



第 7 週 - 機器學習-圖片辨識

# 大綱

Outlines

01



Convolutional Neural Network (CNN)、loss function

02



使用 keras 搭建 CNN

03



實作：建置資料集

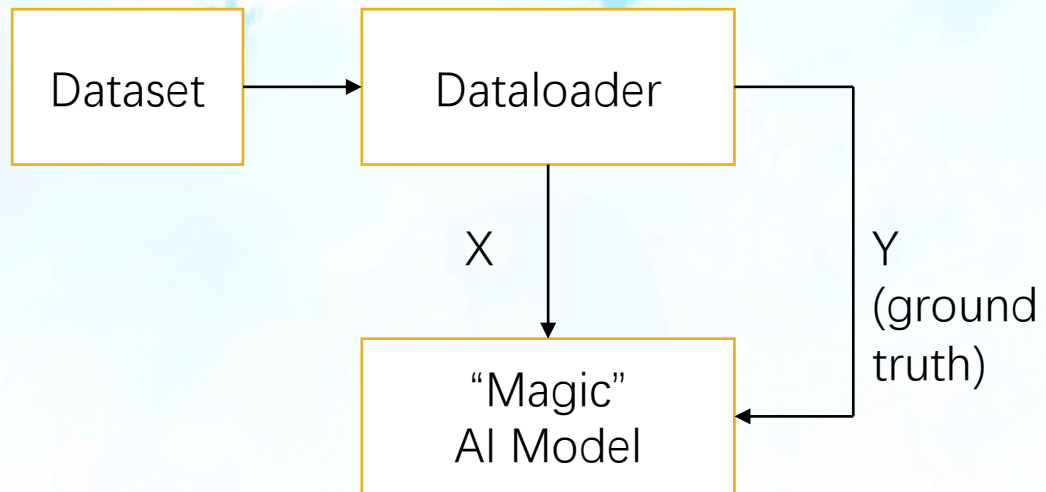


01

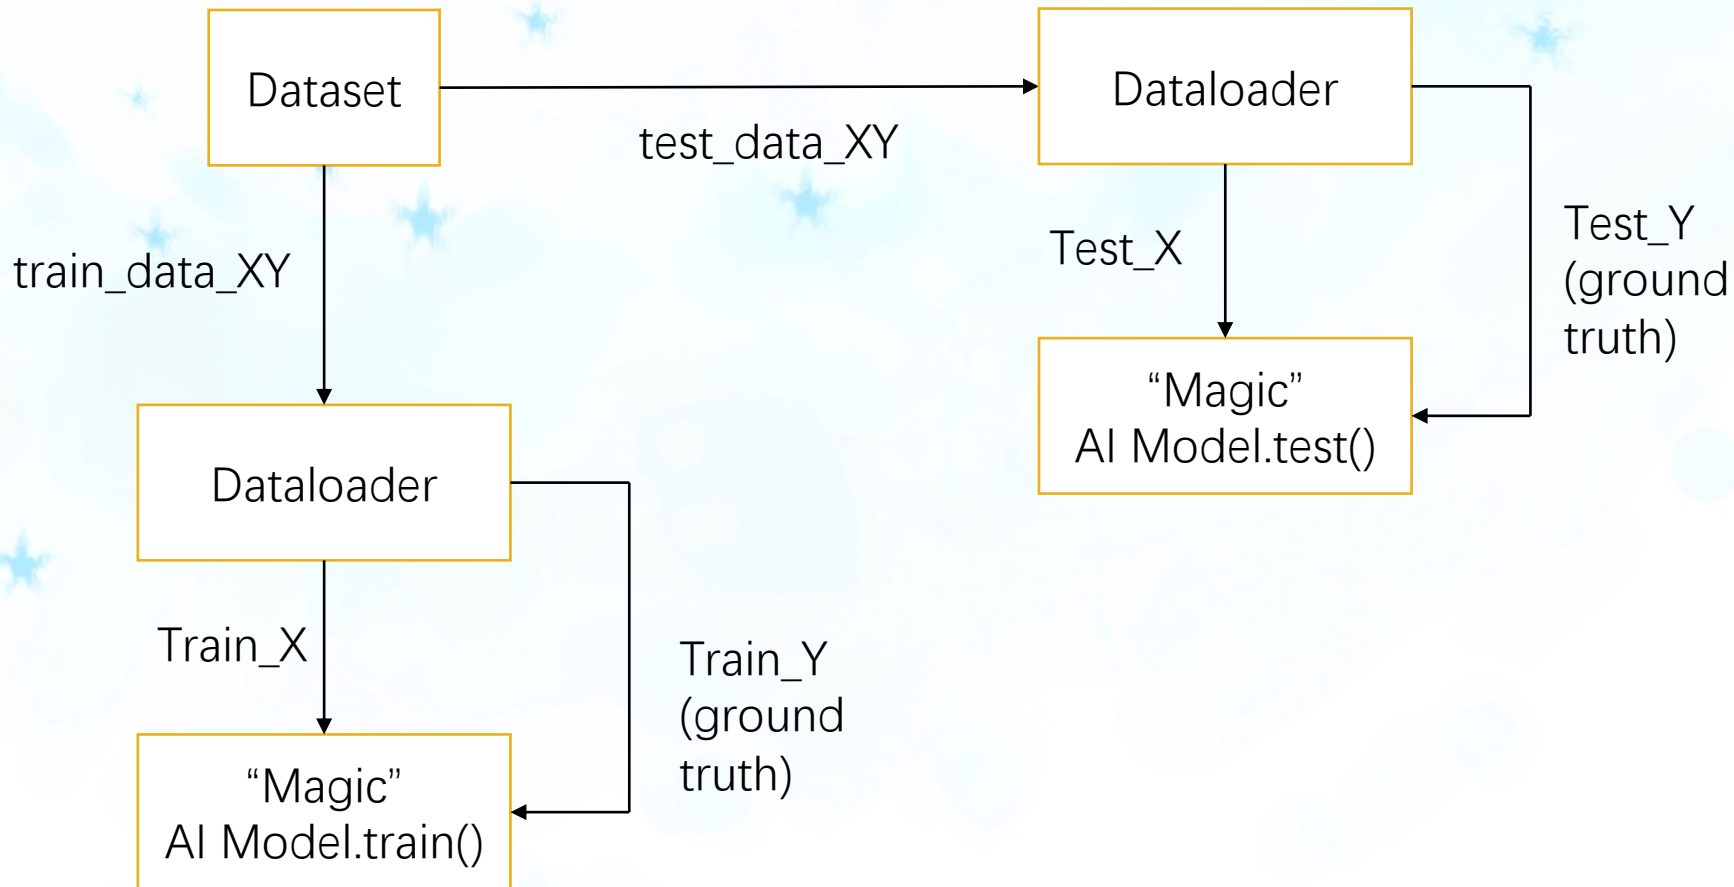
# Convolutional Neural Network (CNN)

來源：[魔法陣系列] Convolutional Neural Network ( CNN )  
之術式解析

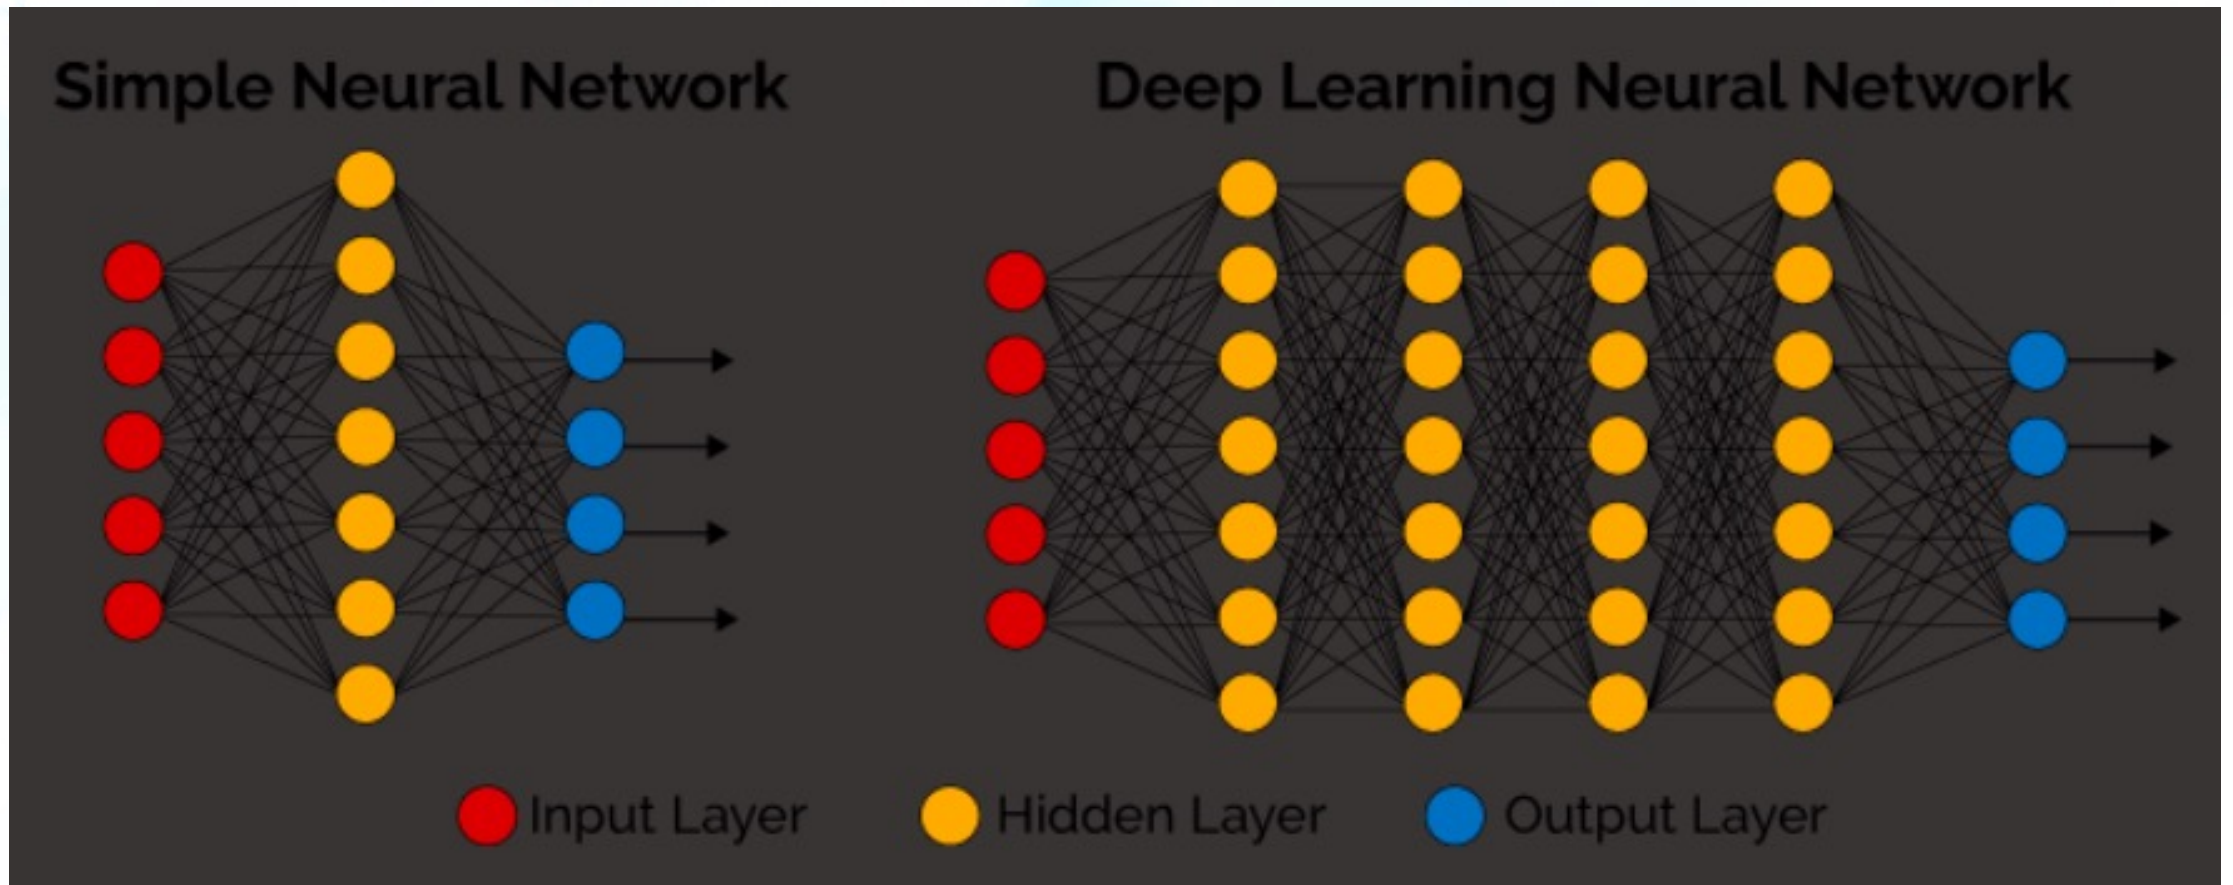
# Training process



# Training process



# Convolutional Neural Network




# Convolutional Neural Network

- CNN 主要由下列概念所組成：
  1. Convolution Operation
  2. Pooling
  3. Fully Connected Networks
  4. Activation

# 1. Convolution Operation


- 神經網絡隨機生成 Kernel ( 又稱 Filter ) 來抓取不同的特徵，將特徵存入 feature maps 中，再透過訓練決定哪些類型是重要的。Filter 在過程中可將圖片變小，使得圖片能夠更容易以及快速被神經網絡處理。





# 在這過程中是否會遺失掉訊息？

- 答案：會的。
- 不過就如同前面探討的圖片，實際上我們在看圖時不會每個 pixel 都看，例如可能只看眼睛、鼻子等特徵（feature），而這些特徵被保存在 feature map 中



# Filter 抓取特徵

Sharpen

0	0	0	0	0
0	0	-1	0	0
0	-1	5	-1	0
0	0	-1	0	0
0	0	0	0	0



Blur


0	0	0	0	0
0	1	1	1	0
0	1	1	1	0
0	1	1	1	0
0	0	0	0	0



## 2. Pooling


- 電腦不如人類聰明，同一張圖片在不同的角度、光線、質地、部位會使電腦判斷成是完全不同的特徵，如何讓神經網絡能夠聰明一點，彈性的處理這些特徵？這就是 Pooling 的功能了，它有不同種形式：

1. Mean pooling
2. Max pooling
3. Sum pooling



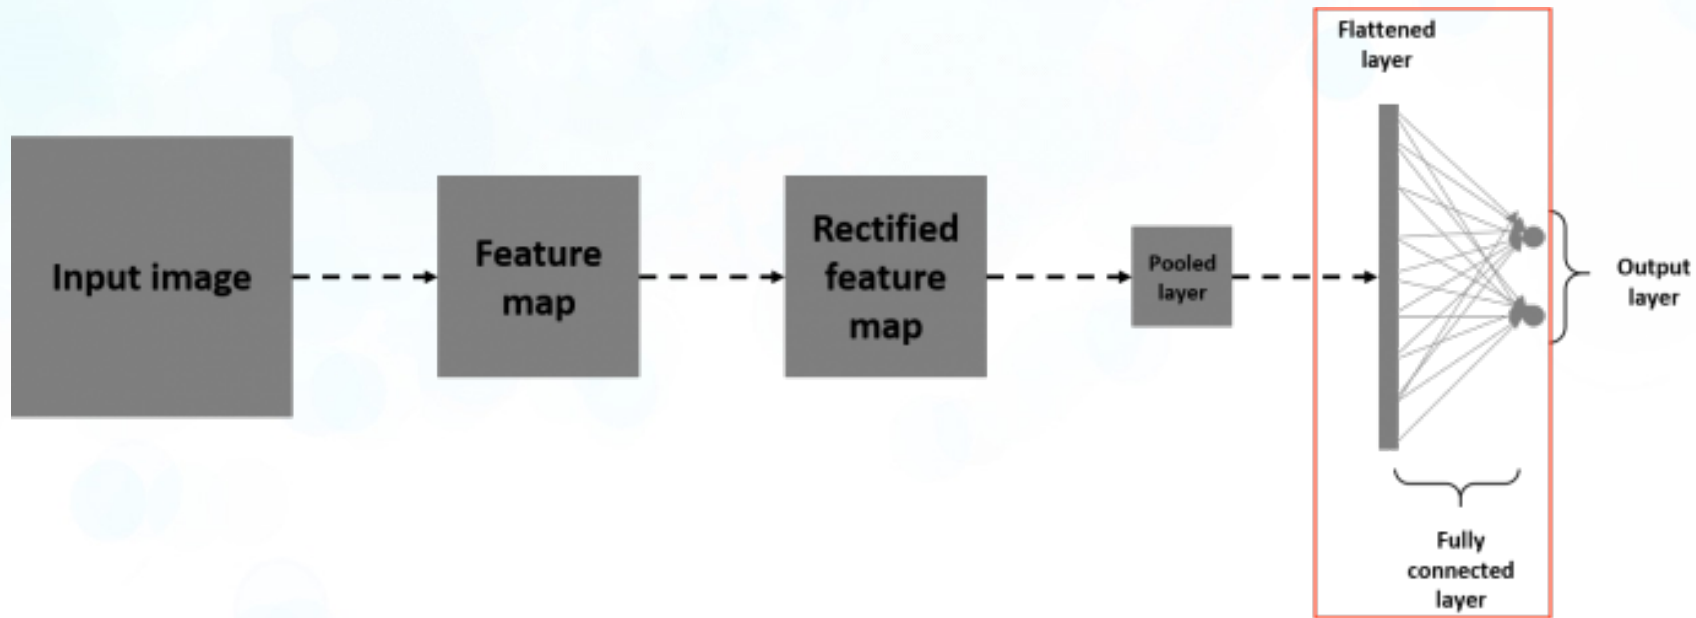
# Max pooling

- 如圖所示，抓出矩陣中的最大值。Max pooling 擁有去雜訊的功能，且當圖片平移的話也不會影響電腦的判斷。



# 3. Fully Connected Networks

- 這邊的全連接層將前一層的輸出做平坦化 ( Flatten ) 攤平合併到一個大向量內。




# 4. Activation

- 激活函數（ Activation functions ）對於人工神經網絡模型去學習、理解非常複雜和非線性的函數來說具有十分重要的作用。
- 它們將非線性特性引入到我們的NN中，使網路能理解更為複雜的事情。
- 常見的activation
  1. ReLU
  2. Sigmoid
  3. Softmax

# 1. ReLU

- 優點
  - 避免了梯度爆炸和梯度消失問題
  - 簡化計算過程
- 常應用於隱藏層

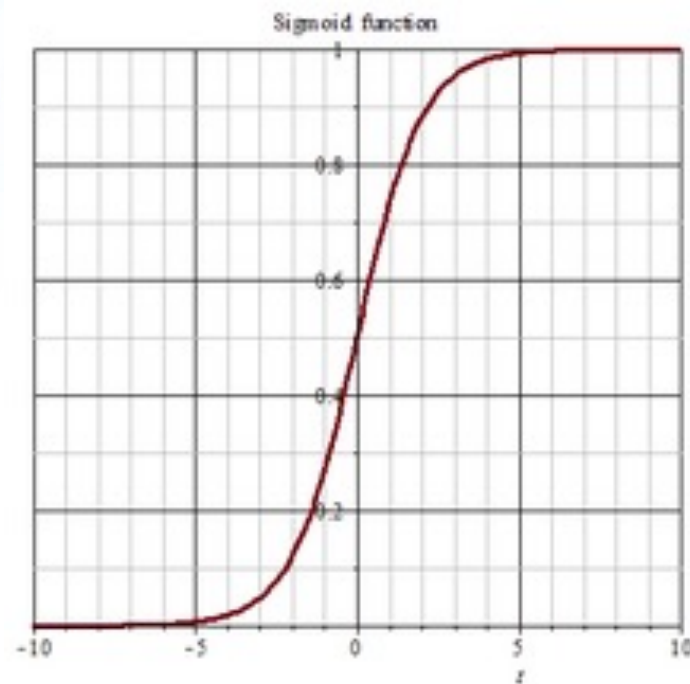
$$f(x) = \max(0, x)$$



## 2. Sigmoid

- 特性
  - 將輸出結果壓縮至0~1間
- 常應用於二元分類的輸出層

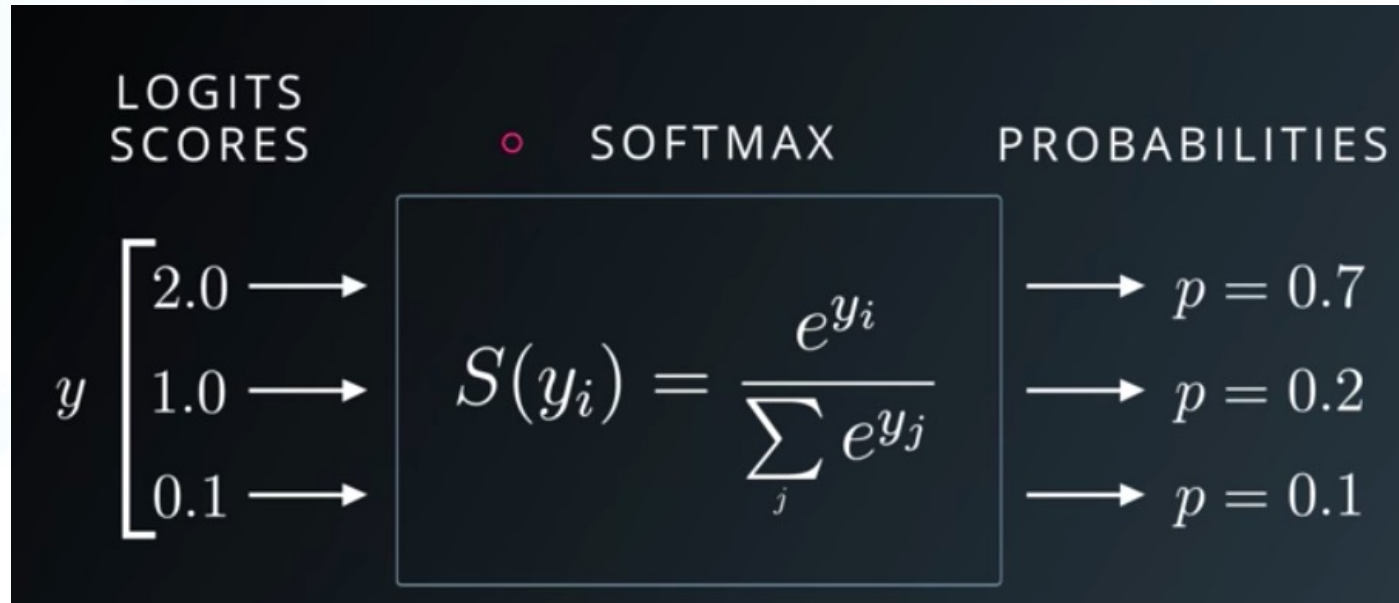
$$S(t) = \frac{1}{1 + e^{-t}}$$






# 3. Softmax

- 特性
  - 將輸出結果壓縮至0~1間，且所有結果相加為1
- 常應用於多元分類的輸出層



# Convolutional Neural Network

- 全連接層（Fully Connected Layer）起到分類任務的作用，而前面的層充當特徵提取器，整個 CNN 的流程如下圖：



# Math inference

- Softmax/Argmax
- Shannon' s entropy

$$H(\mathbf{x}) = \mathbb{E}_{\mathbf{x} \sim P} [I(x)] = -\mathbb{E}_{\mathbf{x} \sim P} [\log P(x)]$$

$$H(p) = E_{x \sim p}[-\ln p(x)]$$

$$\sum_i -p_i \ln p_i$$

# Math inference

- Softmax/Argmax
- Shannon's entropy
- Cross entropy loss

$$H(p, q) = E_{x \sim p}[-\ln q(x)]$$

$$\text{Loss} = -\frac{1}{\text{output size}} \sum_{i=1}^{\text{output size}} y_i \cdot \log \hat{y}_i + (1 - y_i) \cdot \log (1 - \hat{y}_i)$$




02

# 使用 keras 搭建 CNN

來源：[實戰系列] 使用 Keras 搭建一個 CNN 魔法陣（模型）

# 搭建CNN模型



[4]:


```
from keras.models import Sequential
from keras.layers import InputLayer, Conv2D, MaxPool2D, Flatten, Dense

model = Sequential()
model.add(InputLayer(input_shape = (128, 128, 3)))
model.add(Conv2D(32, 3, activation = 'relu'))
model.add(MaxPool2D(pool_size = (2, 2)))
model.add(Flatten())
model.add(Dense(128, activation = 'relu'))
model.add(Dense(1, activation = 'sigmoid'))
```

+ Code


+ Markdown

# Conv2D



```
model.add(Conv2D(32, 3, activation = 'relu'))
```

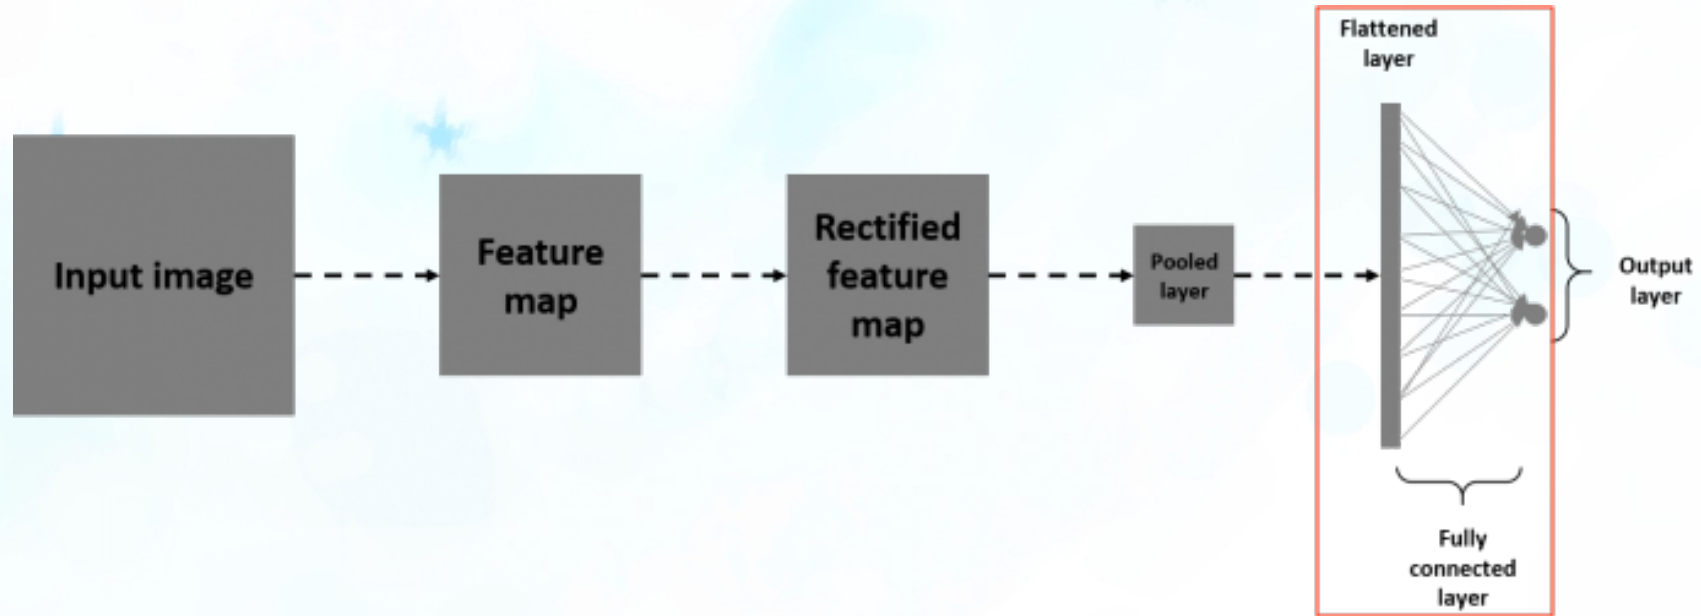
# MaxPool2D



```
model.add(MaxPool2D(pool_size = (2, 2)))
```



# Flatten & Dense



```
model.add(Flatten())  
model.add(Dense(128, activation = 'relu'))  
model.add(Dense(1, activation = 'sigmoid'))
```

# 編譯、訓練、應用CNN模型

```
model.compile(optimizer="rmsprop", loss='categorical_crossentropy', metrics=['acc', 'mse'])
model.fit(x=None, y=None, batch_size=None, epochs=1, callbacks=None,
         validation_split=0.0, validation_data=None, shuffle=True)
model.evaluate(x=None, y=None)
result = model.predict(x)
```



03

實作：建構CNN模型

# Customized Dataset

---

- Colab:  
[https://colab.research.google.com/drive/1rake9kGLVHNRfA3dDBhuZ9RI3k\\_fJrA7](https://colab.research.google.com/drive/1rake9kGLVHNRfA3dDBhuZ9RI3k_fJrA7)
- Google drive:  
[https://drive.google.com/file/d/1rake9kGLVHNRfA3dDBhuZ9RI3k\\_fJrA7/view?usp=sharing](https://drive.google.com/file/d/1rake9kGLVHNRfA3dDBhuZ9RI3k_fJrA7/view?usp=sharing)