

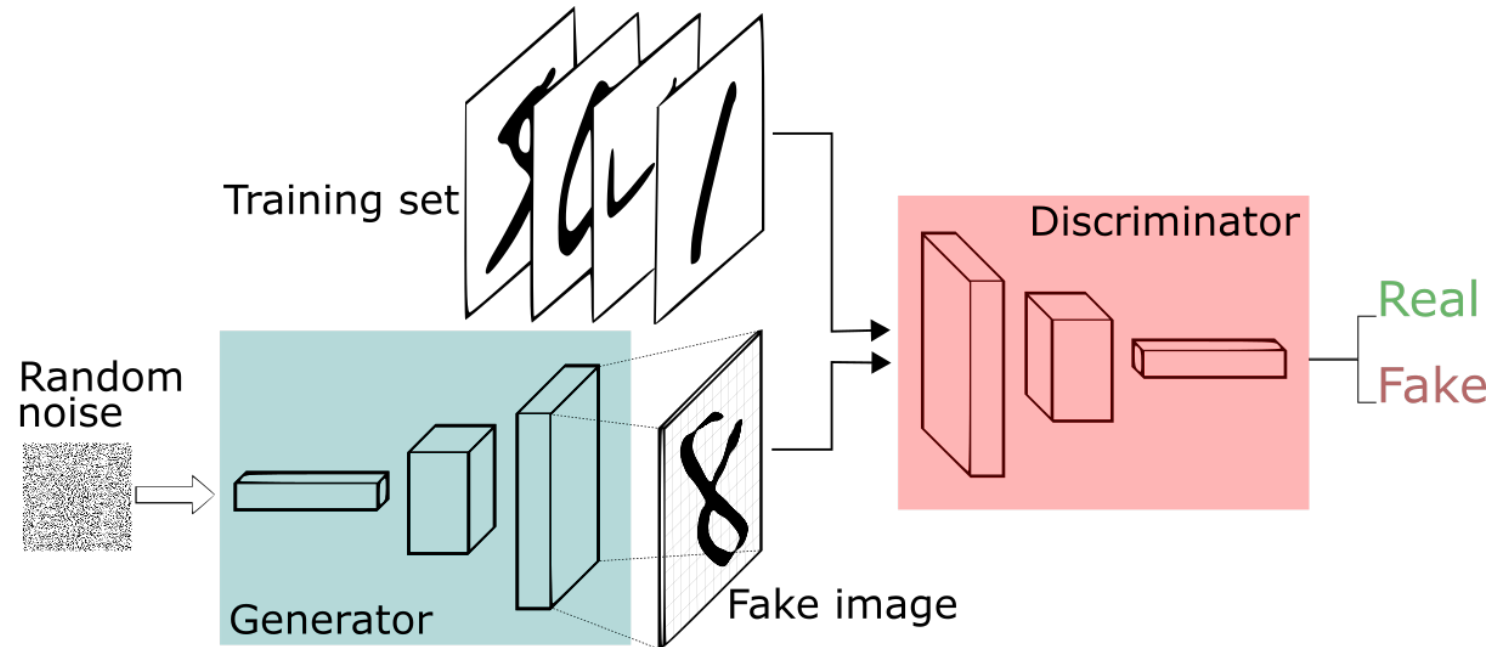
Introduction to Natural Language Processing

GAN - Generative Adversarial Network

RB308-3

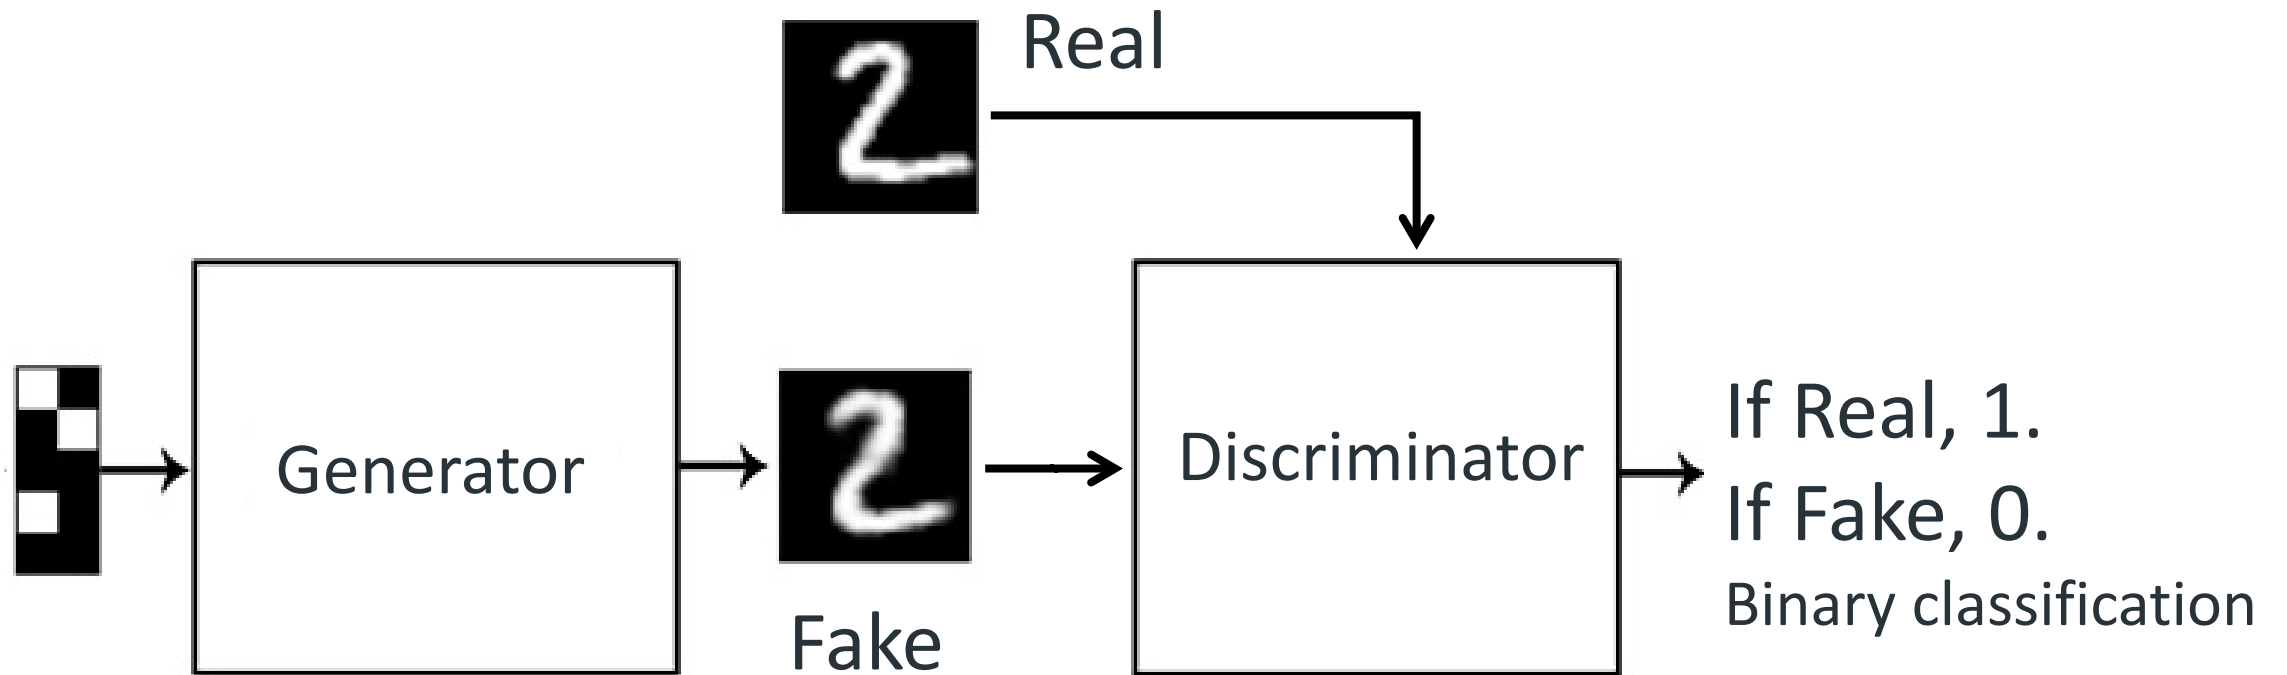
羅上堡

- 1 GAN – Generator & Discriminator
- 2 GAN – keras example



GAN - 生成對抗網路


- GAN由兩個網路所組成 → Generator 、 Discriminator ◦



GAN – Generator 生成器


- Generator 生成器

- 目標：讓Discriminator判別不出，產生出來的圖判定為Fake。



GAN – Generator 生成器

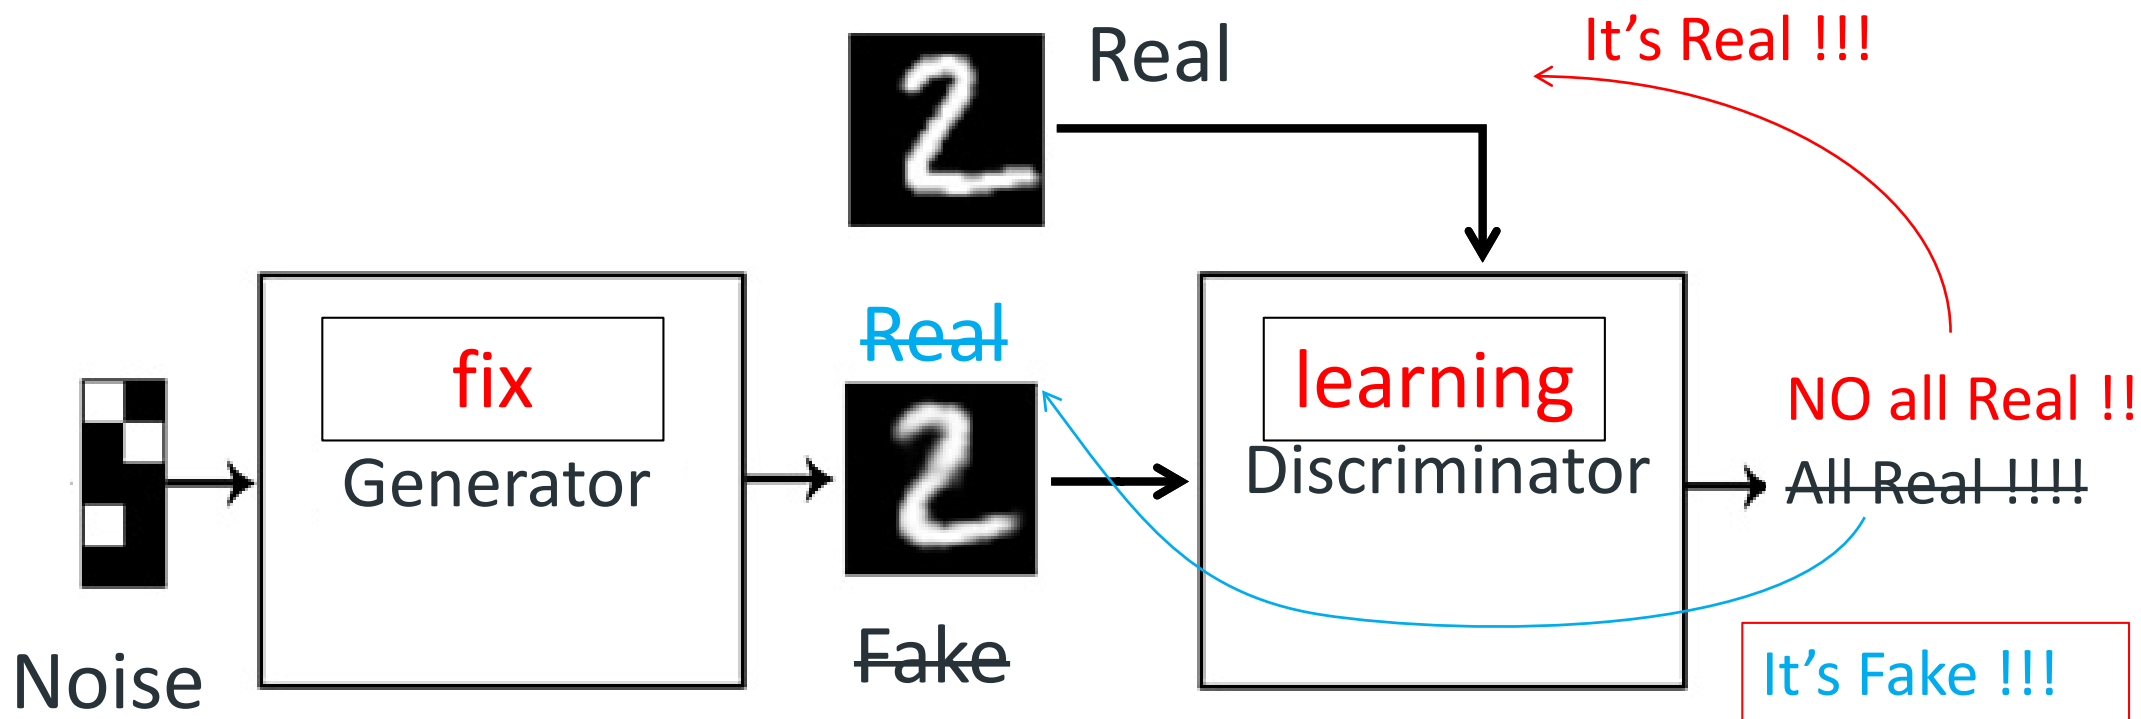
- 訓練 Generator 生成器
 - 與判別器一起訓練，但是不更新判別器，只更新生成器。
 - 輸入：低維度的高斯雜訊。(※通常)
 - 輸出：影像等等...。(※通常與真實data的維度一樣。)



GAN - Discriminator 判別器

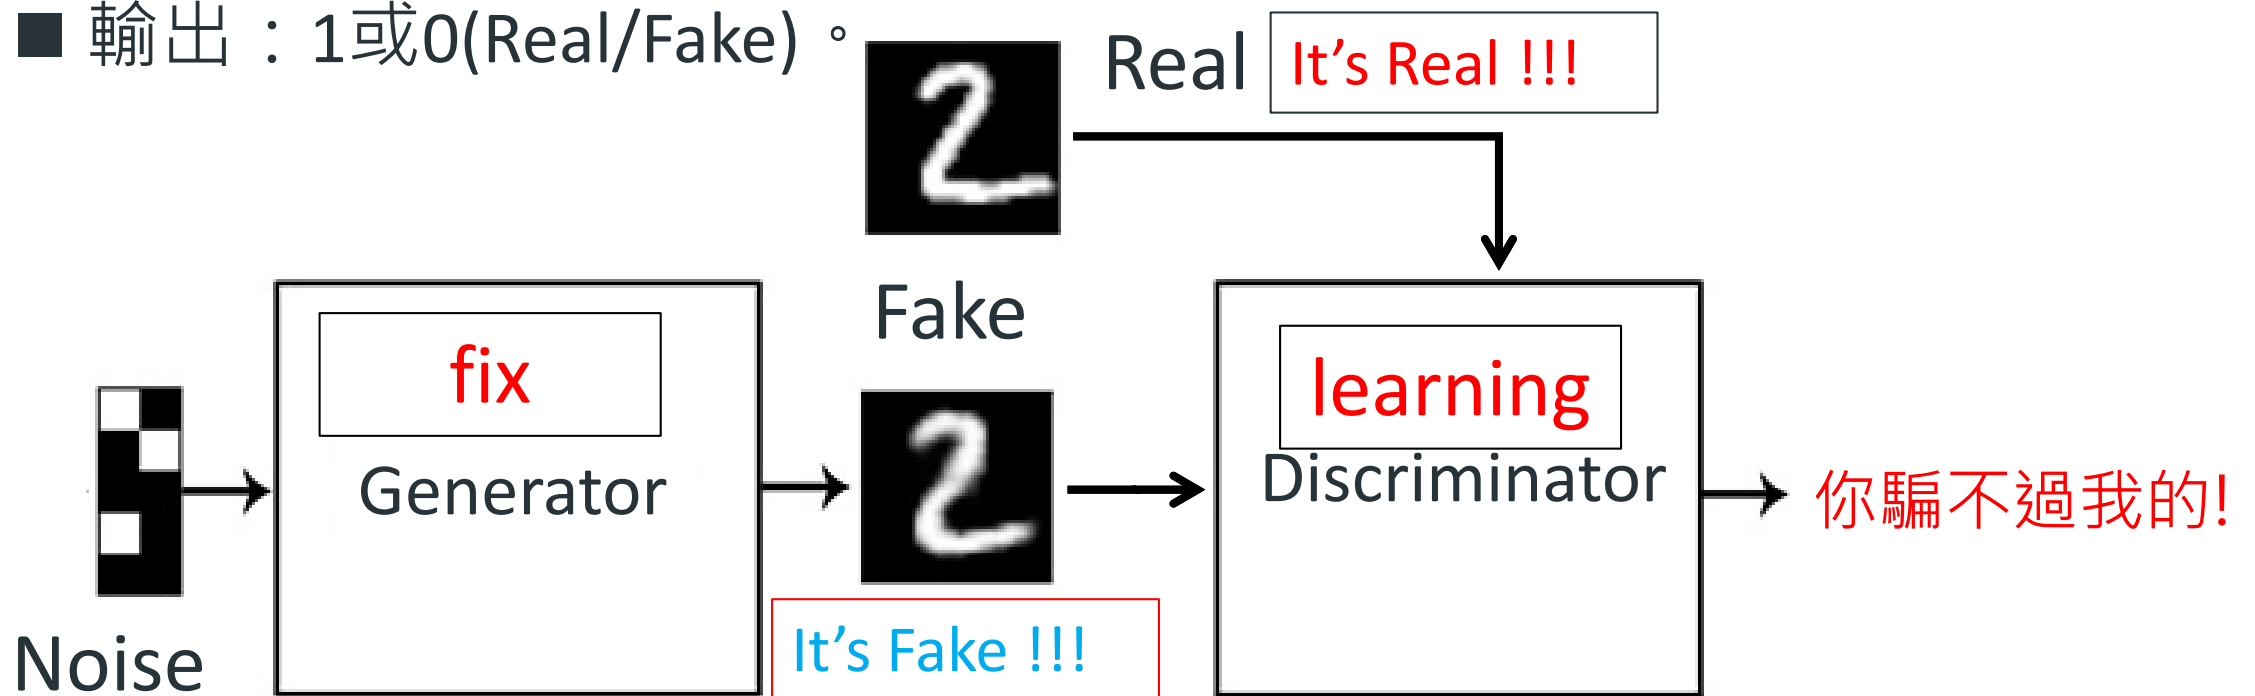
- Discriminator 判別器

- 目標：能夠正確判斷，生成的圖是假的，真實的圖是真的。



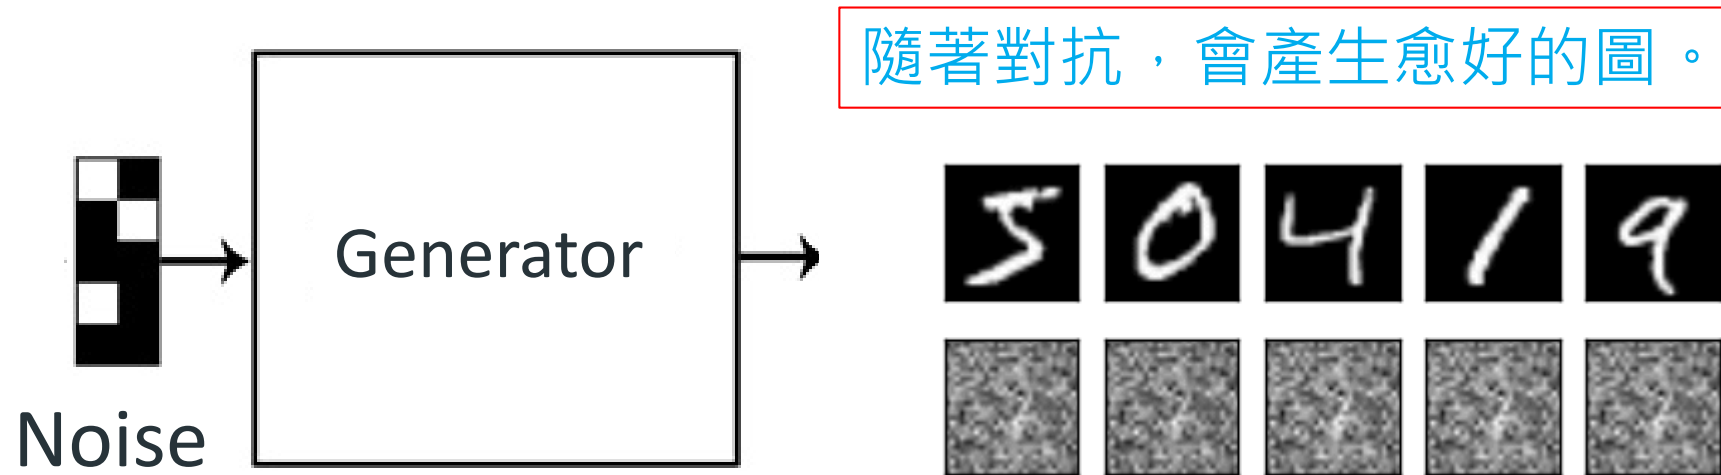
GAN - Discriminator 判別器

- 訓練 Discriminator 判別器
 - 不考慮Generator，只更新判別器。
 - 輸入：影像等等...
 - 輸出：1或0(Real/Fake)。



GAN - 生成對抗網路

- GAN就是藉由兩個網路『一直互相對抗』，來進行訓練。
- 通常最終目的：Generator網路。
 - ※ 因為Generator到最後會非常逼近真實圖像。



GAN – Homework - 【圖像還原 – 『嘴巴生成』】

- 實作一個Conditional GAN → 將抹白的部分，生成嘴巴。

- Dataset : NLP Student Collection .

- Generator

- 輸入：抹白圖。
- 架構：建議 U-NET。
- 輸出：真實圖。




- Discriminator

- 輸入：Real Pair & Fake Pair。(輸入兩張圖)
- 架構：Patch-GAN / 隨意。
- 輸出：n*n的Label map / 1-dimension Label map。

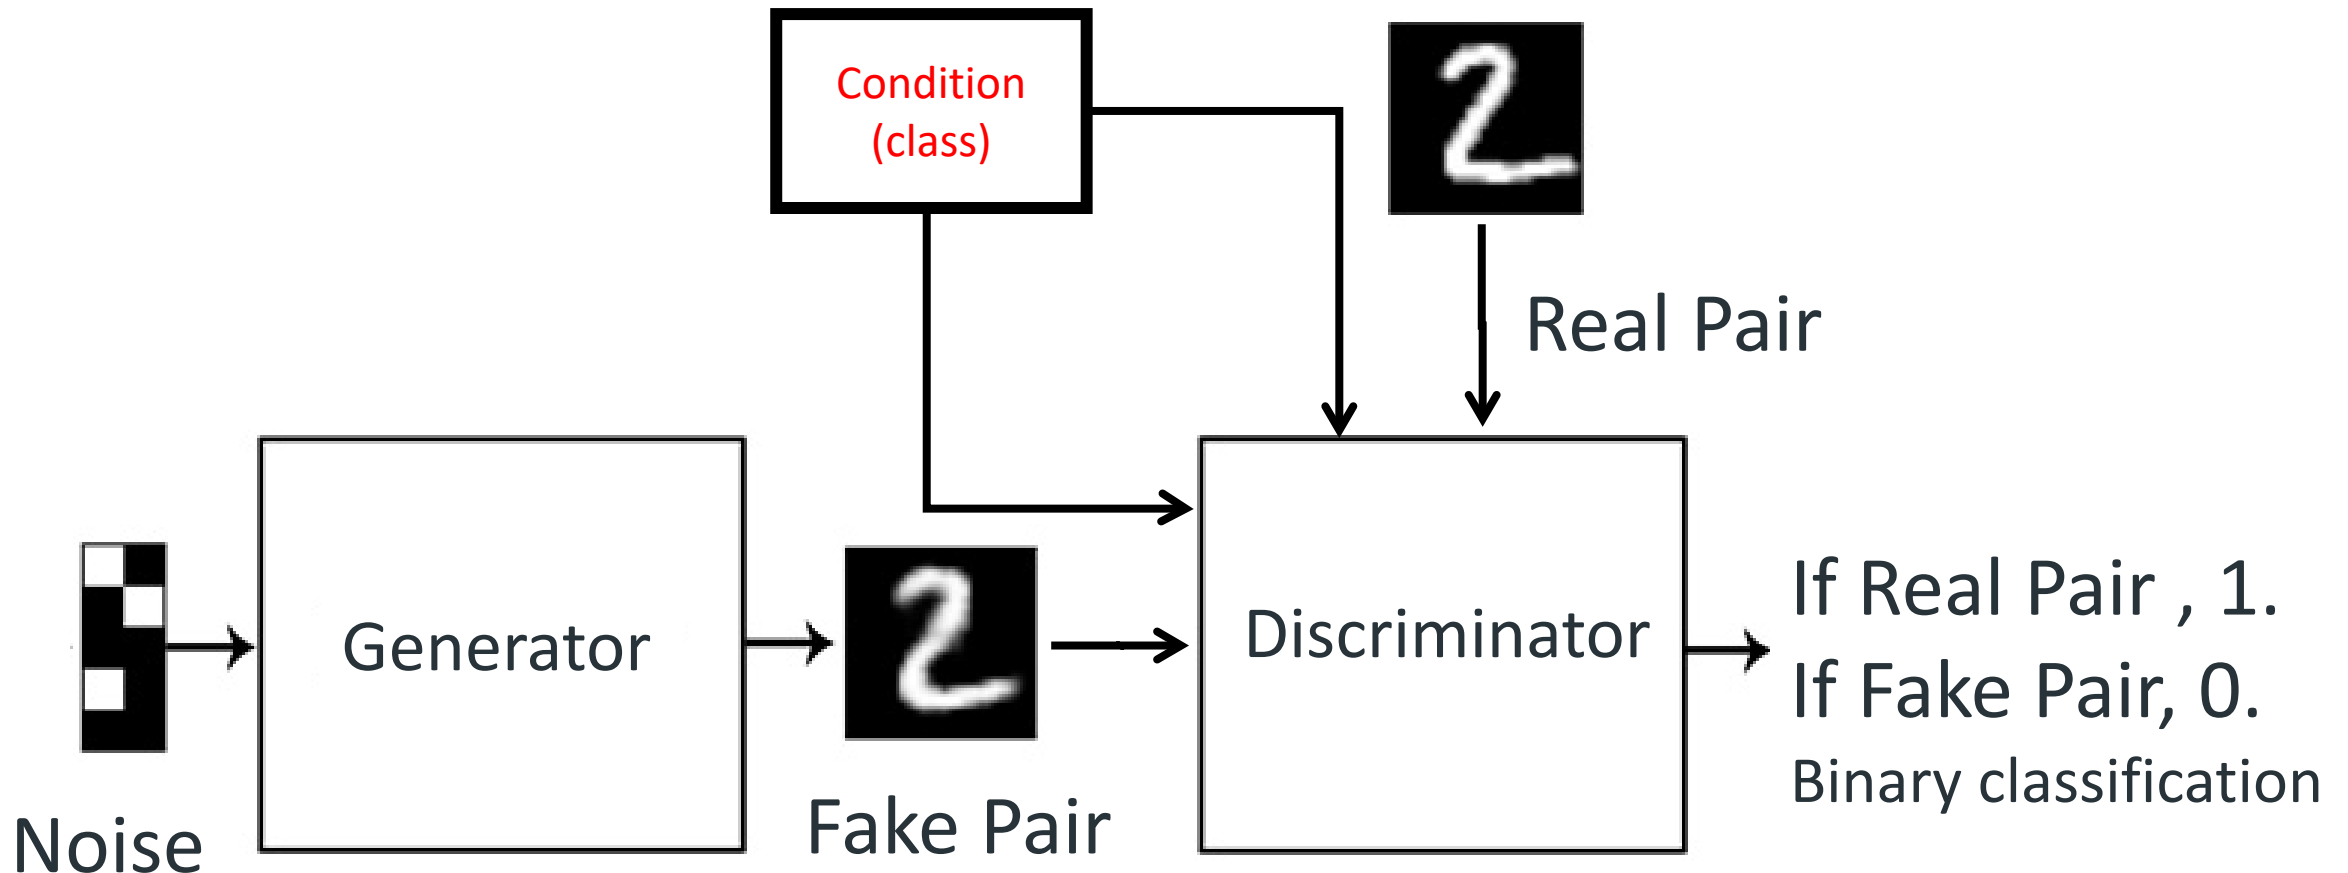
GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● GAN



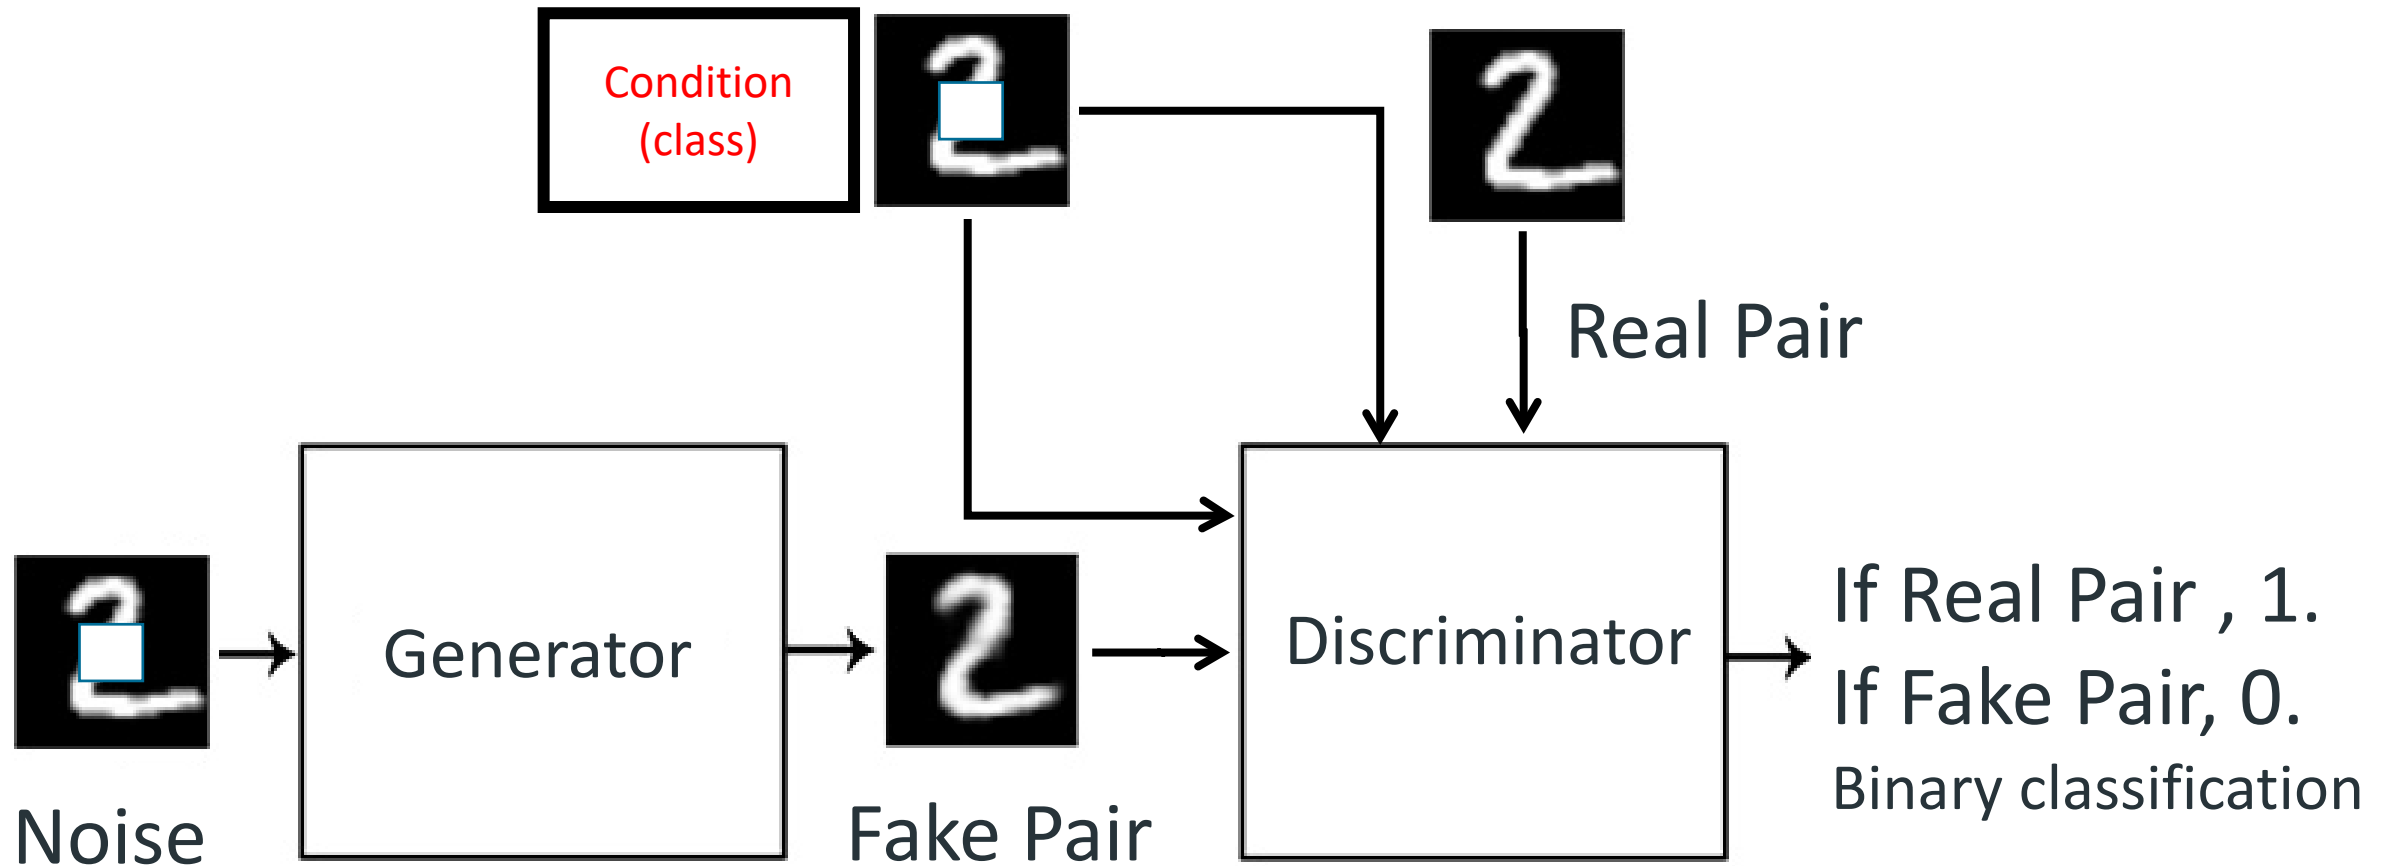
GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Conditional - GAN



GAN – Homework - 【圖像還原 – 『嘴巴生成』】

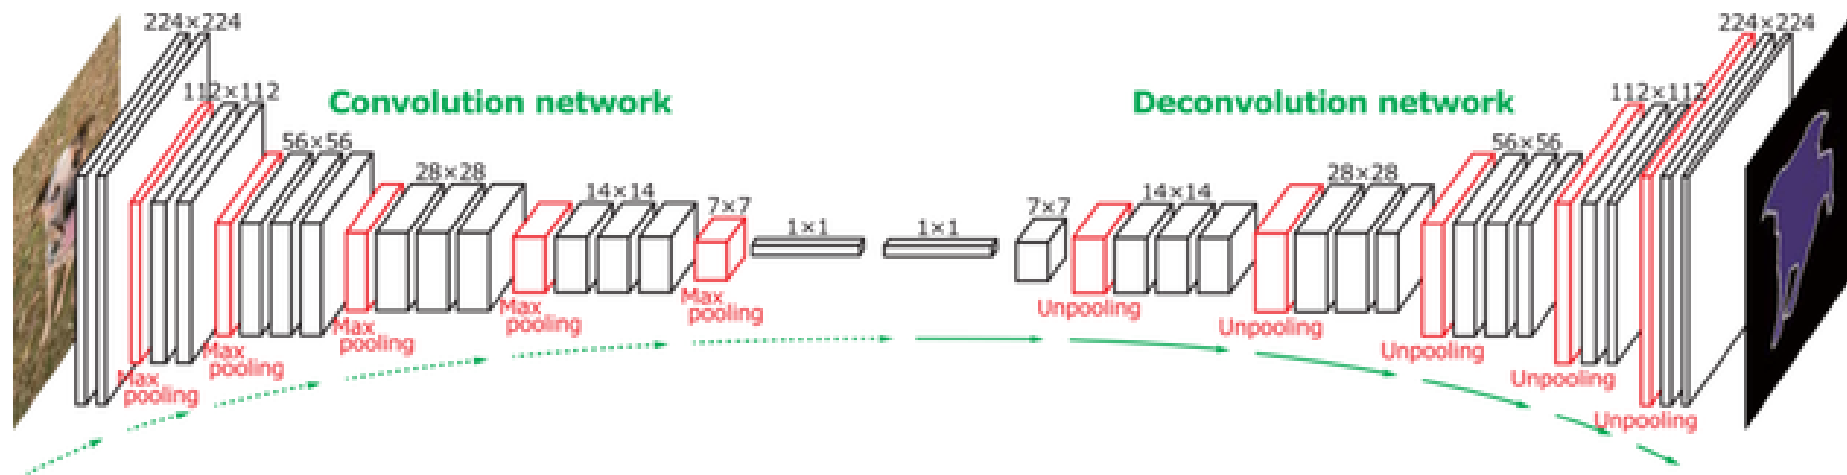

- Pixel2Pixel - GAN由兩個網路所組成 → U-Net(FCN) 、 Patch-GAN 。



GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Generator 設定建議


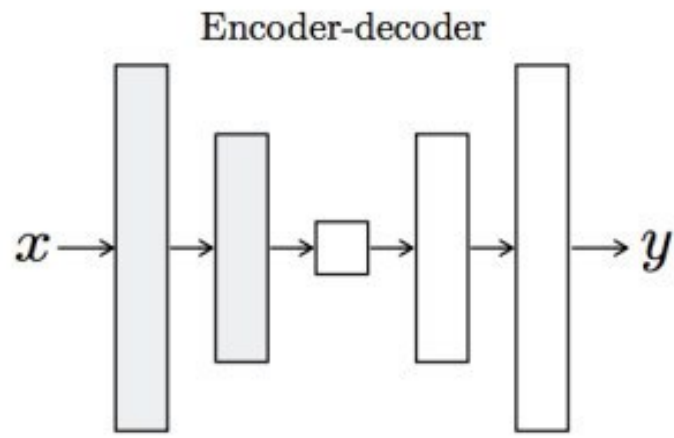
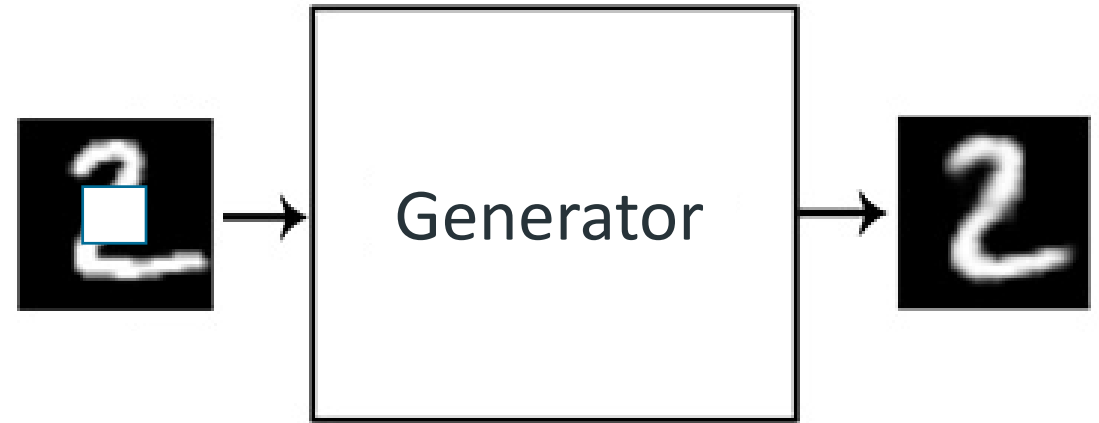
- Fully Convolutional Neural Network.
- 輸入與輸出同大小。
- 由Encoder & Decoder所組成。




GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Generator 設定建議

- U-Net.
- 輸入與輸出同大小。
- 由Encoder & Decoder所組成。



GAN – Homework - 【圖像還原 - 『嘴巴生成』】



GAN – Homework - 【圖像還原 – 『嘴巴生成』】


- Discriminator 設定建議
 - Patch-GAN or Dense or Conv2D + Dense ◦
 - 通常是1維的輸出 ◦
 - 如果是Patch-GAN→是 $n*n$ 的維度輸出 ◦
 - 激活函數通常用Sigmoid ◦
 - 可以一次訓練多次 ◦



GAN – Homework - 【圖像還原 – 『嘴巴生成』】

- Discriminator 設定建議
 - Dense or Conv2D + Dense。
 - 通常是1維的輸出。
 - 激活函數通常用Sigmoid。
 - 可以一次訓練多次。

※ 右圖為Conv2D + Dense示意圖。
輸入是兩張Concat成一張，
而非輸入單張。




GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Discriminator 設定建議

■ Patch-GAN

- 就是一連串的Conv2D做提取，並且輸出是 $n*n$ 的輸出。
- 可視為將一份影像，Patch成很多塊，分別做一次Discriminator。
- 所以假設有 $n*n$ 個Patch → 就有 $n*n$ 個輸出。

- Faster
- Training with larger Images
- Equal or better results



GAN – Homework - 【圖像還原 – 『嘴巴生成』】

- 網路統一設定建議

- 通常用Binary Cross Entropy 來計算loss。
- 在Pix2Pix是用MSE或MAE來計算loss。
- 盡量使用Batch Normalization、Dropout。
- Leaky ReLU通常會比ReLU還好。

- 網路訓練的提醒

- 兩網路的Loss會一直跳動(對抗)。
- 精確度 → Discriminator會在0.5跳動。

- 訓練Discriminator時， Real Pair data label = 1 , Fake Pair data label = 0.
- 訓練Generator時， Fake Pair data label = 1.





GAN – Homework - 【圖像還原 – 『嘴巴生成』】

- 整個作業流程大致分為以下部分：
 - 創建Generator與Discriminator網路。
 - 創建訓練Generator的網路。(訓練Generator時，需要包含Discriminator。)
 - 讀取Data資料。
 - 定義Training Label的答案。(Real Pair Label = 1 , Fake Pair Label = 0)
 - Step1. 隨機挑選N個Real & White Image。(N=batch size)
 - Step2. 將White Image給Generator產生Fake Image。
 - Step3. 拿(Fake Pair & Real Pair)訓練Discriminator網路。(可訓練多次)
 - Step4. 拿(Fake Pair)訓練Generator網路。
 - Step5. 重複Step.1至Step4. 的動作，直到訓練收斂or其他訓練條件滿足。

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Score : 15%

- 程式碼 ◦ 0% (沒給扣5分)
- 文書檔 ◦ 5%
- Kaggle ◦ 10%



kaggle

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

- Link : <https://ppt.cc/fKywMx>
- Deadline : 2018/05/29 23:59 .
- Upload limit 20 times/day .
- Final Score :

<1> \leq baseline

→ 0 score

<2> \geq baseline

→ $3 + 5 \frac{\text{baseline} - \text{your}}{\text{baseline} - \text{strongbaseline}}$

<3> \geq strong baseline

→ $8 + 2 \frac{\text{strongbaseline} - \text{your}}{\text{strongbaseline} - \text{highest}}$

Team Name	Score ?
Strong_Baseline	0.03568
Baseline	0.14744

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

- Data : NLP Student Collection ◦
- Training Set : 700組 真實-抹白 照片 ◦
- Test Set : 10張 抹白照片 ◦
- Metric : RMSE ◦
- Baseline Setting → 直接丟抹白圖與答案圖做RMSE ◦
- Strong Baseline → 使用pix2pix GAN超簡化版 ◦
 - ※ pix2pix原本參數量 : 44,584,214 → 77,766 ◦



GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

■ NN Structure :

<1> Generator → Conv2D(f=4,k=(4,4),s=(2,2))+LeakyRelu(0.2)
+ Conv2D(f=8,k=(4,4),s=(2,2))+LeakyRelu(0.2)+BN
+ Conv2D(f=16,k=(4,4),s=(2,2))+LeakyRelu(0.2)+BN
+ Conv2D(f=32,k=(4,4),s=(2,2))+LeakyRelu(0.2)+BN
+ Conv2D(f=32,k=(4,4),s=(2,2))+LeakyRelu(0.2)+BN
+ UpSampling(s=(2,2))+Conv2D(f=32,k=(4,4),s=(1,1))+Relu(0.2)+BN+skip_input
+ UpSampling(s=(2,2))+Conv2D(f=16,k=(4,4),s=(1,1))+Relu(0.2)+BN+skip_input
+ UpSampling(s=(2,2))+Conv2D(f=8,k=(4,4),s=(1,1))+Relu(0.2)+BN+skip_input
+ UpSampling(s=(2,2))+Conv2D(f=4,k=(4,4),s=(1,1))+Relu(0.2)+BN+skip_input
+ UpSampling(s=(2,2))+Conv2D(f=1,k=(4,4),s=(1,1))+tanh

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

■ NN Structure :

<2> Discriminator → Conv2D(f=4,k=(4,4),s=(2,2))+LeakyRelu(0.2)
+ Conv2D(f=8,k=(4,4),s=(2,2))+LeakyRelu(0.2)+BN
+ Conv2D(f=16,k=(4,4),s=(2,2))+LeakyRelu(0.2)+BN
+ Conv2D(f=32,k=(4,4),s=(2,2))+LeakyRelu(0.2)+BN
+ Conv2D(f=1,k=(4,4),s=(1,1))

■ Optimizer : Adam(lr=0.0002,beta_1=0.5) G & D same.

■ loss : G → 『MSE,MAE』 , D → 『MSE』 ◦

■ Epoch : 3000

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

- 提供三檔案：
 - <1> gan_example_comment_version.py #有註解
 - <2> gan_example_normal_version.py #純Code版
 - <3> image_to_csv.py #繳交至Kaggle



gan_example_com
ment_version.py



gan_example_norm
al_version.py



Image_to_csv.py

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

- 包含：
 1. 『 Training Data Loading 』
 2. 『 Define D and G network structure and parameter setting 』
 3. 『 Define Training D and G model 』
 4. 『 Define Image Generator 』
 5. 『 Training Phase 』
 6. 『 Display your predict 』



gan_example_com
ment_version.py



gan_example_norm
al_version.py

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

■ 包含：1. 『Training Data Loading 』

```
#####  
# Training Data List Creat  
#####  
train_real_data_dir = r'.\NLP_data\Training\Real\*'  
train_white_data_dir = r'.\NLP_data\Training\White\*'  
  
real_list = glob.glob(train_real_data_dir)  
train_real_data_list = []  
train_real_data_list.extend(real_list)  
  
white_list = glob.glob(train_white_data_dir)  
train_white_data_list = []  
train_white_data_list.extend(white_list)
```

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

- 包含：2. 『Define D and G network structure and parameter setting』

```
#####  
# Define D and G and parameter  
#####  
img_row = img_col = 128 #先規定成128*128 不過由於Pixel2Pixel架構的關係 最好是2的次方數 (2^n)  
channels = 1 # 1 is gray  
           # 3 is RGB  
img_shape=(channels,img_row,img_col) # or (img_row,img_col,channels)  
#2018.05.03補充==>這邊img_shape在Keras中 預設是『img_row,img_col,channels』 ==>Channels是放在後面的  
#           所以這邊看你們怎麼設定img_shape  
#           如果你用我這種寫法『channels,img_row,img_col』 你後面在Call Conv2D等等的東西 需要加入『data_format='channe  
#           不過我記得有可以在剛開始一次設定是channels_first還是channels_last, 就請各位去查查囉。  
#  
def dis(input_shape): ...  
  
def gen(input_shape,** kwargs): ...
```

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

- 包含：3. 『Define Training D and G model』

```
#####  
# 定義訓練D的模型  
#####  
#定義你的優化器巴 SGD Adam Adamax Adadelta rmsprop etc... 都可以 隨便  
#只是學習率通常別調太高 ...(ps:容易壞掉QQ) 我自己是用0.0002 Adam  
D_optimizer = <your creativity>  
#如果你是用Patch GAN conv2D做結尾的 建議用MSE  
#如果你是用Dense直接變成1維 則沒限制  
D.compile(loss=<your creativity>, optimizer=D_optimizer, metrics=['accuracy'])  
#Loss 跟投影片一樣 MSE 或 Cross Entropy 隨便 都可以試  
D.summary()
```

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

■ 包含：3. 『Define Training D and G model』

```
#####  
# 定義訓練G的模型  
#####  
#沒錯上課說過  
#再訓練G的時候 需要把D引入近來 並且Fix它 寫法就在下面  
#當然我們還是先定義優化器 ==>記住 通常是跟D的優化器設定一樣 不過沒人說這樣一定好 隨便你的選擇  
#這邊我們將這種網路叫做AM (對抗模型)  
AM_optimizer = <your creativity>  
img_A = Input(input_shape) #真實圖  
img_B = Input(input_shape) #助教塗白的真實圖  
fake_A = G(img_B) #先將塗白的塗去預測出fake image ==>期望生成真實圖  
D.trainable=False #讓D在AM模型Fix  
valid = D([fake_A,img_B]) #將fake img 跟抹白的圖給D去判別 得出判決結果valid  
AM = Model([img_A,img_B],[valid,fake_A]) # 定義model 我們這邊的輸出 有包含D的結果以及  
# G收到抹白的圖所產生的fake圖  
AM.compile(loss=[<your creativity>,<your creativity>],loss_weights=[1,1],optimizer=optimizer)  
# 這邊的Loss通常是MSE或MAE,其他也可以  
# 第一個Loss 是 Dis的輸出Loss  
# 第二個Loss 你就想像是AutoEncoder的訓練方式 輸入抹白 輸  
# loss_weights是為了加快訓練效果 如果不想調整 都為1即可  
AM.summary()
```

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

- 包含：
 - <1> 讀取每個Test Image
 - <2> 將每個Test Image 丟給生成器預測。
 - <3> 將每張預測圖串接並flatten成kaggle可接受的格式。

※ 每張預測圖 Size $\rightarrow (M,N)$

※ 串接預測圖 Size $\rightarrow (10,M,N)$

※ 攤平預測圖 Size $\rightarrow (10,M*N)$ 並轉置 $\rightarrow (M*N,10)$

※ 利用Pandas存成csv檔案。

※ 如果你要自己寫 就需要以上四步驟來完成，不然結果會有問題。



Image_to_csv.py

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Kaggle 10%

```
output_img_col = output_img_row=128
ori_img,white_img = generator_test_Img(list_dir=test_data_list,resize=(output_img_col,output_img_row))
#這邊的G就是Example Code的G拉
#只是怕放在最下面會搞亂大家 所以分別寫出來
image_array = G.predict(white_img).squeeze(1)
image_array = (image_array+1)/2

print(image_array.shape)

numpy_to_csv(input_image=image_array,image_number=n,save_csv_name='Predict.csv')
```

#Predict出來是 (n,1,img_row,img_col) 只是做Reshape為(n, img_row, img_col)

#這邊很重要 因為答案是0~1的灰階值

#然而如果你Generator輸出是tanh 會介於-1~1之間, 須把他變成0~1

#當然如果你是Sigmoid輸出, 就不用作Rescale的動作

#預期是(n,img_row,img_col) 如果不是 可能會轉換不出來, 或

GAN – Homework - 【圖像還原 – 『嘴巴生成』】

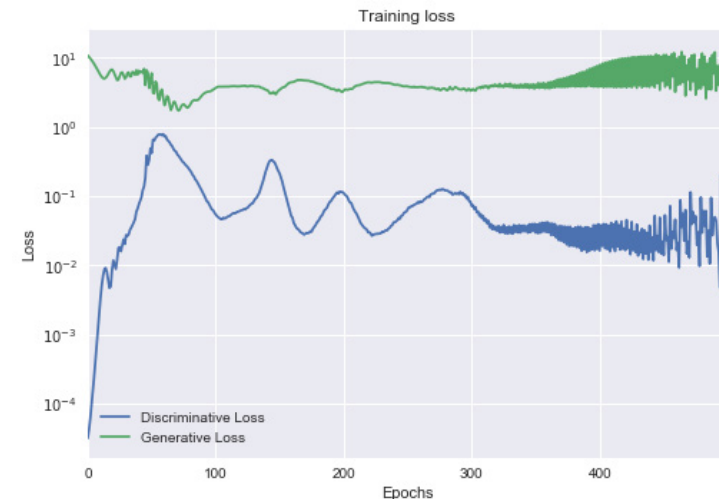
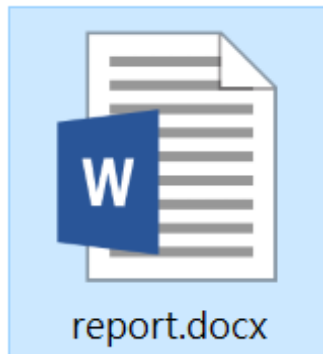

● 上傳兩檔案至Moodle

■ 程式碼。

※ 沒限制實現語法 : keras pytorch caffe caffe2 chainer scikit-learn etc ...

■ 文書檔：

- 網路架構。(每層的設定 等等...。)
- 訓練Loss圖。(包含：Generator & Discriminator。)(※ Tensorboard matplotlib etc ..)
- 訓練方法與心得。



GAN – Homework - 【圖像還原 – 『嘴巴生成』】

● Score : 5%

■ 程式碼。 0% (沒給會扣5分)

■ 文書檔： 5%

➤ 網路架構。(2%)

➤ 訓練Loss圖。(1%)

➤ 訓練方法與心得。(2%)

※ 隨機填值、填固定值、隨機填固定值 → 整體分數0分。

※ 沒使用Generator去生成 → 整體分數0分。

※ 純用AutoEncoder來預測 → 整體分數打8折。

THE END

GAN – Generator 生成器 – keras example

● Generator Network

- 輸入：100維的noise。
- Dense→升維→四層Conv2D來創造圖像，最後一層用Sigmoid輸出。

```
G = Sequential()
G.add(Dense(7*7*256, input_dim=100, activation='relu'))
G.add(Reshape((256,7,7)))
G.add(UpSampling2D())
G.add(Conv2D(128, 5, padding='same', activation='relu'))
G.add(UpSampling2D())
G.add(Conv2D(64, 5, padding='same', activation='relu'))
G.add(Conv2D(32, 5, padding='same', activation='relu'))
G.add(Conv2D(1, 5, padding='same', activation='sigmoid'))
G.summary()
```

GAN – Generator 生成器 – keras example

- Generator Network

- 聽說Conv2DTranspose有更好的效果。(給同學們自己試囉。)

```
G = Sequential()
G.add(Dense(7*7*256, input_dim=100))
G.add(Activation('relu'))
G.add(Reshape((256,7,7)))

G.add(UpSampling2D())
G.add(Conv2DTranspose(128, 5, padding='same'))
G.add(Activation('relu'))

G.add(UpSampling2D())
G.add(Conv2DTranspose(64, 5, padding='same'))
G.add(Activation('relu'))

G.add(Conv2DTranspose(32, 5, padding='same'))
G.add(Activation('relu'))

G.add(Conv2DTranspose(1, 5, padding='same'))
G.add(Activation('sigmoid'))
G.summary()
```

GAN - Discriminator 判別器 – keras example

● Discriminator Network

- 輸入：(1,28,28)。
- 疊4層Conv2D來完成的網路。

```
D = Sequential()  
input_shape = (1,28,28)  
D.add(Conv2D(64, 5, strides=2, input_shape=input_shape, padding='same', activation='relu'))  
D.add(Conv2D(128, 5, strides=2, padding='same', activation='relu'))  
D.add(Conv2D(256, 5, strides=2, padding='same', activation='relu'))  
D.add(Conv2D(512, 5, strides=1, padding='same', activation='relu'))  
D.add(Flatten())  
D.add(Dense(1, activation='sigmoid'))  
D.summary()
```

GAN - Discriminator 判别器 – keras example

- Discriminator Network

- 如果把ReLU改成LeakyReLU，並加入Dropout效果會好很多。

```
D = Sequential()
input_shape = (1,28,28)
D.add(Conv2D(64, 5, strides=2, input_shape=input_shape,padding='same',activation=LeakyReLU(alpha=0.2)))
D.add(Dropout(0.4))
D.add(Conv2D(128, 5, strides=2, padding='same',activation=LeakyReLU(alpha=0.2)))
D.add(Dropout(0.4))
D.add(Conv2D(256, 5, strides=2, padding='same',activation=LeakyReLU(alpha=0.2)))
D.add(Dropout(0.4))
D.add(Conv2D(512, 5, strides=1, padding='same',activation=LeakyReLU(alpha=0.2)))
D.add(Dropout(0.4))
D.add(Flatten())
D.add(Dense(1))
D.add(Activation('sigmoid'))
D.summary()
```

GAN - keras example

- 定義訓練Discriminator & Generator網路
 - 通常會把Discriminator的學習率調高點。
 - 訓練Generator需要考慮到Discriminator，所以創建AM(adversarial Model)。

```
optimizer = RMSprop(Lr=0.0002, clipvalue=1.0, decay=6e-8)
D.compile(Loss='binary_crossentropy', optimizer=optimizer, metrics=['accuracy'])
D.summary()
```

```
optimizer = RMSprop(Lr=0.0001, decay=3e-8)
AM = Sequential()
AM.add(G)
AM.add(D)
AM.compile(Loss='binary_crossentropy', optimizer=optimizer, metrics=['accuracy'])
AM.summary()
```


THE END