

智慧化企業整合

Project 3

使用 CNN 進行 LEGO 圖像辨識

Individual Research Project

109034553 莊婉琦

目錄

一、 緒論

1. 主題介紹
2. 問題定義 5W1H

二、 研究方法

1. 資料蒐集
2. 資料前處理
3. 模型建立
4. 訓練模型
5. 驗證集驗證
6. 改善過程

三、 研究結果

四、 結論

1. 限制
2. 未來展望

五、 參考文獻

一、緒論

1. 主題介紹

樂高是兒童家中常見的玩具，樂高提供不同層次的任務挑戰，學習形狀、顏色識別、計算數字和圖案等，建構基本的數學技能，模型建構、自由創作亦能協助訓練空間能力，對於學齡孩童是一個很好的教材。樂高在教育方面，協助家長和孩童可以一起激發創造力，把建構出來的積木當作互動扮演的素材。孩子可以藉由遊戲表達自己的想法、促進各種情境的語言溝通、問題解決的能力，還可以培養孩子的合作性、專注度和責任感。樂高的無限創造空間，深受大眾喜愛。

樂高官方網站收錄了許多電影及動畫的角色，從經典的哈利波特系列到漫威 DC 系列，新增現代電影、動漫角色速度也有目共睹，本篇研究將利用 Kaggle 資料庫所蒐集的樂高圖像資料，建立 CNN 模型辨識 LEGO 人物角色，並探討其辨識結果及正確性。

2. 5W1H

Why: LEGO 新增現代電影、動漫角色速度有目共睹，透過 LEGO 人物的辨識系統，協助樂高玩家更認識各個角色

What: 藉由建立 CNN 辨識樂高圖像，讓樂高玩家認識自己未知的角色

Where: 樂高販賣店

When: 選購樂高時

Who: LEGO 顧客、LEGO 販賣店員工

How: 蒐集 LEGO 角色圖片，利用卷積神經網路訓練照片，判斷出 LEGO 的角色

二、研究方法

研究之架構共分為以下 6 個步驟：(1)資料蒐集、(2)資料前處理、(3)模型建立、(4)訓練模型、(5)驗證集驗證、(6)改善過程，得出分類效果較佳的模型。

1. 資料蒐集

由 Kaggle 公開數據集中取得樂高圖像資料集，其中 3 個資料夾中分別包含不同系列的樂高角色，包含哈利波特系列 2 個角色、漫威電影宇宙系列 10 個角色、星際大戰系列 10 個角色，樣本數總共有 240 張圖片；資料集中一包含兩個 csv 檔，其中一資料集整理圖片路徑、訓練集/測試集標籤，另一資料則標示角色編號、樂高盒組系列名稱以及樂高角色名稱，樣本共包含 22 個樂高角色。

2. 資料前處理

(1) 匯入資料集

將蒐集下來的資料及上傳至雲端硬碟，掛接 Google 雲端允許 Colaboratory 後端存取雲端硬碟中的檔案。

```
#匯入存在雲端的資料集
path = 'drive/MyDrive/Lego/'
```

```
#查看資料 index.csv
index_df = pd.read_csv('drive/MyDrive/Lego/index.csv')
index_df.head()
```

	path	class_id	train-valid
0	marvel/0001/001.jpg	1	train
1	marvel/0001/002.jpg	1	valid
2	marvel/0001/003.jpg	1	train
3	marvel/0001/004.jpg	1	train
4	marvel/0001/005.jpg	1	train

```
#查看 metadata.csv
meta_df = pd.read_csv(path+'metadata.csv')
meta_df.head()
```

	class_id	lego_ids	lego_names	minifigure_name
0	1	[76115]	['Spider Mech vs. Venom']	SPIDER-MAN
1	2	[76115]	['Spider Mech vs. Venom']	VENOM
2	3	[76115]	['Spider Mech vs. Venom']	AUNT MAY
3	4	[76115]	['Spider Mech vs. Venom']	GHOST SPIDER
4	5	[75208]	['"Yoda's Hut"']	YODA

(2) 資料合併

組合兩個來源的資料集，確認資料名稱及屬性一致後，進行資料的水平合併，這項操作將兩個不同的資料非常直觀的串聯，整理出一個更乾淨的表格。

```
#將index、metadata兩個資料集合併整理，多對多join(path對class_id/minifigure_name)
data_df = pd.merge(index_df, meta_df[['class_id', 'minifigure_name']], on='class_id')
data_df
```

	path	class_id	train-valid	minifigure_name
0	marvel/0001/001.jpg	1	train	SPIDER-MAN
1	marvel/0001/002.jpg	1	valid	SPIDER-MAN
2	marvel/0001/003.jpg	1	train	SPIDER-MAN
3	marvel/0001/004.jpg	1	train	SPIDER-MAN
4	marvel/0001/005.jpg	1	train	SPIDER-MAN
...
235	marvel/0010/010.jpg	22	train	TASKMASTER
236	marvel/0010/011.jpg	22	valid	TASKMASTER
237	marvel/0010/012.jpg	22	valid	TASKMASTER
238	marvel/0010/013.jpg	22	train	TASKMASTER
239	marvel/0010/014.jpg	22	train	TASKMASTER

(3) 檢查資料是否有缺值或遺漏值

結果顯示資料並無缺值，故不用進行資料補值處理。

```
#查看資料有無缺值
data_df.isnull().sum()

path          0
class_id      0
train-valid   0
minifigure_name  0
dtype: int64
```


(4) 資料視覺化

從所有圖片集中隨機抽取 20 張 (為簡單說明，此處只擷取 5 張圖片)來檢視。

```

plt.figure(figsize=(10,10))
i=0
for i in range(20):
    plt.subplot(4,5,i+1)
    plt.grid(False)
    img=load_img('drive/MyDrive/Lego/' +sample_df['path'].values[i])
    plt.imshow(img)
    #plt.axis("off")
    plt.xlabel(sample_df['minifigure_name'].values[i])
    i += 1
plt.show()

```



(5) 將資料分為訓練集、驗證集

Index 資料集中的一欄位已隨機將圖片標籤為訓練集、驗證集，其中訓練集佔 52%，驗證集佔 48%。

#將資料分為訓練集、驗證集

```

train_set = data_df[data_df["train-valid"] == 'train']
validation_set = data_df[data_df["train-valid"] == 'valid']

```

(6) 使用 OpenCV 讀取圖片時，默認的通道順序是 BGR，此處將圖像轉為 RGB；資料集中的原始圖片大小為(512*512)，後續將用 DenseNet121 演算法作為此研究模型，輸入層圖片大小須為(224*224)，故此處重新定義圖片大小，並將圖像像素標準化到 0 到 1 之間。

```

import cv2
#Training Data Preprocessing
#Converted the pixels of the image data to array

train_Data = np.zeros((train_set.shape[0], 224, 224, 3))

for i in range(train_set.shape[0]):

    image = cv2.imread('drive/MyDrive/Lego/' + train_set["path"].values[i])

    #Converting BGR to RGB
    image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)

    #Resizing image
    image = cv2.resize(image, (224,224))

    #Normalizing pixel values to [0,1]
    train_Data[i] = image / 255.0

trainLabel = np.array(train_set["class_id"])-1

```

3. 模型建立

(1) 模型選擇

使用 Pre-trained Model DenseNet121 作為模型。

```
from tensorflow.keras.applications import DenseNet121
from tensorflow.keras.models import Model
from tensorflow.keras.optimizers import Adam

dense_net = tf.keras.applications.DenseNet121()
dense_net_layer=Dropout(0.5)(dense_net.layers[-2].output)
number_of_classes = len(data_df['class_id'].unique())
last_layer = Dense(number_of_classes, activation="sigmoid")(dense_net_layer)
model = Model(dense_net.input, last_layer)
```

(2) 參數設定

```
#優化器 Adam
model.compile(loss='sparse_categorical_crossentropy',
              optimizer=Adam(0.0001),
              metrics=['accuracy'])
```

(3) 儲存點

長時間運行的程序需要能夠中途保存，深度學習的保存點用來存取模型的權重，這樣一來可以再需要時繼續訓練模型，或是直接開始預測。

```
#儲存點
from tensorflow.keras.callbacks import ModelCheckpoint

checkpoint = ModelCheckpoint(filepath='model.h5', monitor="val_accuracy", save_best_only=True, verbose=1)
```

4. 訓練模型

以 epoch 為 10；batch size 為 4 去訓練模型，並儲存訓練結果。


```
#模型訓練
hist=model.fit(
    train_Data,
    trainLabel,
    epochs=10,
    validation_data=(valid_Data, validLabel),
    shuffle=True,
    batch_size=4,
    callbacks=checkpoint
)
```

5. 驗證集驗證

繪製 Loss 及 Accuracy 圖表判斷訓練模型辨識的結果與真實值是否一致，由圖中可看出模型發生過擬合的問題。

```
print(hist.history.keys())
plt.plot(hist.history["loss"], label = "Train Loss")
plt.plot(hist.history["val_loss"], label = "Validation Loss")
plt.legend()
plt.show()

plt.figure()
plt.plot(hist.history["accuracy"], label = "Train Accuracy")
plt.plot(hist.history["val_accuracy"], label = "Validation Accuracy")
plt.legend()
plt.show()
```



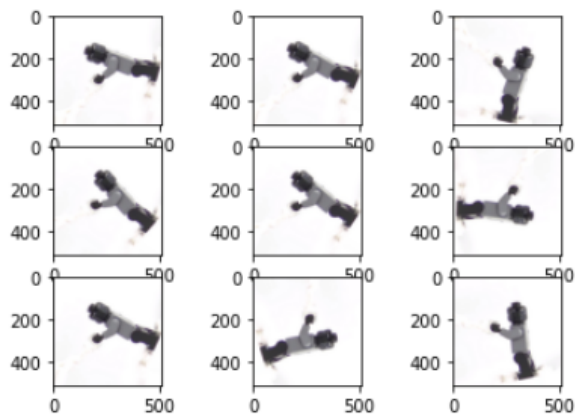
6. 改善過程

模型過擬合的問題可能是由於資料筆數僅有 240 張圖集，資料筆數少所導致，因此利用隨機轉動圖片角度，來增加照片數量。

(1) Image Data Generator

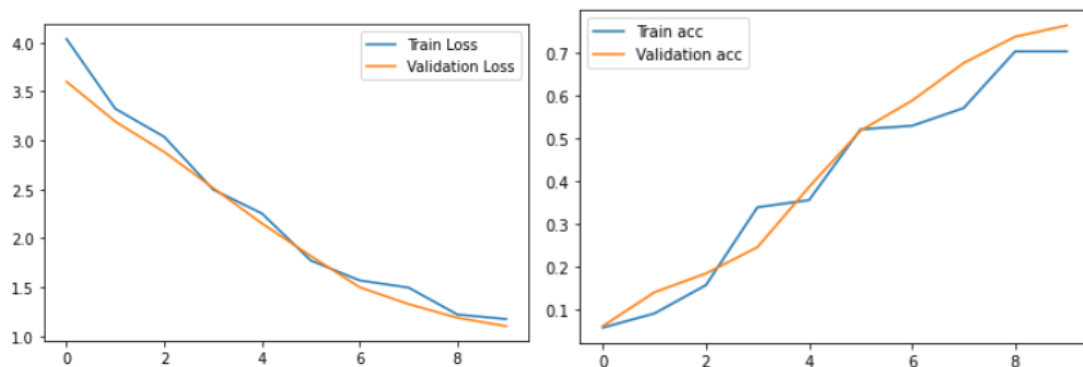
```
img = load_img('drive/MyDrive/Lego/marvel/0007/008.jpg')

data = img_to_array(img)
samples = expand_dims(data, 0)
datagen = ImageDataGenerator(rotation_range=120)
it = datagen.flow(samples, batch_size=1)
for i in range(9):
    pyplot.subplot(330 + 1 + i)
    batch = it.next()
    image = batch[0].astype('uint8')
    pyplot.imshow(image)
pyplot.show()
```

改善結果

增加圖片張量後再次訓練模型，發現過擬合問題得到改善，但由於準確率稍嫌不足，於是下一步繼續透過參數的調整，提升模型的準確度。



(2) 調整參數

利用參數調整的方法，找尋最佳的參數組合提升模型的準確率。透過調整激活函數、學習率的方式，來比較原始模型。

Model 1 的設置如下

	Last layer Dense activation	Learning Rate	Optimizer	Epoch	Accuracy
Model 1	sigmoid	0.0001	Adam	10	0.7632

Model 2 的設置如下

	Last layer Dense activation	Learning Rate	Optimizer	Epoch	Accuracy
Model 2	sigmoid	0.001	Adam	10	0.1930

```

Epoch 1/10
9/9 [=====] - 115s 13s/step - loss: 4.2077 - accuracy: 0.0318 - val_loss: 3.5997 - val_accuracy: 0.0614

Epoch 00001: val_accuracy improved from -inf to 0.06140, saving model to model1.h5
Epoch 2/10
9/9 [=====] - 102s 11s/step - loss: 3.3584 - accuracy: 0.0841 - val_loss: 3.1919 - val_accuracy: 0.1404

Epoch 00002: val_accuracy improved from 0.06140 to 0.14035, saving model to model1.h5
Epoch 3/10
9/9 [=====] - 101s 13s/step - loss: 3.2365 - accuracy: 0.1318 - val_loss: 2.8819 - val_accuracy: 0.1842

Epoch 00003: val_accuracy improved from 0.14035 to 0.18421, saving model to model1.h5
Epoch 4/10
9/9 [=====] - 104s 12s/step - loss: 2.5815 - accuracy: 0.2912 - val_loss: 2.5141 - val_accuracy: 0.2456

Epoch 00004: val_accuracy improved from 0.18421 to 0.24561, saving model to model1.h5
Epoch 5/10
9/9 [=====] - 106s 13s/step - loss: 2.4448 - accuracy: 0.3239 - val_loss: 2.1510 - val_accuracy: 0.3860

Epoch 00005: val_accuracy improved from 0.24561 to 0.38596, saving model to model1.h5
Epoch 6/10
9/9 [=====] - 105s 12s/step - loss: 1.7994 - accuracy: 0.5291 - val_loss: 1.8188 - val_accuracy: 0.5175

Epoch 00006: val_accuracy improved from 0.38596 to 0.51754, saving model to model1.h5
Epoch 7/10
9/9 [=====] - 107s 12s/step - loss: 1.6322 - accuracy: 0.5463 - val_loss: 1.4994 - val_accuracy: 0.5877


Epoch 00007: val_accuracy improved from 0.51754 to 0.58772, saving model to model1.h5
Epoch 8/10
9/9 [=====] - 103s 11s/step - loss: 1.4440 - accuracy: 0.5980 - val_loss: 1.3273 - val_accuracy: 0.6754

Epoch 00008: val_accuracy improved from 0.58772 to 0.67544, saving model to model1.h5
Epoch 9/10
9/9 [=====] - 102s 11s/step - loss: 1.1690 - accuracy: 0.7160 - val_loss: 1.1874 - val_accuracy: 0.7368

Epoch 00009: val_accuracy improved from 0.67544 to 0.73684, saving model to model1.h5
Epoch 10/10
9/9 [=====] - 108s 12s/step - loss: 1.2770 - accuracy: 0.6816 - val_loss: 1.1021 - val_accuracy: 0.7632

Epoch 00010: val_accuracy improved from 0.73684 to 0.76316, saving model to model1.h5

```



Model 3 的設置如下

	Last layer Dense activation	Learning Rate	Optimizer	Epoch	Accuracy
Model 3	softmax	0.0001	Adam	10	0.7018

```

Epoch 1/10
9/9 [=====] - 100s 11s/step - loss: 3.8834 - accuracy: 0.0301 - val_loss: 3.3156 - val_accuracy: 0.0702

Epoch 00001: val_accuracy improved from -inf to 0.07018, saving model to model10.h5
Epoch 2/10
9/9 [=====] - 88s 10s/step - loss: 3.4830 - accuracy: 0.1155 - val_loss: 3.0194 - val_accuracy: 0.1228

Epoch 00002: val_accuracy improved from 0.07018 to 0.12281, saving model to model10.h5
Epoch 3/10
9/9 [=====] - 86s 10s/step - loss: 3.0184 - accuracy: 0.1224 - val_loss: 2.6970 - val_accuracy: 0.2105

Epoch 00003: val_accuracy improved from 0.12281 to 0.21053, saving model to model10.h5
Epoch 4/10
9/9 [=====] - 85s 9s/step - loss: 2.7646 - accuracy: 0.1229 - val_loss: 2.3597 - val_accuracy: 0.3070

Epoch 00004: val_accuracy improved from 0.21053 to 0.30702, saving model to model10.h5
Epoch 5/10
9/9 [=====] - 85s 9s/step - loss: 2.5371 - accuracy: 0.2823 - val_loss: 2.0578 - val_accuracy: 0.3772

Epoch 00005: val_accuracy improved from 0.30702 to 0.37719, saving model to model10.h5
Epoch 6/10
9/9 [=====] - 84s 9s/step - loss: 2.0991 - accuracy: 0.3371 - val_loss: 1.8712 - val_accuracy: 0.4298

Epoch 00006: val_accuracy improved from 0.37719 to 0.42982, saving model to model10.h5
Epoch 7/10
9/9 [=====] - 85s 9s/step - loss: 1.6159 - accuracy: 0.5386 - val_loss: 1.7542 - val_accuracy: 0.4211


Epoch 00007: val_accuracy did not improve from 0.42982
Epoch 8/10
9/9 [=====] - 84s 9s/step - loss: 1.4979 - accuracy: 0.5697 - val_loss: 1.4247 - val_accuracy: 0.5263

Epoch 00008: val_accuracy improved from 0.42982 to 0.52632, saving model to model10.h5
Epoch 9/10
9/9 [=====] - 85s 9s/step - loss: 1.3629 - accuracy: 0.5857 - val_loss: 1.2098 - val_accuracy: 0.6316

Epoch 00009: val_accuracy improved from 0.52632 to 0.63158, saving model to model10.h5
Epoch 10/10
9/9 [=====] - 84s 9s/step - loss: 1.0772 - accuracy: 0.7069 - val_loss: 1.0226 - val_accuracy: 0.7018

Epoch 00010: val_accuracy improved from 0.63158 to 0.70175, saving model to model10.h5

```



Model 4 的設置如下

	Last layer Dense activation	Learning Rate	Optimizer	Epoch	Accuracy
Model 4	softmax	0.0001	Adam	25	0.9123

```

Epoch 00018: val_accuracy improved from 0.81579 to 0.83333, saving model to mode10.h5
Epoch 19/25
9/9 [=====] - 75s 8s/step - loss: 0.4926 - accuracy: 0.8716 - val_loss: 0.5810 - val_accuracy: 0.8684

Epoch 00019: val_accuracy improved from 0.83333 to 0.86842, saving model to mode10.h5
Epoch 20/25
9/9 [=====] - 76s 8s/step - loss: 0.5940 - accuracy: 0.8772 - val_loss: 0.5053 - val_accuracy: 0.9035

Epoch 00020: val_accuracy improved from 0.86842 to 0.90351, saving model to mode10.h5
Epoch 21/25
9/9 [=====] - 76s 8s/step - loss: 0.4537 - accuracy: 0.9242 - val_loss: 0.5155 - val_accuracy: 0.8772

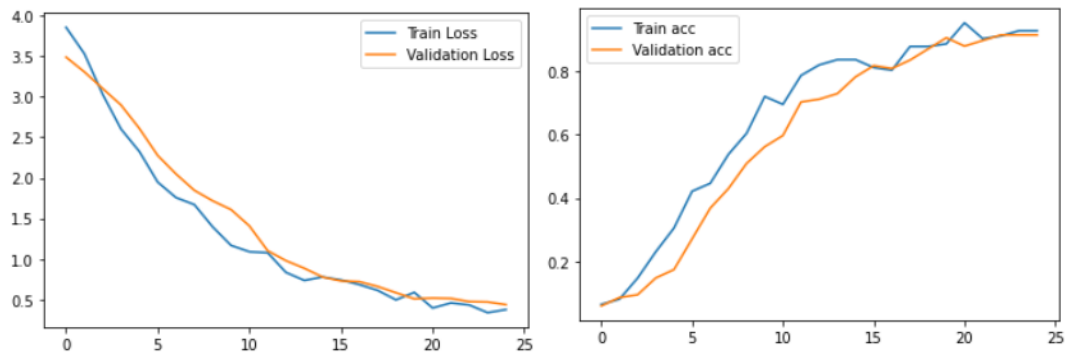
Epoch 00021: val_accuracy did not improve from 0.90351
Epoch 22/25
9/9 [=====] - 76s 8s/step - loss: 0.5341 - accuracy: 0.8605 - val_loss: 0.5102 - val_accuracy: 0.8947

Epoch 00022: val_accuracy did not improve from 0.90351
Epoch 23/25
9/9 [=====] - 75s 8s/step - loss: 0.3640 - accuracy: 0.9263 - val_loss: 0.4715 - val_accuracy: 0.9123

Epoch 00023: val_accuracy improved from 0.90351 to 0.91228, saving model to mode10.h5
Epoch 24/25
9/9 [=====] - 76s 9s/step - loss: 0.7858 - accuracy: 0.8056 - val_loss: 0.4669 - val_accuracy: 0.9123

Epoch 00024: val_accuracy did not improve from 0.91228
Epoch 25/25
9/9 [=====] - 76s 8s/step - loss: 0.3192 - accuracy: 0.9408 - val_loss: 0.4336 - val_accuracy: 0.9123

Epoch 00025: val_accuracy did not improve from 0.91228
    
```



三、研究結果

Model	Last layer Dense activation	Learning Rate	Epoch	Accuracy
1	sigmoid	0.0001	10	0.7632
2	sigmoid	0.001	10	0.1930
3	softmax	0.0001	10	0.7018
4	softmax	0.0001	25	0.9123

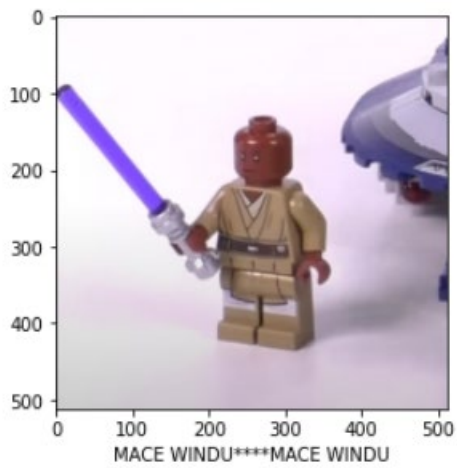

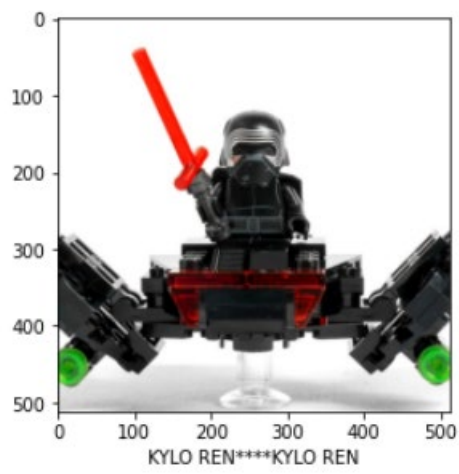

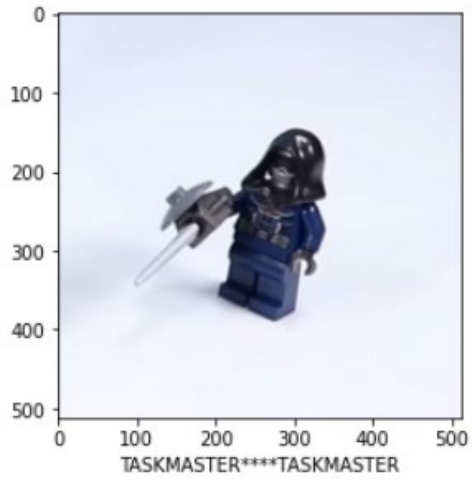
整理出上述結果可以看出，Model 2 更動學習率後，準確度不但沒有提升反而大幅下降，因此提高學習率此方法將不適用於此模型；Model 3 的學習率採用原模型的 0.0001，調整最後一層全連接層激活函數為 softmax 發現準確率提升、接近輸出層的過擬合情形也明顯收斂；Model 4 調整最後一層全連接層激活函數為 softmax、將 Epoch 增加到 25 次，結果顯示增加 Epoch 可以顯著的提升模型的準確率。

上述參數調整比較模型得知，使用後一層全連接層激活函數為 softmax、學習率為 0.0001 在三個模型中具有最高的準確率為 91.23%。因此可利用 Model 4 來進行新圖片的辨識，於下圖顯示辨識結果。

```
final_result = pd.merge(test_df[['minifigure_name', 'path']], results[['path', 'Predictions']], on='path')
final_result
```

	minifigure_name	path	Predictions
0	TASKMASTER	marvel/0010/014.jpg	TASKMASTER
1	GHOST SPIDER	marvel/0004/007.jpg	GHOST SPIDER
2	KYLO REN	star-wars/0006/003.jpg	KYLO REN
3	GENERAL GRIEVOUS	star-wars/0005/005.jpg	GENERAL GRIEVOUS
4	MACE WINDU	star-wars/0004/012.jpg	MACE WINDU

```
for i in range(5):
    image = cv2.imread('drive/MyDrive/Lego/' + final_result['path'].values[i])
    image = cv2.resize(image, dsize=(512, 512))
    image = cv2.cvtColor(image, cv2.COLOR_BGR2RGB)/255
    plt.imshow(image)
    plt.xlabel(final_result['minifigure_name'].values[i] + '***' + final_result['Predictions'].values[i])
    plt.show()
```



由測試集預測結果跟真實資料比對，模型皆做出正確的預測。

四、結論

1. 限制

研究過程中遇到的最大瓶頸及困難是程式語言能力的缺乏，需要在更進一步精進，此外這次所採用的數據資料只有 240 筆，雖然已經透過 Image Data Generator 去做改善，但未來仍可增加更多數據集讓模型訓練結果更具可靠性。礙於時間關係，嘗試參數的調整並不夠完善，未來可以利用實驗設計，將所有的參數組合去做訓練，找出最佳的模型。

2. 未來展望

未來可以持續優化辨識模型，結合 LEGO 手機 APP 實現 Real-Time 辨識系統，除了正確辨別出樂高人物角色以外，還能連結 LEGO 官方網站的角色背景來源，在 APP 上快速的連結各角色的故事背景集相關資料。

五、參考文獻

DenseNet-121 <https://www.kaggle.com/pytorch/densenet121> 、
<https://medium.com/%E5%AD%B8%E4%BB%A5%E5%BB%A3%E6%89%8D/dense-cnn-%E5%AD%B8%E7%BF%92%E5%BF%83%E5%BE%97-%E6%8C%81%E7%BA%8C%E6%9B%B4%E6%96%B0-8cd8c65a6f3f>
Lego Minifigures Dataset <https://www.kaggle.com/ihelon/lego-minifigures-classification>
Lego Transfer-CNN Classification <https://www.kaggle.com/drfrank/lego-transfer-cnn-classification>
Tensorflow 儲存模型參數 <https://ithelp.ithome.com.tw/articles/10187786>
Using Pre-Trained Models <https://keras.rstudio.com/articles/applications.html>
Geoff Pleiss et al. Memory-Efficient Implementation of DenseNets, Cornell University, 2017 <https://arxiv.org/abs/1707.06990>