

## 農作物葉片健康或病態識別分類

林呈昱

國立清華大學工業工程與工程管理學系  
qaz7416565@gmail.com

### 摘要

好的農作物收成是農民所樂見的，而對於農作物的健康狀態與否，其農作物上的葉片常常能反映出一些資訊給農民，以讓農民可以察知而及時做出相應措施，但現今由於觀光農場的普及，或許觀光的民眾也會想了解所觀察到的農作物狀況，但由於普遍大眾對農作物不甚了解，所以說如果能藉由圖像辨識並作分類，或許能在參觀之餘透過此技術辨別一些葉片的情況，相信對於參觀民眾會有所收穫，而本次資料集由 kaggle 所提供，其農作物照片共 9 萬多張，包含了 38 種類的健康和病態農作物照片，藉由建構 CNN 模型，並進行多次的訓練及嘗試修改模型以獲致更好的測試準確率，最終的模型在測試集上的準確率來到了 99.03%，相信對於未來由此資料集來源地，基於這些農作物所建構出的觀光農場，能為其觀光客帶來一些幫助。

**關鍵字 (3 至 5 個字):** Deep Learning、Convolutional Neural Networks、Crop

## 1 緒論

近年來，農業的轉型進而成立了許多的觀光農場帶動了旅遊產業，成為觀光客嘉日休閒或放鬆的好去處，而本次的研究專案，資料集為從 kaggle 網站獲取農作物的照片共 9 萬多張，其中包含了 38 種類的健康和病態農作物照片，農作物的健康狀態與否，其農作物上的葉片常常能反映出一些資訊給農民，以讓農民可以察知而及時做出相應措施，而假設今日實際將這些資料集之農作物一同栽作在一起，並建構出一個假想的觀光農場，由於普遍大眾對農作物不甚了解，所以說如果能藉由圖像辨識並作分類，或許能在參觀之餘透過此技術辨別一些葉片的情況，相信對於參觀民眾會有所收穫。

而本章分別利用 5W1H 分析此專案及闡述其預期之成果。

### 1.1 5W1H

#### Why

農作物的健康狀態與否，其農作物上的葉片常常能反映出一些資訊給農民，

以讓農民可以察知而及時做出相應措施，但由於普遍大眾對農作物不甚了解，所以觀光客也不易得知其有興趣之農作物之狀態。



#### What

我們想建立一個辨識農作物葉片的系統，讓觀光客能透過這個系統理解他們在觀光時有興趣之農作物的狀態。



#### Where

本專案所假想之觀光農場內，或擁有相同農作物的場合中。



#### When

觀光客對觀光農場內某些農作物有興趣了解時。



#### Who

舉凡對農作物狀態有興趣或需了解其狀態者，可以是農民、此觀光農場之觀光客或管理者等等。



#### How

收集大量農作物之葉片照片，利用卷積神經網路訓練這些照片，以判斷觀光客有興趣之農作物的狀態，得知其是否健康或者屬於何種病態類別的知識。

## 1.2 預期成果

希望能透過所建構並訓練出的優良 CNN 神經網路模型，幫助在此觀光農場的觀光客，在體驗及觀察農作物的同時，能辨別其所觀察到的農作物健康與否或者是為何種病態，進而獲取一些農作物上的知識。

## 2 文獻回顧

本章節探討了農作物葉片重要性的相關資料，及本次使用之研究方法 Convolutional Neural Networks, CNN。

### 2.1 卷積神經網路 (Convolutional Neural Networks, CNN)

卷積神經網路 (Convolutional Neural Network, CNN) 是一種前饋神經網路，它的人工神經元可以回應一部分覆蓋範圍內的周圍單元，對於大型圖像處理有出色表現。

一般在進行圖片辨識時，我們不會單純使用 ANN 或 DNN 這種全連接層的神經網路模型架構，因為這樣子做會有幾個問題：

(1) 在一般的圖片辨識問題中，事實上會有一些 pattern 可能會出現在圖片中的某個部位，且這樣的 pattern 可能由許多個鄰近像素構成，如果單純直接操作全連接層的神經網路模型架構會破壞這樣的 pattern 結構。

(2) 全連接層搭配高像素的圖片，會讓整個計算成本大幅增加。

基於上面幾個理由便衍伸出 Convolutional Neural Network (CNN) 卷積神經網路來進行圖像辨識。

整個 CNN 結構主要分成幾個部分：卷積層 (Convolution layer)、池化層 (Pooling layer) 以及最後一個全連接層 (Fully Connected layer)。

卷積層主要是由許多不同的 kernel 在輸入圖片上進行卷積運算，而卷積其實就是兩個步驟組成的運算：滑動+內積，利用 filter 在輸入圖片上滑動並且持續進行矩陣內積，卷積後得到的圖片我們稱之為 feature map。卷積神經網路由一個或多個卷積層和頂端的全連通層 (對應經典的神經網路) 組成，同時也包括關聯權重和池化層 (pooling layer)。這一結構使得卷積神經網路能夠利用輸入資料的二維結構。與其他深度學習結構相比，卷積神經網路在圖像和語音辨識方面能夠給出更好的結果。這一模型也可以使用反向傳播演算法進行訓練。相比較其他深度、前饋神經網路，卷積神經網路需要考量的參數更少，使之成為一種頗具吸引力的深度學習結構。

## 2.2 葉片的重要性

葉是高等植物的營養器官，側邊發育自植物的莖的葉原基。葉內含有葉綠體，是植物進行光合作用的主要場所，同時，植物的蒸散作用是通過葉的氣孔實現的，而葉的形態也是多種多樣的，從非常原始的針狀小型葉發展出各種各樣形態的大型葉。有些葉，已不再行使葉的功能 (光合作用和蒸騰作用)，而成為花瓣，花刺，葉卷鬚和保護幼葉的牙鱗。

葉片，是作物進行光合作用的主要器官，葉綠體是進行光合作用的細胞器，而葉綠素是葉綠體中的一個色素，它受光照強度的影響。在光照不足的情況下不利於葉綠素的生物合成，作物葉片缺乏葉綠素時，可見黃化現象。所以，在我們栽種農作物密度過大時，遮擋嚴重受光不足，常會引起葉片變黃。這對指導我們種植，和判斷作物的缺素，有很重要的意義。

所以說，隨時觀測葉片，識別葉片的狀態對於農民來說是非常重要的，能否友好的農作物收成，其過程中的葉片健康或病態反映給農民的資訊，即能及時提供給農民做相應的措施，而了解有關於葉片健康或病態的資訊，相信對於觀光農場中觀光客來說，無疑也是一種收穫。

## 3 研究架構或方法

本次研究其整體執行流程大致可分成以下六個步驟：

- (1) 資料收集
- (2) 資料前處理

- (3) 模型設定
- (4) 訓練集訓練
- (5) 測試集測試
- (6) 輸出結果



其中在第三步會不斷嘗試不同的模型設定，以訓練出一個具有一定程度準確率的模型，以提供具有可信力的系統給觀光客。

### 3.1 資料前處理(Data-preprocessing)

#### (1) 資料集分類及劃分

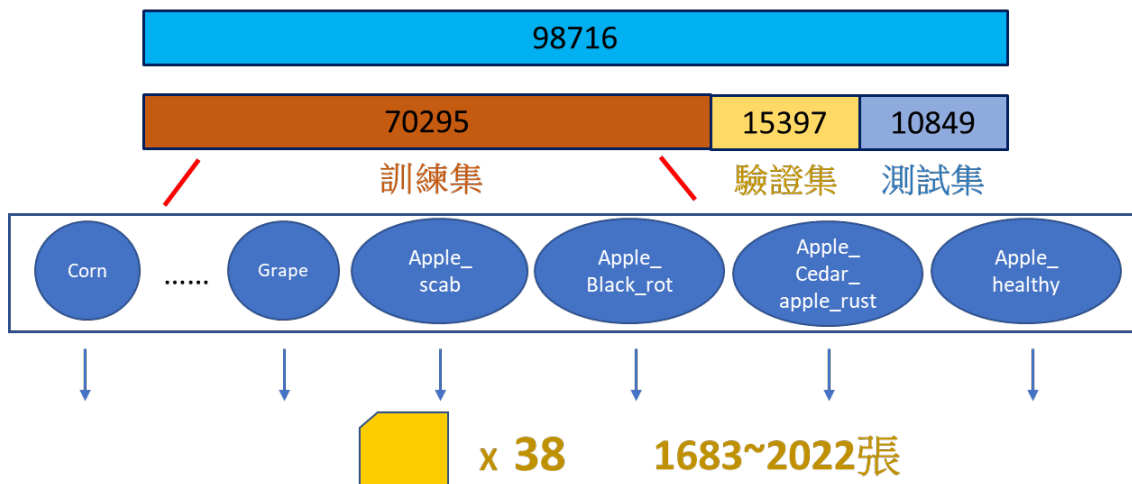
由 Kaggle 公開數據集中取得農作物葉片圖像資料集，包含了 13 種不同的農作物，其中每種作物的狀態又可分為健康及幾種可能的病態性質，因此每種作物又可分為若干類別，而此 13 種作物共包含了 38 種類別，依類別分別分成 29 個資料夾。

(總共 98,716 張照片)

訓練集 70295 張

驗證集 15397 張

測試集 10849 張)



## (2) ImageDataGenerator

使用 ImageDataGenerator 生成更多樣的圖像

(1) rescale=1./255 :

將圖像做歸一化，使其像素值從 [0-255] 縮放到 [0-1]

(2) width\_shift\_range=0.2

圖片寬度的某個比例，生成更多圖像時圖片水平偏移的幅度

(3) height\_shift\_range=0.2,

圖片高度的某個比例，生成更多圖像時圖片垂直變換的幅度

```
83 from keras.preprocessing.image import ImageDataGenerator
84
85 train_datagen = ImageDataGenerator(rescale=1./255,
86                                   shear_range=0.2,
87                                   zoom_range=0.2,
88                                   width_shift_range=0.2,
89                                   height_shift_range=0.2,
90                                   fill_mode='nearest')
```

## (3) flow\_from\_directory

使用 flow\_from\_directory 處理每張圖像

(1) target\_size=(224, 224)

所有的圖像將被調整到 224\*224 的尺寸

(2) color\_mode='rgb'

圖像轉換成 1 或 3 個顏色通道

```

103 training_set = train_datagen.flow_from_directory(train_dir,
104                                             target_size=(224, 224),
105                                             color_mode='rgb',
106                                             classes=None,
107                                             batch_size=batch_size,
108                                             class_mode='categorical')
109
110 valid_set = valid_datagen.flow_from_directory(valid_dir,
111                                             target_size=(224, 224),
112                                             color_mode='rgb',
113                                             classes=None,
114                                             batch_size=batch_size,
115                                             class_mode='categorical')

```

#### (4) Labeling & one-hot encoding\

讀取各個資料夾，為同類別資料夾內的圖片進行 labeling，其值為 0-37 共 38 種，並進行 2D one-hot encoding

(1) classes=None

(2) class\_mode='categorical'

(3) class\_indices

```

103 training_set = train_datagen.flow_from_directory(train_dir,
104                                             target_size=(224, 224),
105                                             color_mode='rgb',
106                                             classes=None,
107                                             batch_size=batch_size,
108                                             class_mode='categorical')
109
110 valid_set = valid_datagen.flow_from_directory(valid_dir,
111                                             target_size=(224, 224),
112                                             color_mode='rgb',
113                                             classes=None,
114                                             batch_size=batch_size,
115                                             class_mode='categorical')

```

```

In [27]: class_dict = training_set.class_indices
...: print(class_dict)
{'Apple__Apple_scab': 0, 'Apple__Black_rot': 1,
'Apple__Cedar_apple_rust': 2, 'Apple__healthy': 3, 'Blueberry__healthy':
4, 'Cherry_(including_sour)__Powdery_mildew': 5,
'Cherry_(including_sour)__healthy': 6, 'Corn_(maize)__Cercospora_leaf_spot
Gray_leaf_spot': 7, 'Corn_(maize)__Common_rust': 8,
'Corn_(maize)__Northern_Leaf_Blight': 9, 'Corn_(maize)__healthy': 10,
'Grape__Black_rot': 11, 'Grape__Esca_(Black_Measles)': 12,
'Grape__Leaf_blight_(Isariopsis_Leaf_Spot)': 13, 'Grape__healthy': 14,
'Orange__Haunglongbing_(Citrus_greening)': 15, 'Peach__Bacterial_spot':
16, 'Peach__healthy': 17, 'Pepper,_bell__Bacterial_spot': 18,
'Pepper,_bell__healthy': 19, 'Potato__Early_blight': 20,
'Potato__Late_blight': 21, 'Potato__healthy': 22, 'Raspberry__healthy':
23, 'Soybean__healthy': 24, 'Squash__Powdery_mildew': 25,
'Strawberry__Leaf_scorch': 26, 'Strawberry__healthy': 27,
'Tomato__Bacterial_spot': 28, 'Tomato__Early_blight': 29,
'Tomato__Late_blight': 30, 'Tomato__Leaf_Mold': 31,
'Tomato__Septoria_leaf_spot': 32, 'Tomato__Spider_mites_Two-
spotted_spider_mite': 33, 'Tomato__Target_Spot': 34,
'Tomato__Tomato_Yellow_Leaf_Curl_Virus': 35,
'Tomato__Tomato_mosaic_virus': 36, 'Tomato__healthy': 37}

```



### 3.2 初始模型設定

初始模型(Model 1)設定包含輸入層在那，總共 24 層，卷積與池化層用綠底表示，而全連接層用藍底來表示。



而 Model1 的設置如下：

	Loss	激活函數	最後一層 全連接層 激活函數	優化器	Epoch
<b>Model 1</b>	categorical	relu	softmax	SGD	10

```
20 # Initializing the CNN
21 classifier = Sequential()
22
23 # Convolution Step 1
24 classifier.add(Convolution2D(96, 11, strides = (4, 4), padding = 'valid', input_shape=(224, 224, 3), activation = 'relu'))
25 # Max Pooling Step 1
26 classifier.add(MaxPooling2D(pool_size = (2, 2), strides = (2, 2), padding = 'valid'))
27 classifier.add(BatchNormalization())
28 # Convolution Step 2
29 classifier.add(Convolution2D(256, 11, strides = (1, 1), padding='valid', activation = 'relu'))
30 # Max Pooling Step 2
31 classifier.add(MaxPooling2D(pool_size = (2, 2), strides = (2, 2), padding='valid'))
32 classifier.add(BatchNormalization())
33 # Convolution Step 3
34 classifier.add(Convolution2D(384, 3, strides = (1, 1), padding='valid', activation = 'relu'))
35 classifier.add(BatchNormalization())
36 # Convolution Step 4
37 classifier.add(Convolution2D(384, 3, strides = (1, 1), padding='valid', activation = 'relu'))
38 classifier.add(BatchNormalization())
39 # Convolution Step 5
40 classifier.add(Convolution2D(256, 3, strides=(1,1), padding='valid', activation = 'relu'))
41 # Max Pooling Step 3
42 classifier.add(MaxPooling2D(pool_size = (2, 2), strides = (2, 2), padding = 'valid'))
43 classifier.add(BatchNormalization())
44
45 # Flattening Step
46 classifier.add(Flatten())
47
48 # Full Connection Step
49 classifier.add(Dense(units = 4096, activation = 'relu'))
50 classifier.add(Dropout(0.4))
51 classifier.add(BatchNormalization())
52 classifier.add(Dense(units = 4096, activation = 'relu'))
53 classifier.add(Dropout(0.4))
54 classifier.add(BatchNormalization())
55 classifier.add(Dense(units = 1000, activation = 'relu'))
56 classifier.add(Dropout(0.2))
57 classifier.add(BatchNormalization())
58 classifier.add(Dense(units = 38, activation = 'softmax'))
59
60 classifier.summary()
--

80 # Compiling the Model
81 from keras import optimizers
82 classifier.compile(optimizer= 'adam',
83                   loss='categorical_crossentropy',
84                   metrics=['accuracy'])
--

80 # Compiling the Model
81 from keras import optimizers
82 classifier.compile(optimizer=optimizers.SGD(lr=0.001, momentum=0.9, decay=0.005),
83                   loss='categorical_crossentropy',
84                   metrics=['accuracy'])
--
```


## 4 模型結果與調整

### 4.1 初始模型結果

初始模型的結果，經過了 10 次迭代之後，測試集準確率為 43.91%。由圖可看出訓練集集、驗證集皆保有上升趨勢，因此保存 Model 1 以提供給 Model 2 繼續訓練。



	Loss	激活函數	最後一層 全連接層 激活函數	優化器	Epoch
<b>Model 1</b>	categorical	relu	softmax	SGD	10



```
361/361 [=====] - 926s 3s/step
```

```
Test_Accuracy: 43.91%
```

```
155 #saving model
```

```
156 filepath="model_1"
```

```
157 classifier.save(filepath)
```

## 4.2 模型調整及優化

### 4.2.1 Model 2

將 model 1 的模型權重讀進去，並繼續訓練，一樣再次保存模型給下次模型使用，最後測試集準確率為 60.10%。

```
62 classifier.load_weights('C:/Users/qaz74/Desktop/project3/model_1')
```

	Loss	激活函數	最後一層 全連接層 激活函數	優化器	Epoch
<b>Model 2</b>	categorical	relu	softmax	SGD	<b>25</b>

Epoch 1/25  
274/274 [=====] - 1852s 7s/step - loss: 1.2402 - accuracy: 0.6259 - val\_loss: 2.9623 - val\_accuracy: 0.4018

Epoch 2/25  
274/274 [=====] - 1749s 6s/step - loss: 1.0697 - accuracy: 0.6661 - val\_loss: 3.2971 - val\_accuracy: 0.4199

Epoch 3/25  
274/274 [=====] - 1786s 7s/step - loss: 1.0175 - accuracy: 0.6777 - val\_loss: 2.6515 - val\_accuracy: 0.4007

Epoch 4/25  
274/274 [=====] - 1826s 7s/step - loss: 0.9956 - accuracy: 0.6833 - val\_loss: 3.1368 - val\_accuracy: 0.4071

Epoch 5/25  
274/274 [=====] - 1778s 6s/step - loss: 0.9698 - accuracy: 0.6914 - val\_loss: 3.0172 - val\_accuracy: 0.3757

Epoch 6/25  
274/274 [=====] - 1797s 7s/step - loss: 0.9508 - accuracy: 0.6957 - val\_loss: 2.5361 - val\_accuracy: 0.4231

Epoch 7/25  
274/274 [=====] - 1803s 7s/step - loss: 0.9333 - accuracy: 0.7002 - val\_loss: 2.7280 - val\_accuracy: 0.4301

Epoch 8/25  
274/274 [=====] - 1741s 6s/step - loss: 0.9267 - accuracy: 0.7027 - val\_loss: 2.7332 - val\_accuracy: 0.4077

accuracy: 0.7175 - val\_loss: 3.1355 - val\_accuracy: 0.4062

Epoch 18/25  
274/274 [=====] - 1664s 6s/step - loss: 0.8639 - accuracy: 0.7218 - val\_loss: 2.7810 - val\_accuracy: 0.4222

Epoch 19/25  
274/274 [=====] - 1649s 6s/step - loss: 0.8677 - accuracy: 0.7187 - val\_loss: 2.7626 - val\_accuracy: 0.4241

Epoch 20/25  
274/274 [=====] - 1623s 6s/step - loss: 0.8618 - accuracy: 0.7208 - val\_loss: 3.0297 - val\_accuracy: 0.4020


Epoch 21/25  
274/274 [=====] - 1689s 6s/step - loss: 0.8533 - accuracy: 0.7248 - val\_loss: 3.1380 - val\_accuracy: 0.3937

Epoch 22/25  
274/274 [=====] - 1647s 6s/step - loss: 0.8543 - accuracy: 0.7236 - val\_loss: 2.5496 - val\_accuracy: 0.4160

Epoch 23/25  
274/274 [=====] - 1641s 6s/step - loss: 0.8393 - accuracy: 0.7271 - val\_loss: 3.3058 - val\_accuracy: 0.4105

Epoch 24/25  
274/274 [=====] - 1674s 6s/step - loss: 0.8476 - accuracy: 0.7254 - val\_loss: 2.9179 - val\_accuracy: 0.4216

Epoch 25/25  
274/274 [=====] - 1651s 6s/step - loss: 0.8400 - accuracy: 0.7269 - val\_loss: 3.0704 - val\_accuracy: 0.4124



```
361/361 [=====] - 926s 3s/step
```

```
Test_Accuracy: 69.10%
```

```
155 #saving model
156 filepath="model_2"
157 classifier.save(filepath)
```

#### 4.2.2 Model 3


由 Model2 可看出模型開始慢慢在收斂，因此嘗試調整優化器為 adam 尋求更好的解，將 model 2 的模型權重讀進去，並繼續訓練，最後測試集準確率為 80.50%。

```
62 classifier.load_weights('C:/Users/qaz74/Desktop/project3/model_2')
```

	Loss	激活函數	最後一層 全連接層 激活函數	優化器	Epoch
<b>Model 3</b>	categorical	relu	softmax	adam	25

```
Epoch 1/25
274/274 [=====] - 2018s 7s/step - loss: 0.7015 - accuracy: 0.7804 -
val_loss: 0.9415 - val_accuracy: 0.7784
Epoch 2/25
274/274 [=====] - 2017s 7s/step - loss: 0.6058 - accuracy: 0.8042 -
val_loss: 0.7185 - val_accuracy: 0.7695
Epoch 3/25
274/274 [=====] - 2041s 7s/step - loss: 0.5739 - accuracy: 0.8155 -
val_loss: 0.7353 - val_accuracy: 0.7914
Epoch 4/25
274/274 [=====] - 2028s 7s/step - loss: 0.5519 - accuracy: 0.8199 -
val_loss: 0.6906 - val_accuracy: 0.7868
Epoch 5/25
274/274 [=====] - 2019s 7s/step - loss: 0.5374 - accuracy: 0.8236 -
val_loss: 0.6165 - val_accuracy: 0.7847
Epoch 6/25
274/274 [=====] - 2019s 7s/step - loss: 0.5288 - accuracy: 0.8276 -
val_loss: 0.7519 - val_accuracy: 0.7760
Epoch 7/25
274/274 [=====] - 2024s 7s/step - loss: 0.5140 - accuracy: 0.8314 -
val_loss: 0.8420 - val_accuracy: 0.7844
Epoch 8/25
274/274 [=====] - 2060s 8s/step - loss: 0.5111 - accuracy: 0.8320 -
val_loss: 0.8329 - val_accuracy: 0.7893
Epoch 9/25
274/274 [=====] - 2043s 7s/step - loss: 0.4999 - accuracy: 0.8348 -
val_loss: 0.7863 - val_accuracy: 0.7766
Epoch 10/25
274/274 [=====] - 2050s 7s/step - loss: 0.4957 - accuracy: 0.8361 -
val_loss: 0.5406 - val_accuracy: 0.8005
Epoch 11/25
274/274 [=====] - 2046s 7s/step - loss: 0.4948 - accuracy: 0.8379 -
val_loss: 0.6910 - val_accuracy: 0.7830

Epoch 15/25
274/274 [=====] - 1951s 7s/step - loss: 0.4775 - accuracy: 0.8412 -
val_loss: 0.7685 - val_accuracy: 0.7885
Epoch 16/25
274/274 [=====] - 1955s 7s/step - loss: 0.4653 - accuracy: 0.8476 -
val_loss: 0.7344 - val_accuracy: 0.7970
Epoch 17/25
274/274 [=====] - 1985s 7s/step - loss: 0.4686 - accuracy: 0.8437 -
val_loss: 0.6843 - val_accuracy: 0.8001
Epoch 18/25
274/274 [=====] - 1973s 7s/step - loss: 0.4680 - accuracy: 0.8450 -
val_loss: 0.6433 - val_accuracy: 0.7885
Epoch 19/25
274/274 [=====] - 1967s 7s/step - loss: 0.4674 - accuracy: 0.8452 -
val_loss: 0.7827 - val_accuracy: 0.7938
Epoch 20/25
274/274 [=====] - 2036s 7s/step - loss: 0.4565 - accuracy: 0.8487 -
val_loss: 0.8171 - val_accuracy: 0.7949
Epoch 21/25
274/274 [=====] - 2037s 7s/step - loss: 0.4631 - accuracy: 0.8467 -
val_loss: 0.6373 - val_accuracy: 0.7877
Epoch 22/25
274/274 [=====] - 1982s 7s/step - loss: 0.4619 - accuracy: 0.8473 -
val_loss: 0.7672 - val_accuracy: 0.7894
Epoch 23/25
274/274 [=====] - 1966s 7s/step - loss: 0.4510 - accuracy: 0.8473 -
val_loss: 0.5738 - val_accuracy: 0.8015
Epoch 24/25
274/274 [=====] - 1956s 7s/step - loss: 0.4484 - accuracy: 0.8513 -
val_loss: 0.6403 - val_accuracy: 0.7918
Epoch 25/25
274/274 [=====] - 1960s 7s/step - loss: 0.4486 - accuracy: 0.8501 -
val_loss: 0.5826 - val_accuracy: 0.7949
```



```
361/361 [=====] - 1761s 5s/step
Test_Accuracy: 80.50%
```

### 4.2.3 Model 4

嘗試調整優化器為 adam 尋求更好的解，將 model 2 的模型權重讀進去，並繼續訓練，最後測試集準確率為 99.03%。

```
62 classifier.load_weights('C:/Users/qaz74/Desktop/project3/model_2')
```

	Loss	激活函數	最後一層全連接層激活函數	優化器	Epoch
<b>Model 4</b>	binary	relu	sigmoid	adam	25

```
Epoch 1/25
274/274 [=====] - 893s 3s/step - loss: 0.2028 - accuracy: 0.9332 - val_loss: 0.1096 - val_accuracy: 0.9711
Epoch 2/25
274/274 [=====] - 831s 3s/step - loss: 0.0497 - accuracy: 0.9832 - val_loss: 0.0892 - val_accuracy: 0.9759
Epoch 3/25
274/274 [=====] - 654s 2s/step - loss: 0.0309 - accuracy: 0.9891 - val_loss: 0.0876 - val_accuracy: 0.9767
Epoch 4/25
274/274 [=====] - 608s 2s/step - loss: 0.0226 - accuracy: 0.9920 - val_loss: 0.0391 - val_accuracy: 0.9869
Epoch 5/25
274/274 [=====] - 605s 2s/step - loss: 0.0176 - accuracy: 0.9937 - val_loss: 0.0808 - val_accuracy: 0.9787
Epoch 6/25
274/274 [=====] - 603s 2s/step - loss: 0.0151 - accuracy: 0.9947 - val_loss: 0.0817 - val_accuracy: 0.9823
```



```
274/274 [=====] - 598s 2s/step - loss: 0.0054 - accuracy: 0.9981 - val_loss: 0.0408 - val_accuracy: 0.9893
Epoch 20/25
274/274 [=====] - 597s 2s/step - loss: 0.0054 - accuracy: 0.9982 - val_loss: 0.0063 - val_accuracy: 0.9976
Epoch 21/25
274/274 [=====] - 598s 2s/step - loss: 0.0048 - accuracy: 0.9983 - val_loss: 0.0294 - val_accuracy: 0.9916
Epoch 22/25
274/274 [=====] - 826s 3s/step - loss: 0.0047 - accuracy: 0.9983 - val_loss: 0.0103 - val_accuracy: 0.9957
Epoch 23/25
274/274 [=====] - 603s 2s/step - loss: 0.0048 - accuracy: 0.9984 - val_loss: 0.0146 - val_accuracy: 0.9961
Epoch 24/25
274/274 [=====] - 591s 2s/step - loss: 0.0046 - accuracy: 0.9984 - val_loss: 0.0113 - val_accuracy: 0.9955
Epoch 25/25
274/274 [=====] - 597s 2s/step - loss: 0.0043 - accuracy: 0.9985 - val_loss: 0.0432 - val_accuracy: 0.9885
```



```
361/361 [=====] - 124s 344ms/step
Test_Accuracy: 99.03%
```

#### 4.2.4 Model 5

套用 Model 4 的模型設置在 Model 1 上，發現結果也可以直接達到非常高的準確率，其測試集的準確率為 97.48%

```
62 classifier.load_weights('C:/Users/qaz74/Desktop/project3/model_1')
```

```

Epoch 1/25
274/274 [=====] - 656s 2s/step - loss: 0.1962 - accuracy: 0.9344 - val_loss: 0.2735 - val_accuracy: 0.9733
Epoch 2/25
274/274 [=====] - 844s 3s/step - loss: 0.0519 - accuracy: 0.9831 - val_loss: 0.1168 - val_accuracy: 0.9788
Epoch 3/25
274/274 [=====] - 615s 2s/step - loss: 0.0343 - accuracy: 0.9885 - val_loss: 0.0455 - val_accuracy: 0.9850
Epoch 4/25
274/274 [=====] - 612s 2s/step - loss: 0.0243 - accuracy: 0.9914 - val_loss: 0.1574 - val_accuracy: 0.9669
Epoch 5/25
274/274 [=====] - 610s 2s/step - loss: 0.0193 - accuracy: 0.9932 - val_loss: 0.1807 - val_accuracy: 0.9676
Epoch 6/25
274/274 [=====] - 608s 2s/step - loss: 0.0162 - accuracy: 0.9942 - val_loss: 0.1230 - val_accuracy: 0.9721
Epoch 7/25
274/274 [=====] - 605s 2s/step - loss: 0.0140 - accuracy: 0.9951 - val_loss: 0.0424 - val_accuracy: 0.9878
Epoch 8/25
274/274 [=====] - 604s 2s/step - loss: 0.0124 - accuracy: 0.9956 - val_loss: 0.0312 - val_accuracy: 0.9888
Epoch 9/25
274/274 [=====] - 601s 2s/step - loss: 0.0112 - accuracy: 0.9961 - val_loss: 0.0204 - val_accuracy: 0.9935
Epoch 10/25
274/274 [=====] - 602s 2s/step - loss: 0.0104 - accuracy: 0.9963 - val_loss: 0.0343 - val_accuracy: 0.9906
Epoch 11/25
274/274 [=====] - 598s 2s/step - loss: 0.0092 - accuracy: 0.9968 - val_loss: 0.0742 - val_accuracy: 0.9816
Epoch 12/25
274/274 [=====] - 590s 2s/step - loss: 0.0088 - accuracy: 0.9969 - val_loss: 0.1345 - val_accuracy: 0.9717
Epoch 15/25
274/274 [=====] - 593s 2s/step - loss: 0.0071 - accuracy: 0.9975 - val_loss: 0.0529 - val_accuracy: 0.9858
Epoch 16/25
274/274 [=====] - 593s 2s/step - loss: 0.0067 - accuracy: 0.9977 - val_loss: 0.0261 - val_accuracy: 0.9906
Epoch 17/25
274/274 [=====] - 593s 2s/step - loss: 0.0062 - accuracy: 0.9978 - val_loss: 0.0505 - val_accuracy: 0.9871
Epoch 18/25
274/274 [=====] - 593s 2s/step - loss: 0.0061 - accuracy: 0.9979 - val_loss: 0.0789 - val_accuracy: 0.9837
Epoch 19/25
274/274 [=====] - 594s 2s/step - loss: 0.0060 - accuracy: 0.9979 - val_loss: 0.0215 - val_accuracy: 0.9930
Epoch 20/25
274/274 [=====] - 593s 2s/step - loss: 0.0053 - accuracy: 0.9981 - val_loss: 0.0129 - val_accuracy: 0.9950
Epoch 21/25
274/274 [=====] - 593s 2s/step - loss: 0.0053 - accuracy: 0.9982 - val_loss: 0.0271 - val_accuracy: 0.9917
Epoch 22/25
274/274 [=====] - 593s 2s/step - loss: 0.0053 - accuracy: 0.9982 - val_loss: 0.1791 - val_accuracy: 0.9711
Epoch 23/25
274/274 [=====] - 593s 2s/step - loss: 0.0051 - accuracy: 0.9982 - val_loss: 0.0280 - val_accuracy: 0.9936
Epoch 24/25
274/274 [=====] - 597s 2s/step - loss: 0.0047 - accuracy: 0.9983 - val_loss: 0.0936 - val_accuracy: 0.9791
Epoch 25/25
274/274 [=====] - 594s 2s/step - loss: 0.0048 - accuracy: 0.9983 - val_loss: 0.0329 - val_accuracy: 0.9910

```




```
361/361 [=====] - 1728s 5s/step  
Test_Accuracy: 97.48%
```

## 5 結論與未來展望

### 5.1 結論

#### 1) 準確率大幅提升

	Loss	激活函數	最後一層全連接層激活函數	優化器	Epoch	Test Accuracy
Model 1	categorical	<u>relu</u>	<u>softmax</u>	SGD	10	43.91 %
Model 2	categorical	<u>relu</u>	<u>softmax</u>	SGD	25	69.10 %
Model 3	categorical	<u>relu</u>	<u>softmax</u>	<u>adam</u>	25	80.05 %
Model 4	binary	<u>relu</u>	<u>sigmoid</u>	<u>adam</u>	25	99.03 %



- 2) 為觀光客在此觀光農場提供可信的辨識系統
- 3) 為後續系統建立奠定基礎

### 5.2 未來展望

- 1) 加入更多圖像
- 2) 加入更多物種

目前只有 13 種的農作物，加入更多的物種以因應更大規模的觀光農場。

- 3) 開發不同適用範圍的系統

農作物的種植類型，可能會因國家、氣候……等等因素，而有不同區域性分布的種植類型，可針對此開發專屬某區域的系統。

### 誌謝

感謝全體 IIE 師生人員

### 參考資料

<https://hackmd.io/@allen108108/rkn-oVGA4>

<https://zh.wikipedia.org/wiki/%E5%8D%B7%E7%A7%AF%E7%A5%9E%E7%BB%8F%E7%BD%91%E7%BB%9C>

<https://zh.wikipedia.org/wiki/%E8%91%89>

<https://kknews.cc/agriculture/vyqvjq.html>