平均成果評分為0.55（最大值為1）。

參、研究結果

問卷調查

生成成果	自動比對評分	問卷調查分數
	.579	.562
	.570	.523



問卷調查人數：130位

身分：學生、工程師、律師等

81.5% 肯定（79.2%完全肯定，2.3%認為有幫助）

肆、結論


1. 本研究以**GAN**為中心，配合**選擇性傳輸單元、編碼器與解碼器結構**成功發展出**可限制特徵之人臉生成器**。
2. 發展出**五官、毛髮、飾品、整體形象**四大類別，共有**40**個特徵生成編輯種類，也可自行輸入照片編輯。
3. 友善的**GUI**：因應不同的嫌犯臉孔描繪需求情境，對該圖片臉孔進行指定特徵之生成編輯
4. 成果評估：**自動比對評分的平均為0.55**（最大值為1）。
5. 問卷調查：**82%**的受訪者肯定本研究可生成嫌犯影像。

肆、結論




未來展望與延伸應用

除了嫌犯描繪，可延伸應用於眼鏡業、醫學美容業、娛樂業、美髮業等。


眼鏡業應用



美髮業應用



娛樂業應用



美容業應用



有高彈性的編輯，且模擬視覺化！

伍、參考文獻

生成器的選擇－GAN發想論文：

Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2014). *Generative adversarial networks*. arXiv preprint arXiv:1406.2661.

GAN的散度計算改良－WGAN（權重修剪）：

Arjovsky, M., Chintala, S., & Bottou, L. (2017, July). *Wasserstein generative adversarial networks*. In International conference on machine learning (pp. 214-223). PMLR.

WGAN改良（梯度約束）－WGAN-GP：

Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. (2017). Improved training of wasserstein gans. arXiv preprint arXiv:1704.00028.

臉部特徵編輯 AttGAN，本研究的GAN架構學習楷模：

He, Z., Zuo, W., Kan, M., Shan, S., & Chen, X. (2019). *Attgan: Facial attribute editing by only changing what you want*. IEEE Transactions on Image Processing, 28(11), 5464-5478. doi: 10.1109/TIP.2019.2916751.

STGAN改良AttGAN，使用STU結構，本研究所參考採用方法：

Liu, M., Ding, Y., Xia, M., Liu, X., Ding, E., Zuo, W., & Wen, S. (2019). *STGAN: A unified selective transfer network for arbitrary image attribute editing*. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 3673-3682).