

# AI技術研討

影像辨識AI與應用(電流故障頻譜故障偵測影像辨識等)  
(第一堂課)

中油5G AIoT 推動辦公室

王朝民

2026 年 03 月 24 日

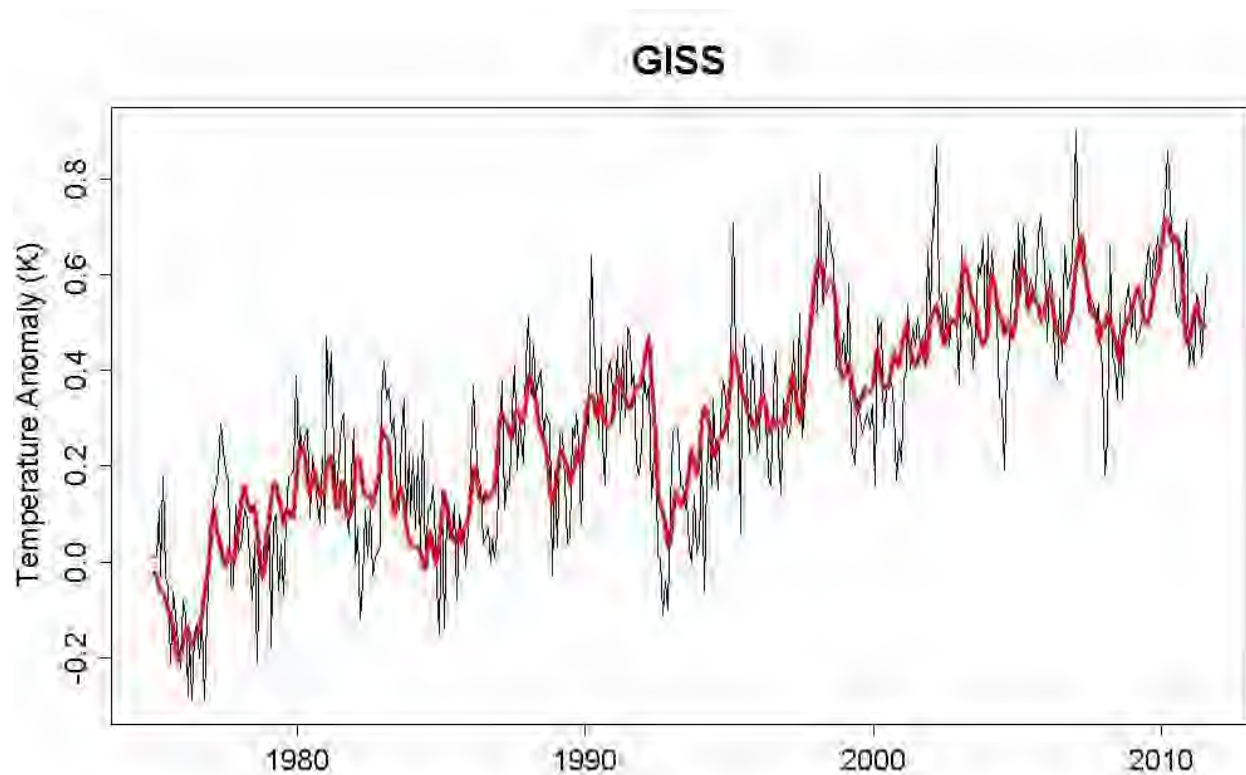


# AI 兩大主流

# AI



## 影像辨識



## 預測

# 中油5G AIoT科技防災與AI應用



- 關鍵設備 ●
- 智慧工安 ●
- 管線儲槽 ●
- 營運管理 ●

# 各部門5G AIoT推動之KPI 原則

## 須確實有效益的AI案件

1. 共分4類,可以再擴增,比照儀控轉機中心的方式,分類A/B/C/D等項目,各單位進行調查/評估/建置3個階段

2. **A類 影像辨識** : 技術成熟,各種工地工安,場域工安等,區分A01-A08

3. **B類 異常預測** : 目的明確,可預知設備何時異常,區分B01-A04

4. **C類 數值預測** : 技術難度低,純預知數值或趨勢用處不大,需配套工作的對應作為,區分C01-C04

5. **D類 生成式AI** : 由資訊處訂定。





# 自從2016年3月AlphaGo贏了李世石後，人們才相信人工智慧 (深度學習)的威力



AlphaGo為何厲害？

AlphaGo怎麼會這麼厲害？主要原因有兩個。

一、AlphaGo使用的是蒙特卡洛樹搜索，它會在下棋時分析每一步的風險係數，比如在未來20步的N種情況下，它立即就能判斷出如何落子的勝率最高。

二、AlphaGo有自己學習和進化的能力。它**集合了3,000萬種職業棋手的下法，數百萬次深度學習與自我對戰**，十分接近帶著直覺和第六感的人類大腦，能以57%的概率預測與其對陣人類的水平。此外，研發者表示「人類在長時間的比賽中會因疲勞而犯錯，但電腦程式不會，**人類可能1年只能下1,000盤棋，而AlphaGo一天就能下100萬盤**」。因此，在數據提取、統計、分析、判斷、選擇等方面，人類不是它的對手。李世石會犯錯，AlphaGo不會。

# 1. IoT物聯網


## 物聯網 (Internet of Things, IoT)

資訊傳遞由過去人與人的通訊，演化為物聯網架構下物對人乃至物物相連的通訊



## 2. 機器學習與深度學習

### 人工智慧的歷史階段

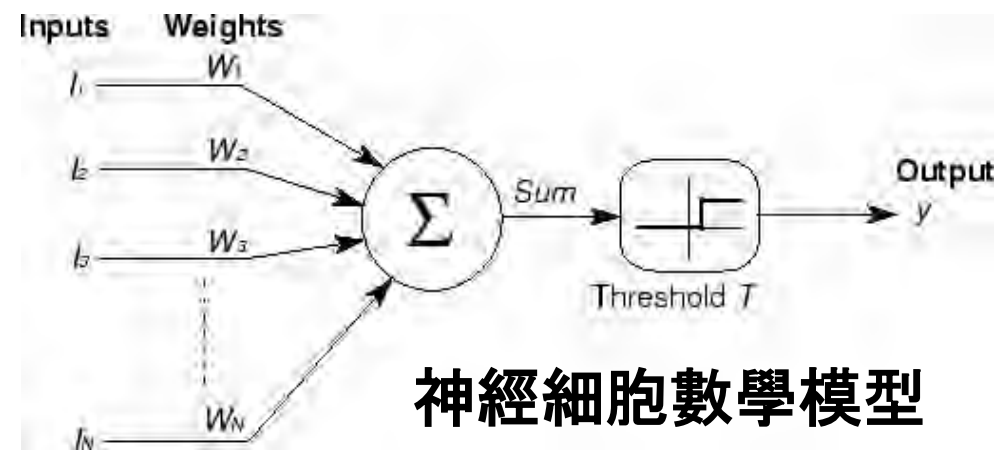


資料來源:清華大學:"AI於煉油廠分餾塔之應用"

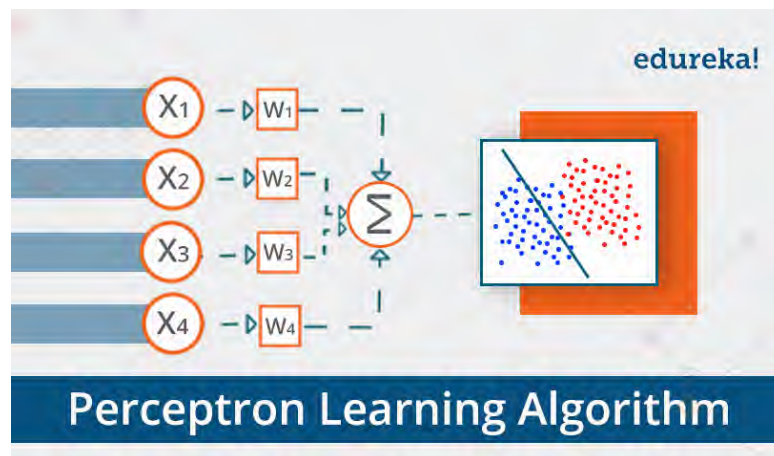
# 萌芽期的數學基礎



$$y = \text{Heaviside} \left( \sum_j w_j x_j \right)$$



可以從數據學習分類



# 什麼是AI?

AI是人工智慧

對機器(1)輸入一些有標註的資料,(2)經過演算法,(3)一次一次地讓輸出的特徵更清楚呈現,就是AI

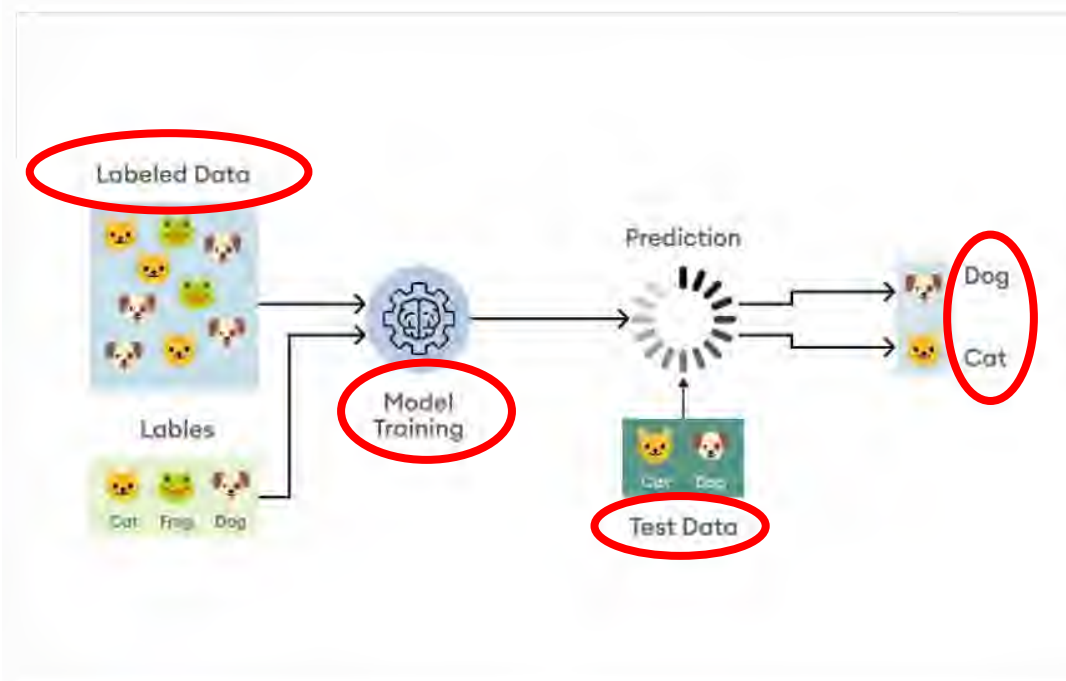

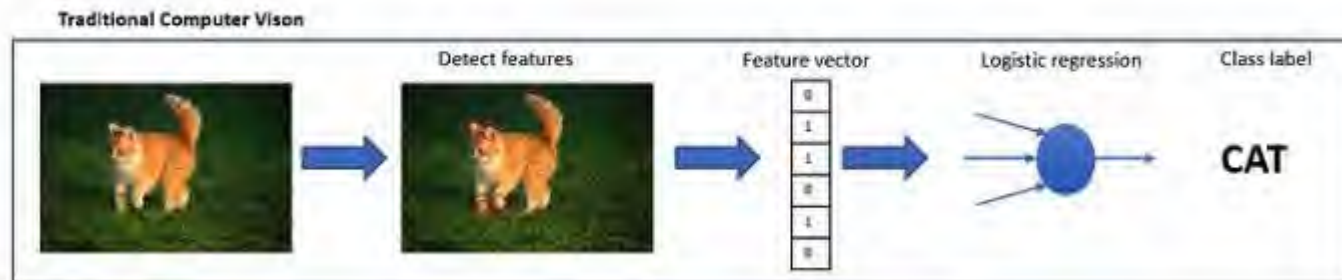
例如:

影像辨識AI:

判斷是什麼動物

預測型AI:


糖尿病的預測






# 機器學習與深度學習

## Machine Learning

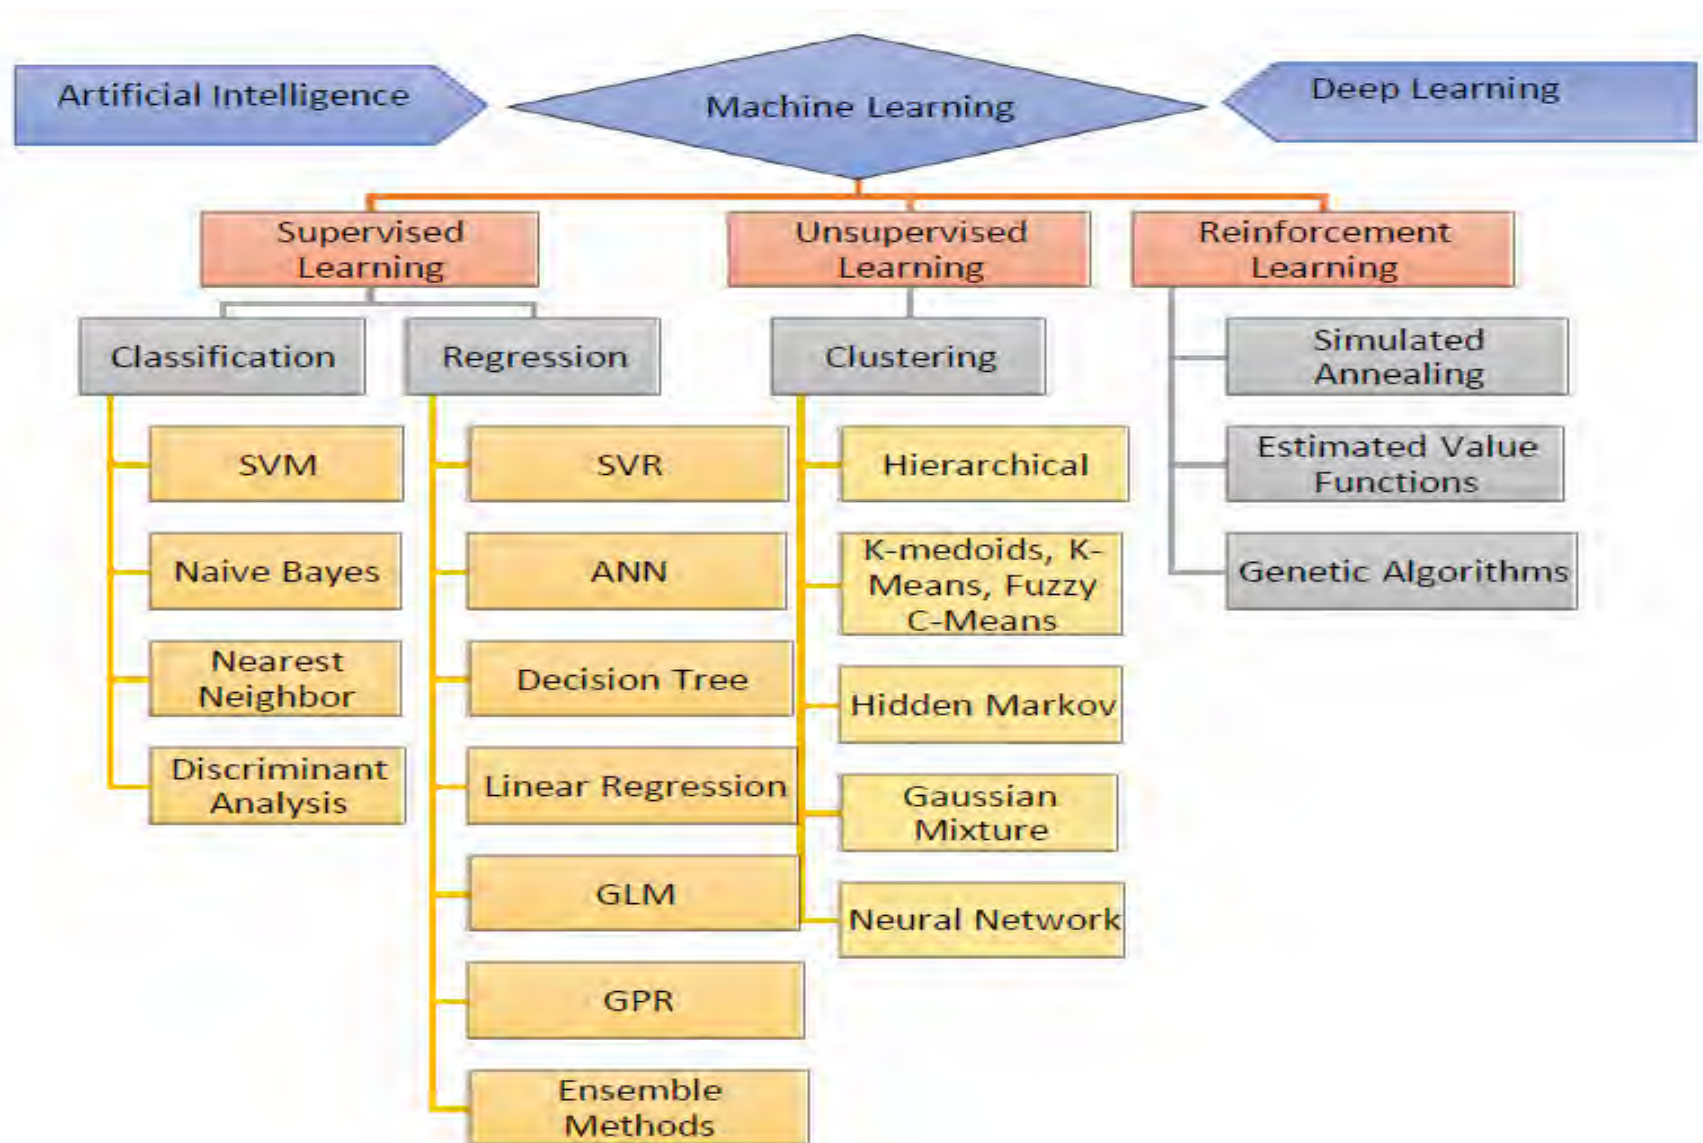


## Deep Learning




# 機器學習分類技術

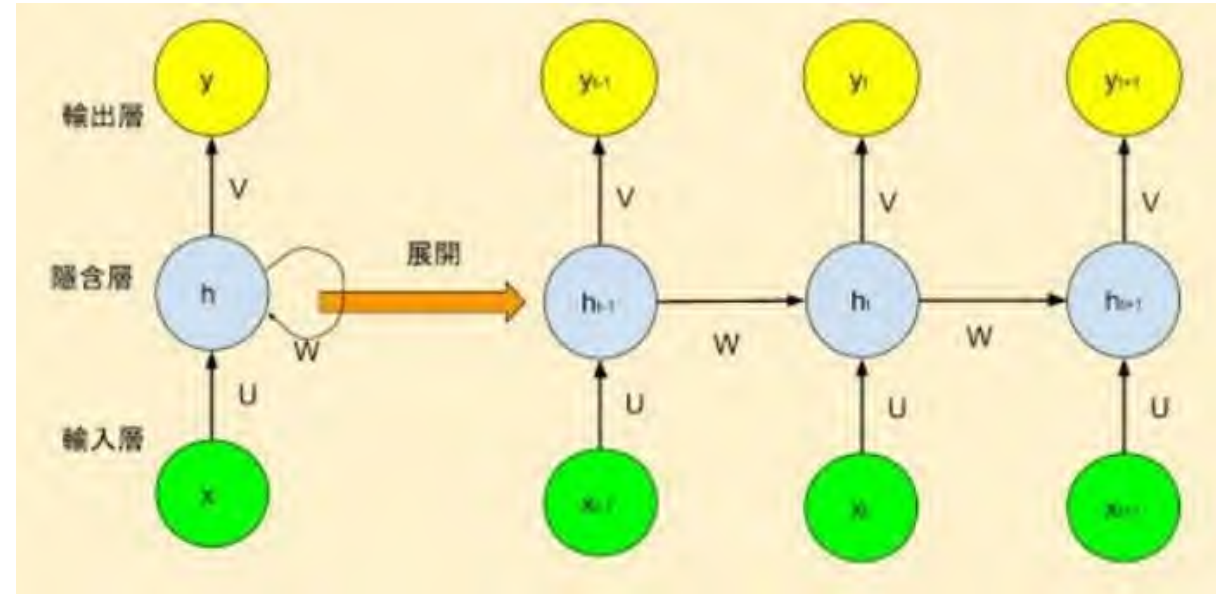
## Classification within Machine Learning Techniques



# 深度學習是什麼



卷積網路 (CNN)



遞回網路 (RNN)

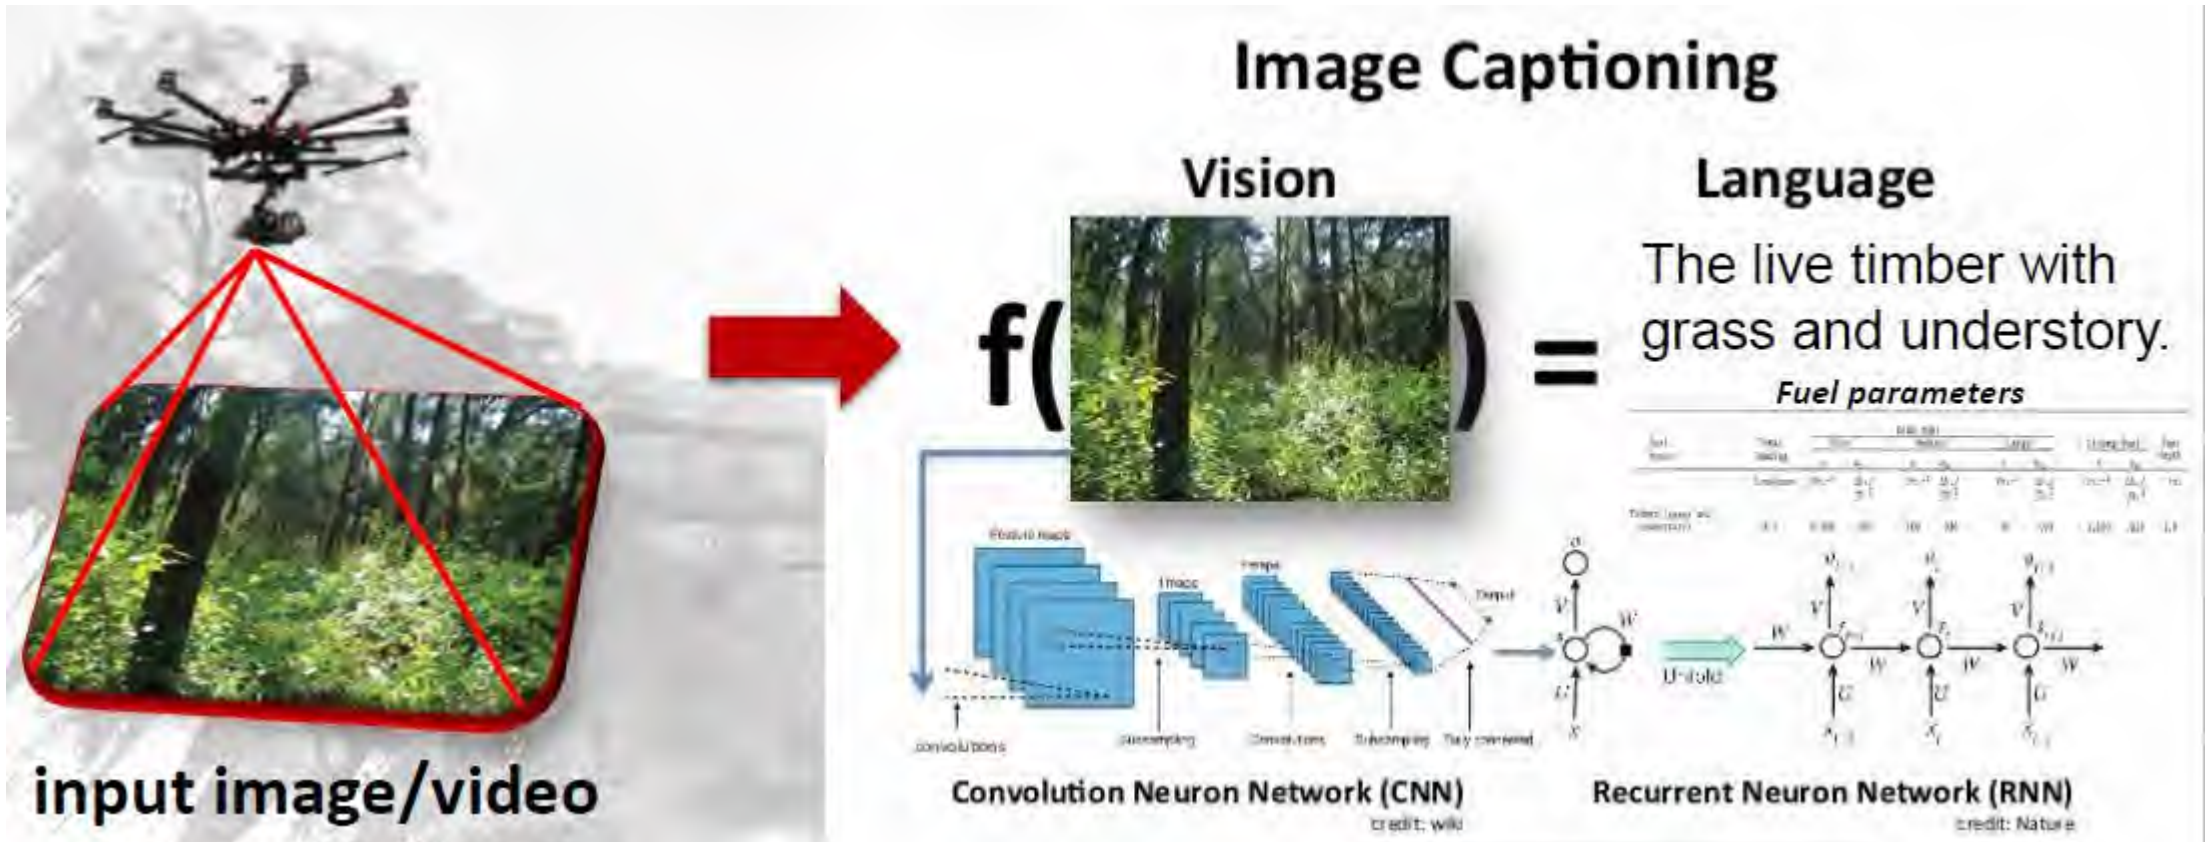
通過新型類神經網路的開發，深度學習將各種形態的資料如數位，圖形，文本，語音，影片處理一體化。

**任何數據之間的函數關係都可以學習-萬物皆可函**




# 監督式學習

- 監督式(supervised)深度學習
  - 最常見和最被廣泛使用的類型。這些算法從被事先標記好的數據 ( labeled data ) 中學習，用以預測結果



# 非監督式學習


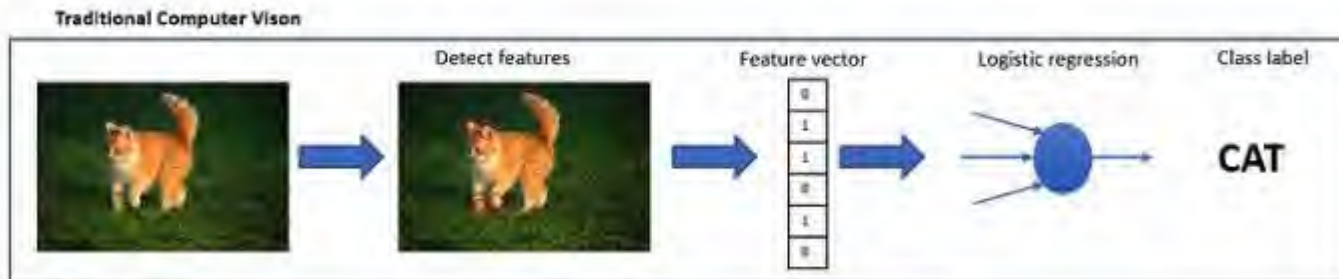
- 非監督式(unsupervised)深度學習
  - 無監督學習算法不需要事先標示，而是直接從數據學習判讀模式。它可以用於分群 (clustering)，關聯 (association) 和異常檢測 (anomaly detection) 問題。





# (一). 影像辨識CNN

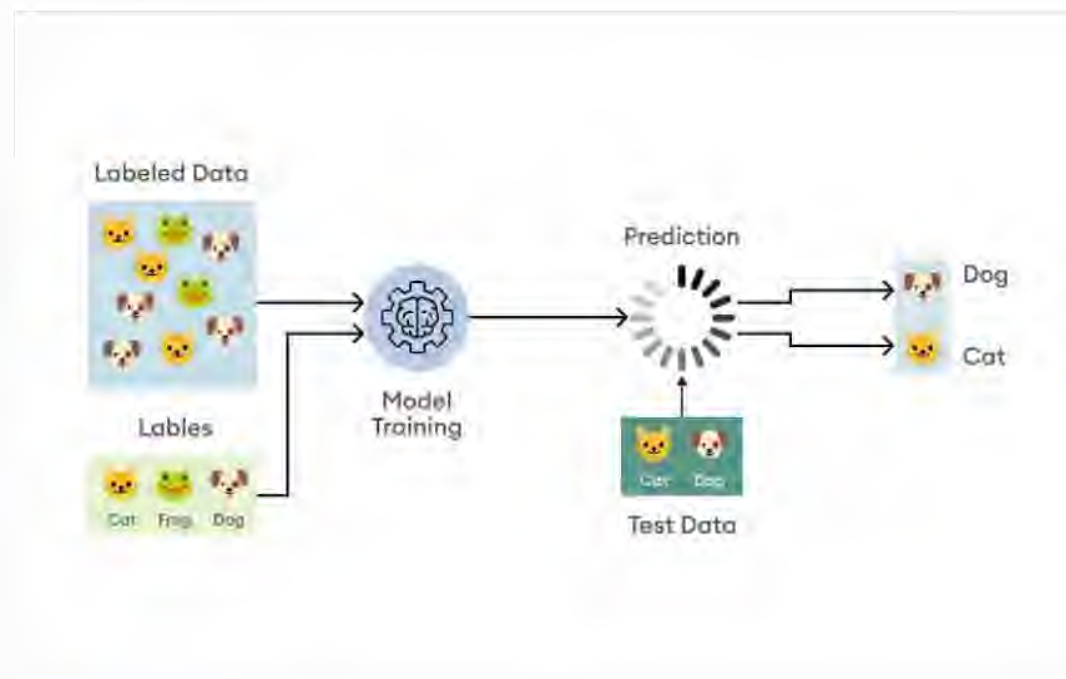
## (影像分類)



## 影像分類與物件偵測

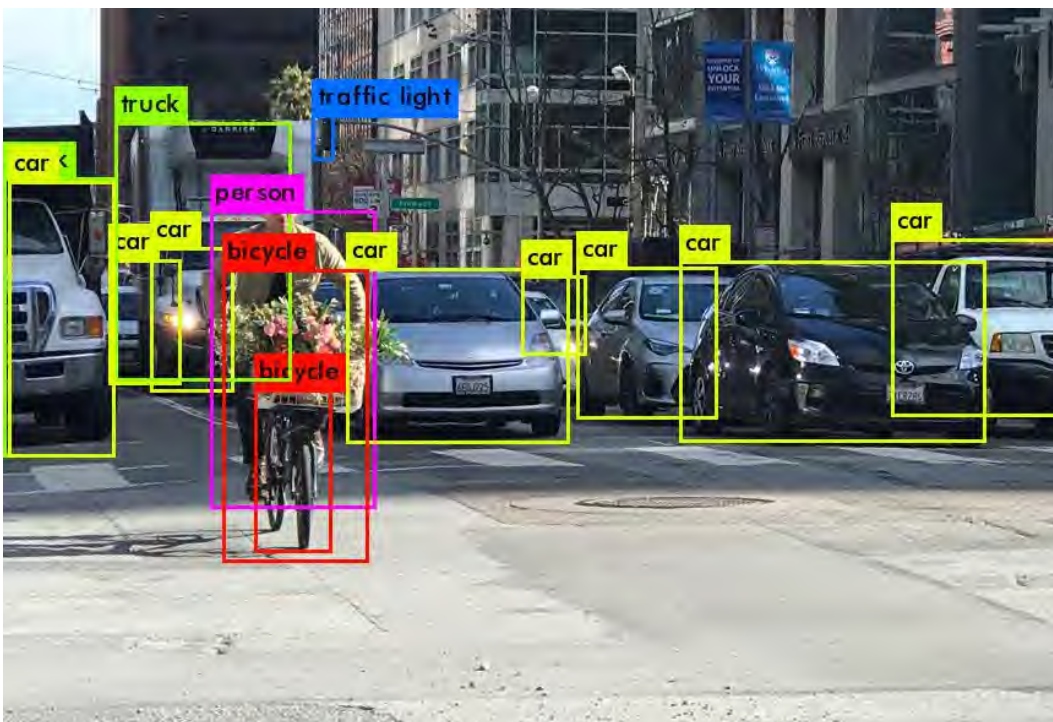
- 整張圖的辨識,為影像分類

範例” 土石坍塌災情威脅評估系統”



## 影像分類與物件偵測

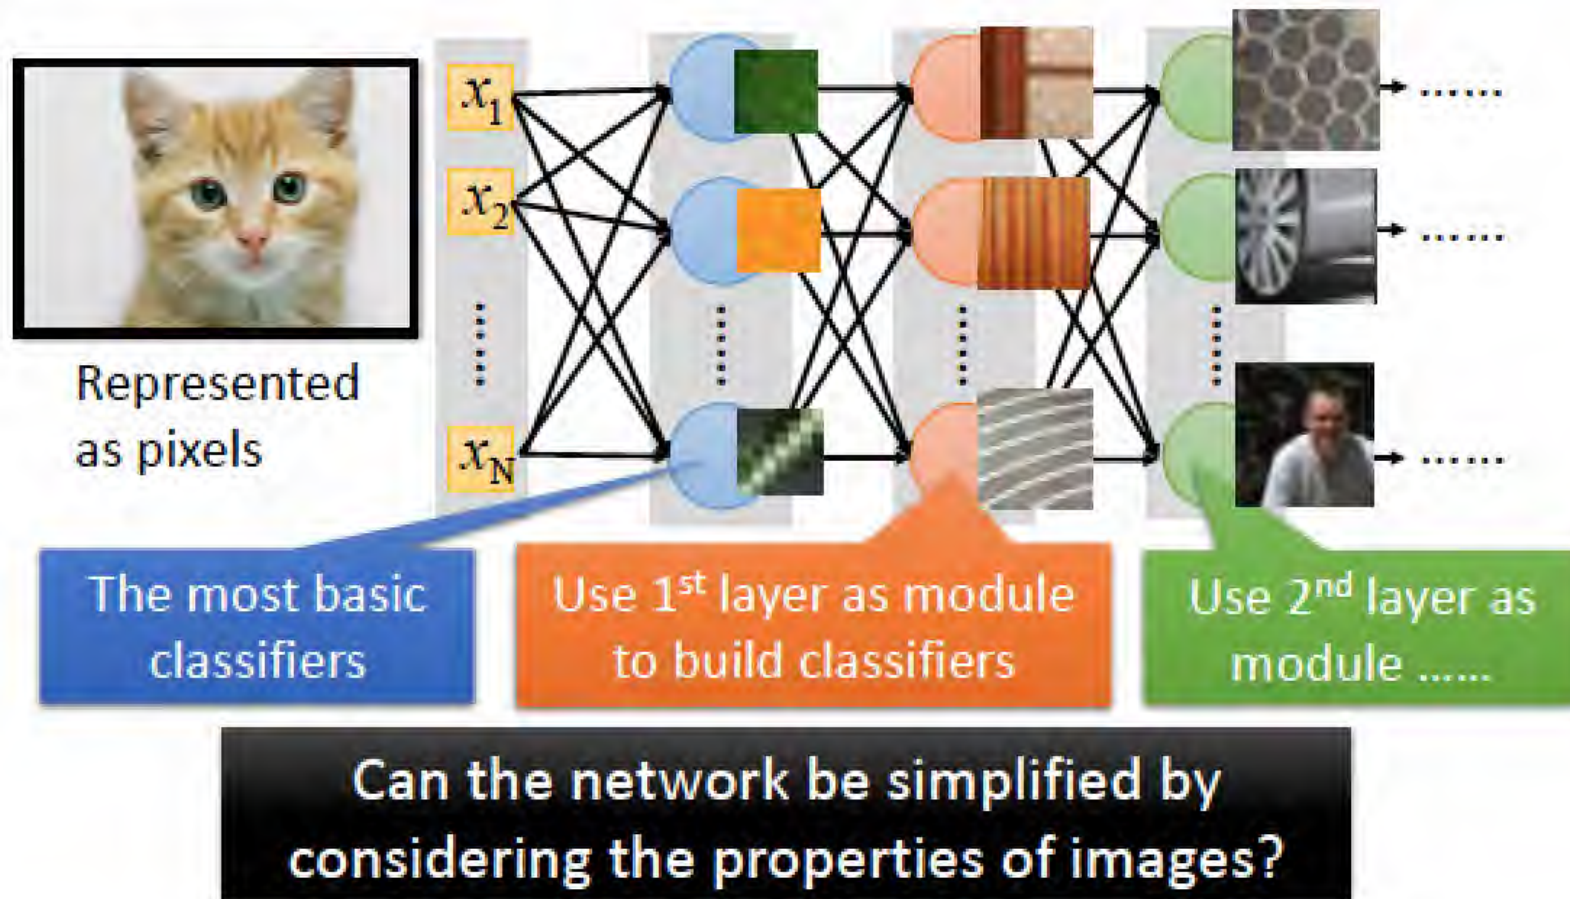
- 偵測圖中的部分物件, 稱為物件偵測
- 例如工地施工是否戴安全帽, 是否有危險機具靠近(電子圍籬), 是否有不安全行為等, 都是影像辨識工安AI的範疇.
- 本課程案例” 1.森林土石流判別” 與” 2.馬達電流頻譜故障識別”





# Why CNN for Image?

[Zeiler, M. D., *ECCV 2014*]



## MNIST 機械學習

- 訓練圖像  
60000張
- 測試圖像  
10000張
- 使用Softmax  
回歸模型訓練,  
準確率為  
91.85%



# MNIST 機械學習

- 在MNIST 數據集的官網, 使用多達68種的模型來訓練.
- 包含線性分類器、K近鄰方法、普通神經網路、卷積神經網路(CNN)等
- 使用卷積神經網路(CNN)訓練, 準確率達99%

Method	Recognition accuracy (%)
CNN	99.18
SVM	93.78
HOG-SVM	97.82
kNN	97.31
Random forest	94.82
RNN	96.95

Recognition accuracy of machine learning methods on MNIST dataset



# 3. CNN影像辨識


## ImageNet 數據集

- 一個為促進影像識別技術發展而設立的大型數據庫
- 包含上千種圖形類別,至2016年,數據集中的圖片已經超過1000萬張




# ImageNet 影像辨識競賽



- ImageNet每年舉辦一場大規模的影像識別競賽 (ILSVRC)
- 2012年加拿大多倫多大學 Alex 使用深度學習, 將錯誤率由26%降至16%, 引起大家的興趣, 這個模型又稱為 AlexNet



# CNN 的架構

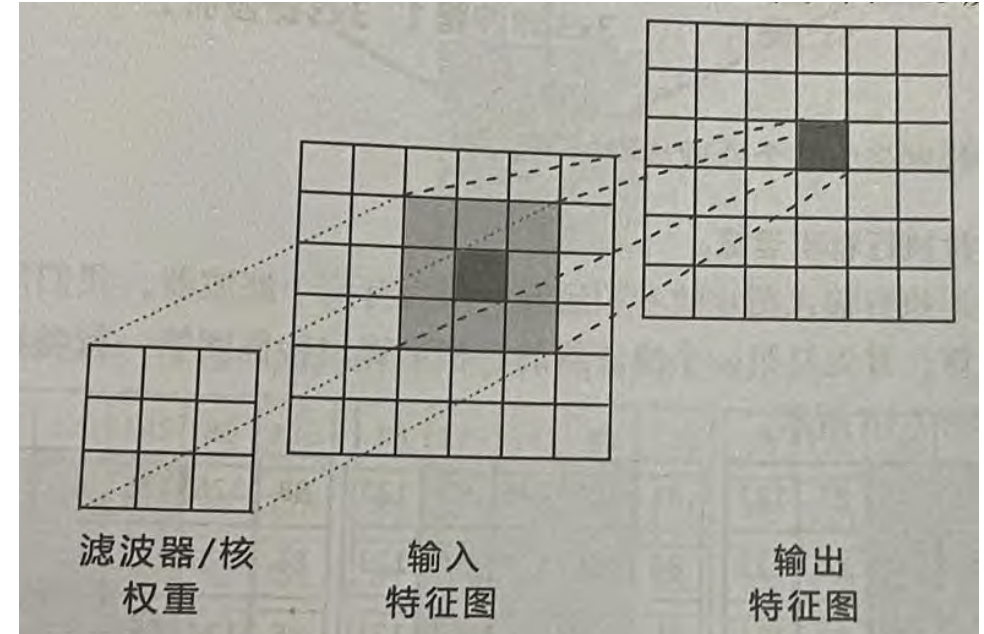
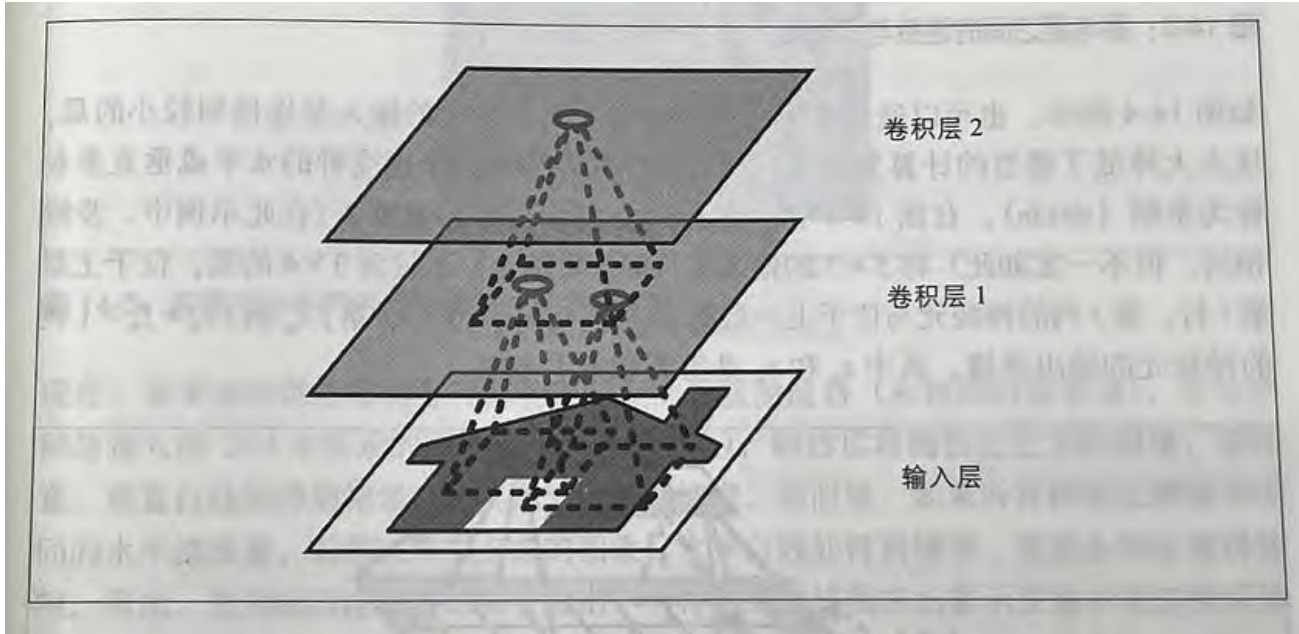



# CNN 的原理：提取特徵





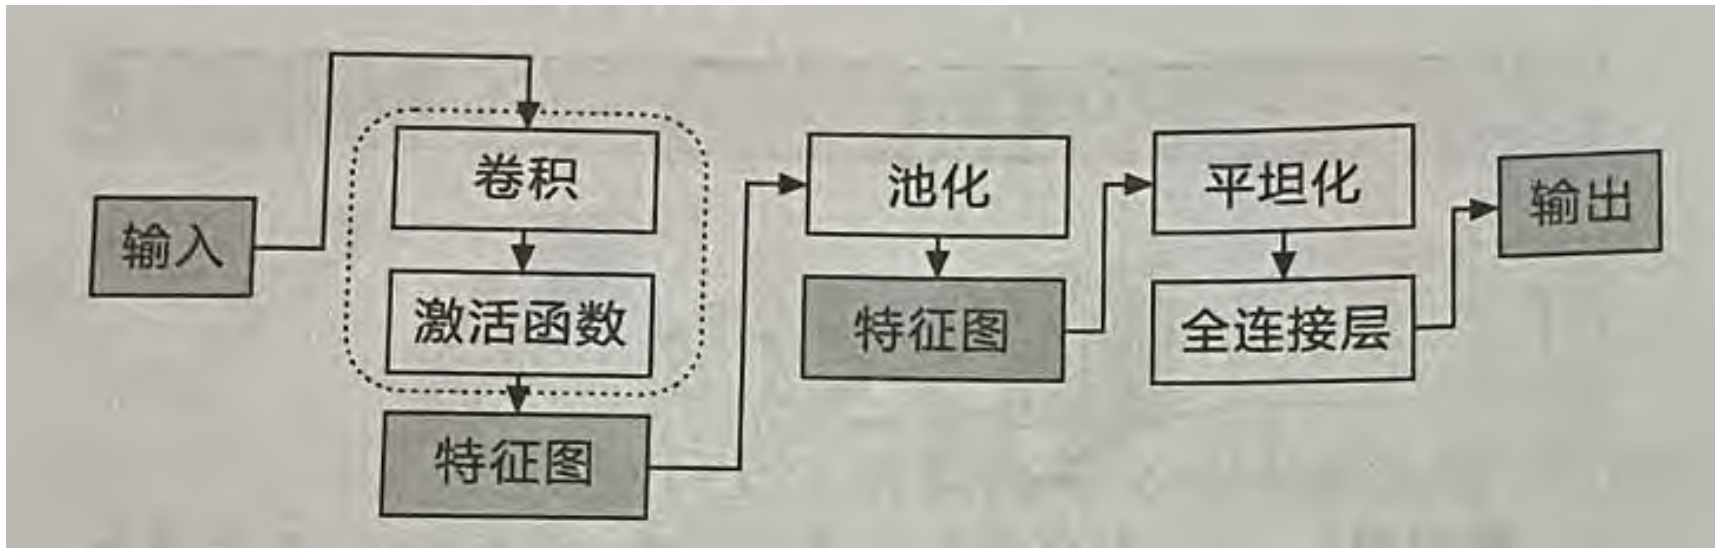
# CNN 卷積層 的運作



卷積：

- 由視野框 Kernal 與圖形乘積後提取特徵

# CNN 卷積層 範例說明



88	126	145	85	123
86	125	142	84	123
85	124	141	82	121
82	119	135	80	117
78	114	128	77	113

5x5 图片

1	0	1
1	1	0
0	0	0



3x3 濾波器 1

1	0	1
0	1	0
1	1	0

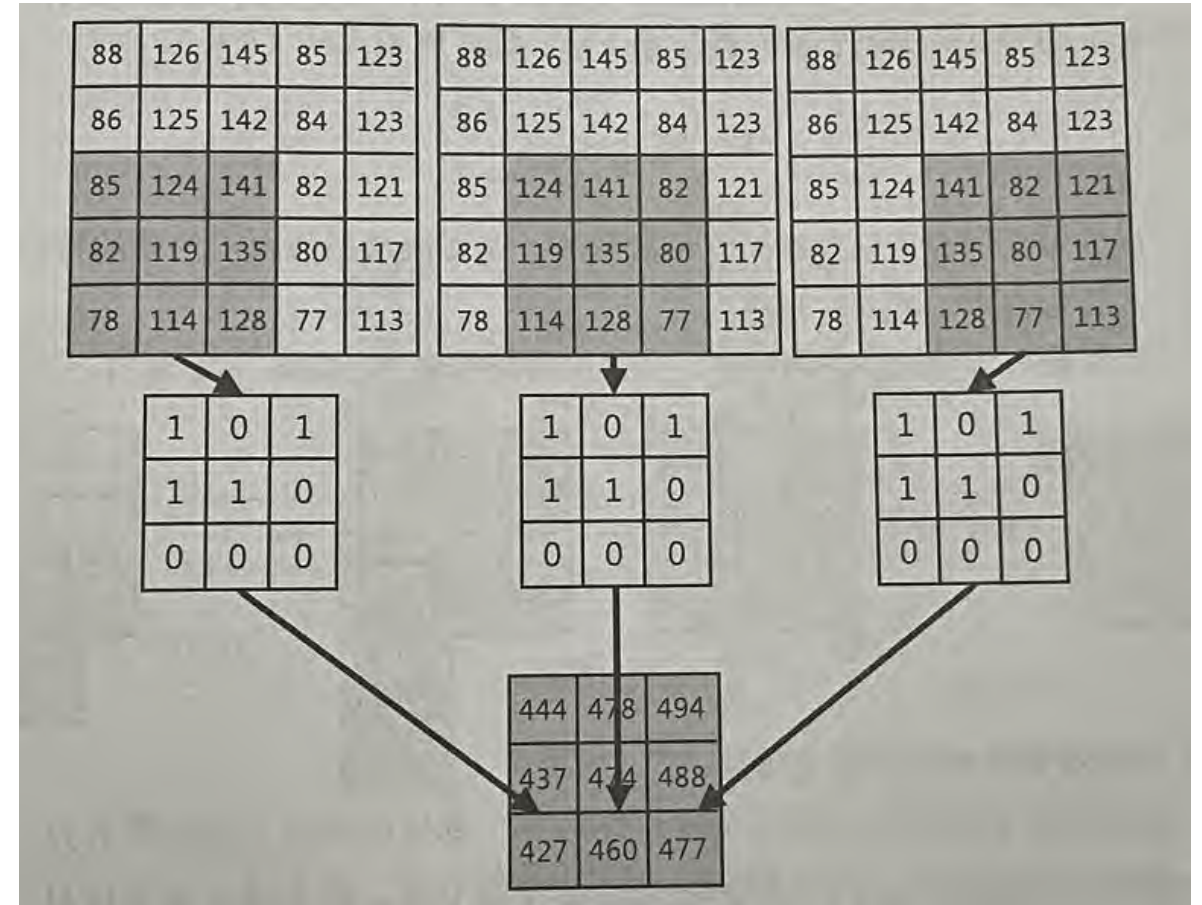
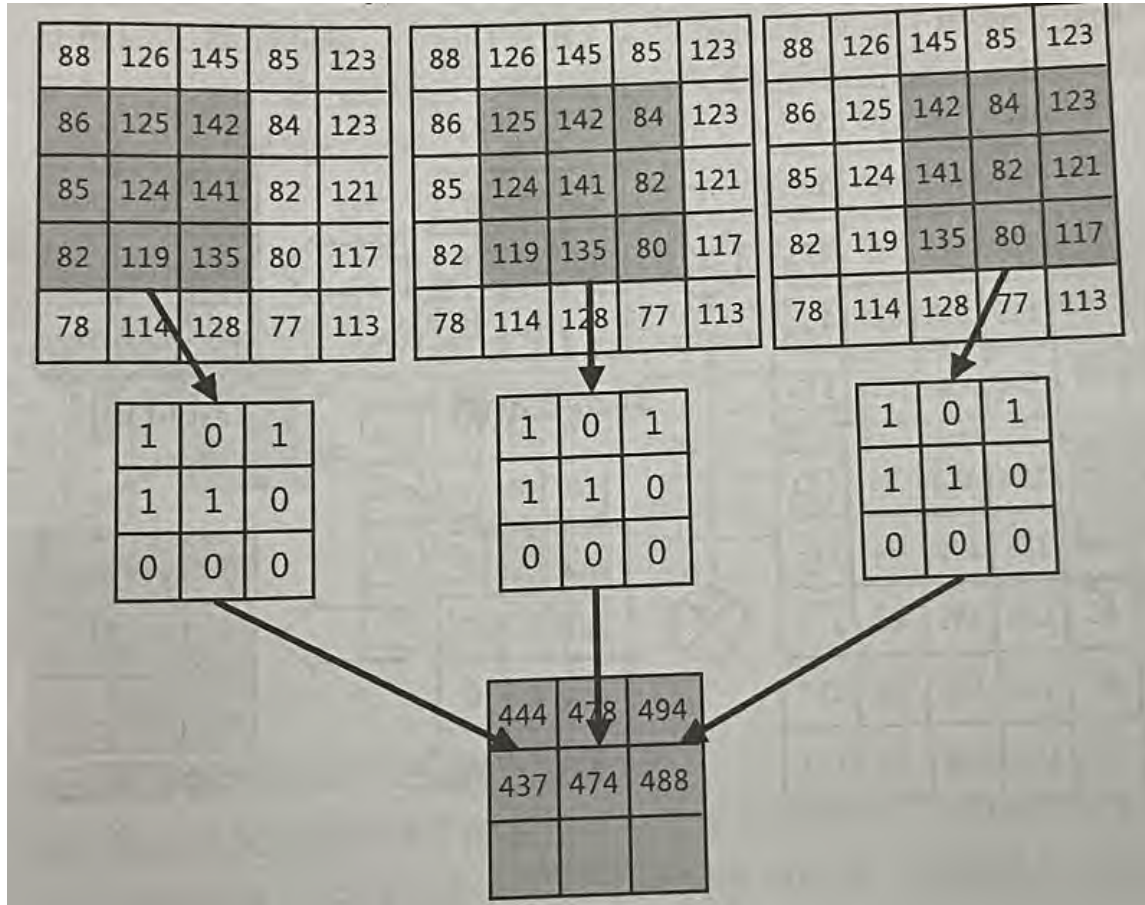

3x3 濾波器 2



# CNN 卷積層的運作



# CNN 卷積層的運作






88	126	145	85	123
86	125	142	84	123
85	124	141	82	121
82	119	135	80	117
78	114	128	77	113



1	0	1
1	1	0
0	0	0

3x3滤波器1



444	478	494
437	474	488
427	460	477

特征图1

88	126	145	85	123
86	125	142	84	123
85	124	141	82	121
82	119	135	80	117
78	114	128	77	113



1	0	1
0	1	0
1	1	0

3x3滤波器2

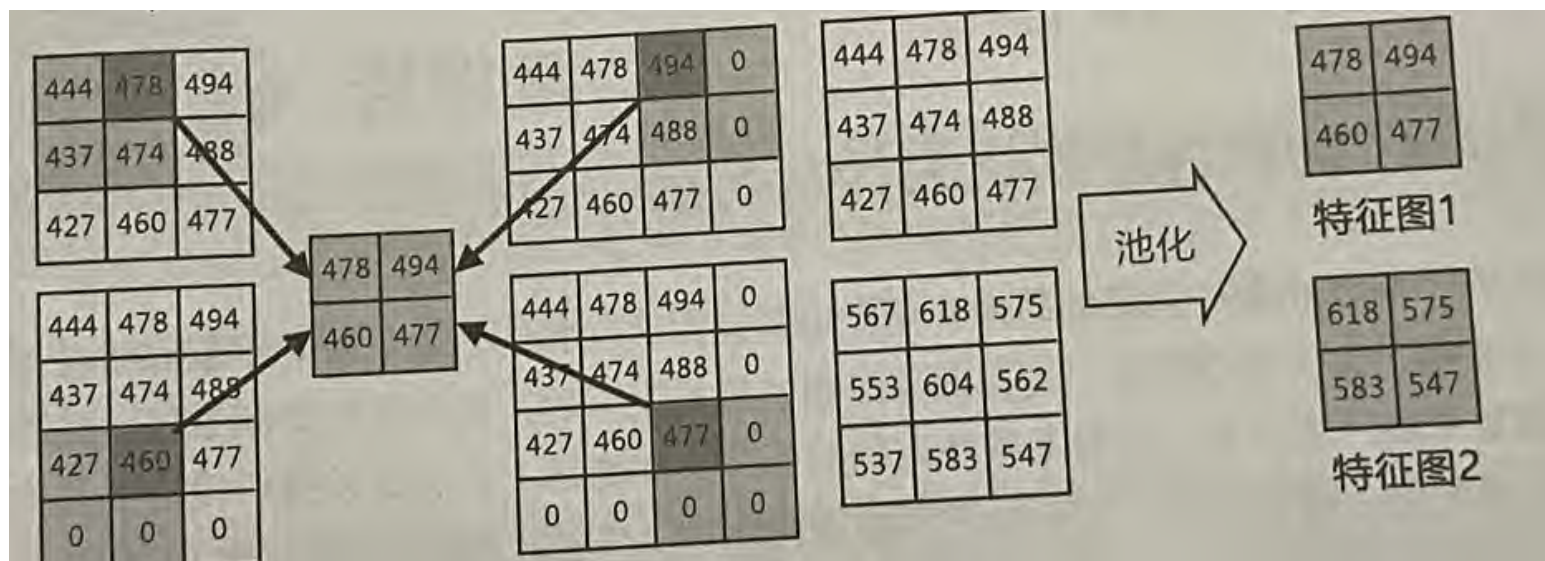




567	618	575
553	604	562
537	583	547


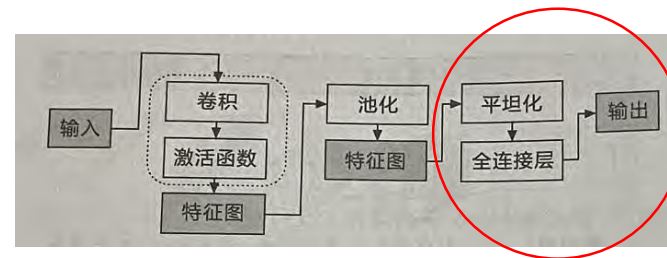
特征图2




# 池化層



# 分類 輸出層





## AlexNet :

- 輸入層經過5層卷積層,再經過三層全連接層
- 深度學習



# AlexNet : 輸入層經過5層卷積層,再經過三層全連接層

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout,
BatchNormalization
from tensorflow.keras.regularizers import l2
```

```
def build_alexnet(input_shape=(227, 227, 3), num_classes=1000):
    model = Sequential(name="AlexNet")
```


```
    # 第一層卷積 + ReLU + 池化
    model.add(Conv2D(96, (11, 11), strides=4, padding='valid', activation='relu',
input_shape=input_shape))
    model.add(BatchNormalization())
    model.add(MaxPooling2D((3, 3), strides=2))

    # 第二層卷積 + ReLU + 池化
    model.add(Conv2D(256, (5, 5), strides=1, padding='same', activation='relu'))
    model.add(BatchNormalization())
    model.add(MaxPooling2D((3, 3), strides=2))

    # 第三層卷積 + ReLU
    model.add(Conv2D(384, (3, 3), strides=1, padding='same', activation='relu'))

    # 第四層卷積 + ReLU
    model.add(Conv2D(384, (3, 3), strides=1, padding='same', activation='relu'))

    # 第五層卷積 + ReLU + 池化
    model.add(Conv2D(256, (3, 3), strides=1, padding='same', activation='relu'))
    model.add(MaxPooling2D((3, 3), strides=2))
```



```
    # 展平層
    model.add(Flatten())

    # 全連接層 + Dropout
    model.add(Dense(4096, activation='relu', kernel_regularizer=l2(0.01)))
    model.add(Dropout(0.5))

    model.add(Dense(4096, activation='relu', kernel_regularizer=l2(0.01)))
    model.add(Dropout(0.5))

    # 輸出層 (假設分類任務)
    model.add(Dense(num_classes, activation='softmax'))

    return model

# 構建模型
model = build_alexnet(input_shape=(227, 227, 3), num_classes=1000)
model.summary()
```


# AlexNet : 輸入層經過5層卷積層,再經過三層全連接層

Model: "AlexNet"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 55, 55, 96)	34,944
batch_normalization (BatchNormalization)	(None, 55, 55, 96)	384
max_pooling2d (MaxPooling2D)	(None, 27, 27, 96)	0
conv2d_1 (Conv2D)	(None, 27, 27, 256)	614,656
batch_normalization_1 (BatchNormalization)	(None, 27, 27, 256)	1,024
max_pooling2d_1 (MaxPooling2D)	(None, 13, 13, 256)	0
conv2d_2 (Conv2D)	(None, 13, 13, 384)	885,120
conv2d_3 (Conv2D)	(None, 13, 13, 384)	1,327,488
conv2d_4 (Conv2D)	(None, 13, 13, 256)	884,992
max_pooling2d_2 (MaxPooling2D)	(None, 6, 6, 256)	0
flatten (Flatten)	(None, 9216)	0
dense (Dense)	(None, 4096)	37,752,832
dropout (Dropout)	(None, 4096)	0
dense_1 (Dense)	(None, 4096)	16,781,312
dropout_1 (Dropout)	(None, 4096)	0
dense_2 (Dense)	(None, 1000)	4,097,000

Total params: 62,379,752 (237.96 MB)

Trainable params: 62,379,048 (237.96 MB)

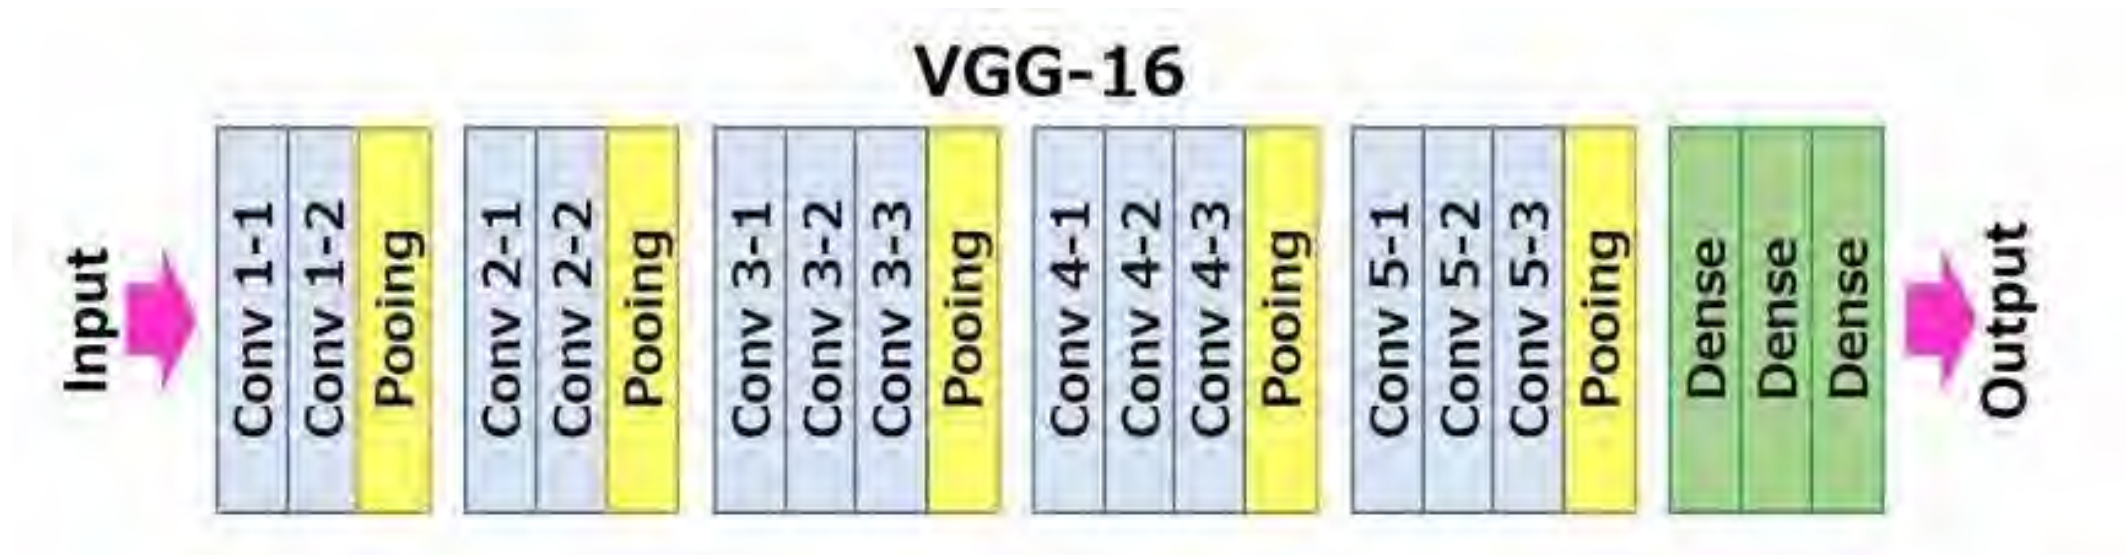


# VGG Net

- 共訓練6種網路,分別為 VGG-A、VGG-A-LRN、VGG-B、VGG-C、VGG-D、VGG-E
- VGG-D和VGG-E效果最好,由於VGG-D有16層,VGG-E有19層,因此又稱為VGG-16與VGG-19

ConvNet Configuration					
A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 <b>LRN</b>	conv3-64 <b>conv3-64</b>	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 <b>conv3-128</b>	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 <b>conv1-256</b>	conv3-256 conv3-256 <b>conv3-256</b>	conv3-256 conv3-256 conv3-256 <b>conv3-256</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 <b>conv1-512</b>	conv3-512 conv3-512 <b>conv3-512</b>	conv3-512 conv3-512 conv3-512 <b>conv3-512</b>
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					





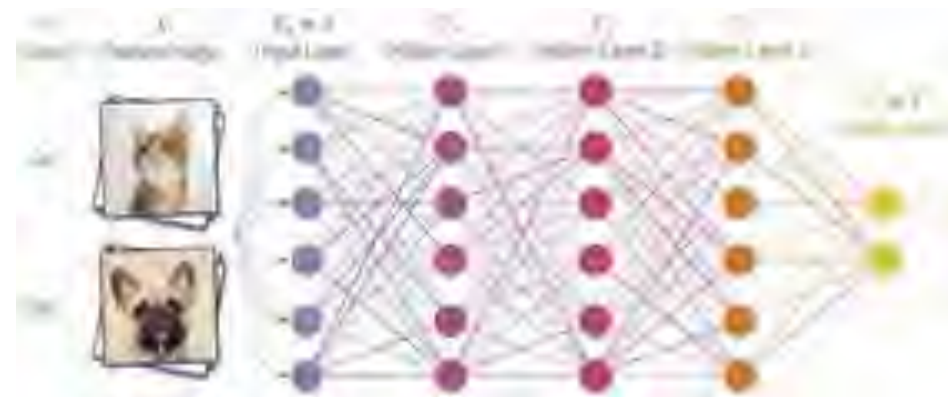
## VGG16


- 共訓練6種網路,分別為VGG-A、VGG-A-LRN、VGG-B、VGG-C、VGG-D、VGG-E
- VGG-D和VGG-E效果最好,由於VGG-D有16層,VGG-E有19層,因此又稱為VGG-16與VGG-19

Model	Size	Top-1 Accuracy	Top-5 Accuracy	Parameters	Depth
Xception	88 MB	0.790	0.945	22,910,480	126
VGG16	528 MB	0.715	0.901	138,357,544	23
VGG19	549 MB	0.727	0.910	143,667,240	26
ResNet50	99 MB	0.759	0.929	25,636,712	168
InceptionV3	92 MB	0.788	0.944	23,851,784	159
InceptionResNetV2	215 MB	0.804	0.953	55,873,736	572
MobileNet	17 MB	0.665	0.871	4,253,864	88

## 深度學習的層數

- VGG-16共有16層,加上5個池化層,1個輸入層,1個輸出層,深度為23層
- VGG-19,深度為26層
- ResNet 深度達到168層
- InceptionResNetV2達到572層





## Inception V3


- 共有159層



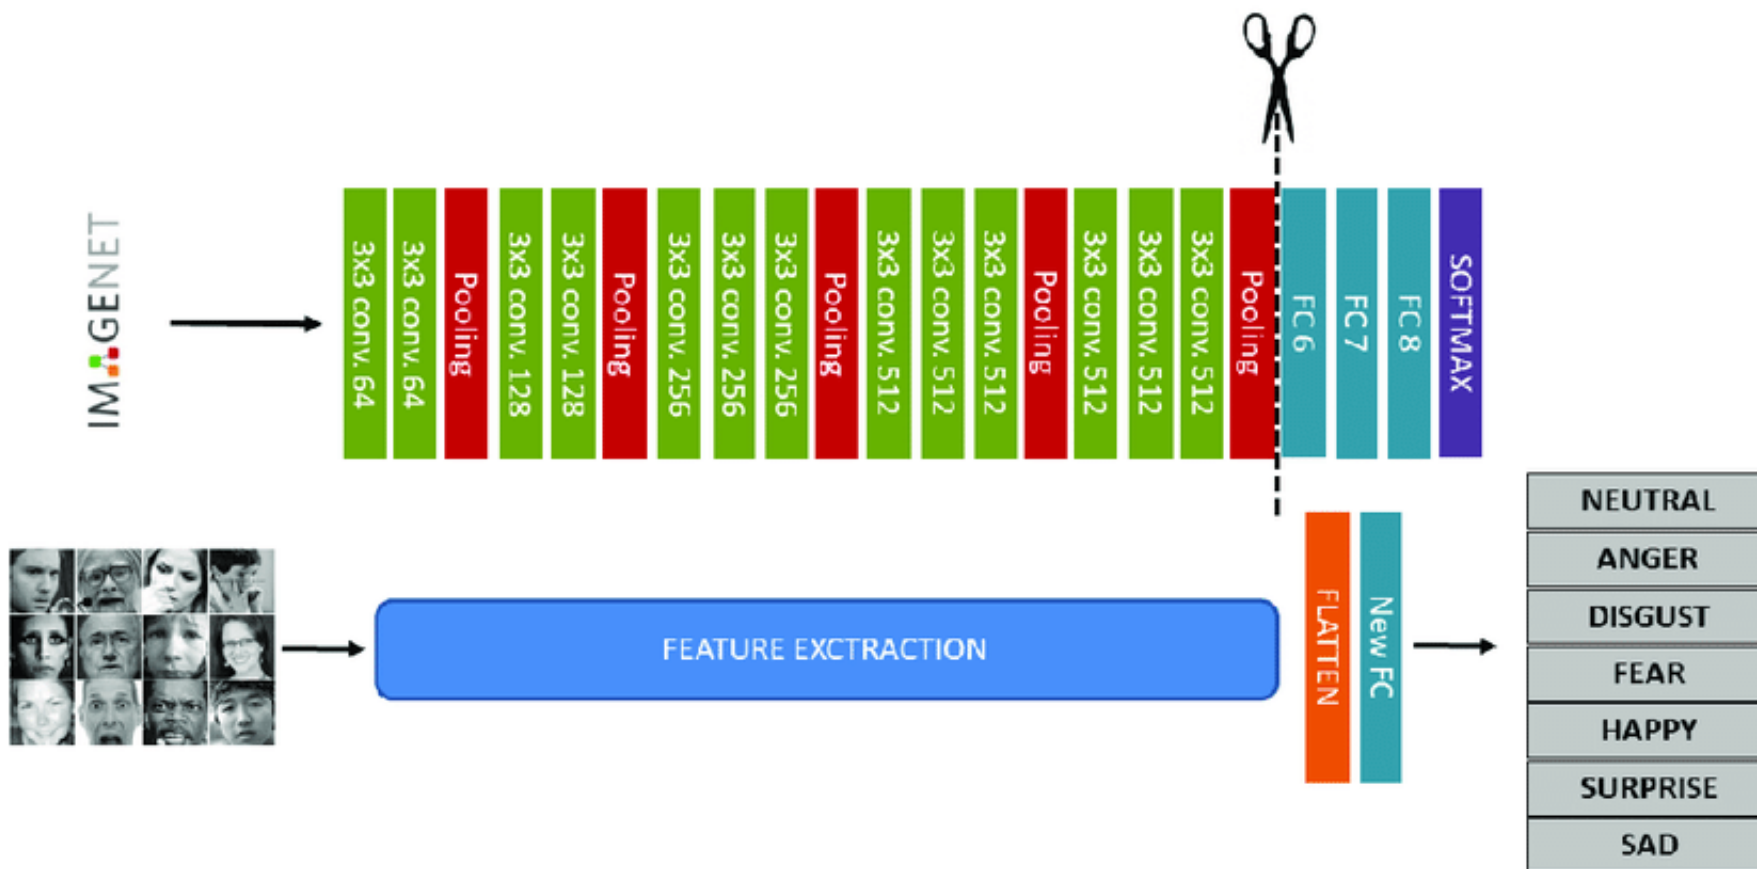
# (模型微調)

## 模型微調

- 右圖為VGG-16
- 在ImageNet已經預訓練好的模型上微調,可以節省很多時間



# (模型微調)



## 模型微調

- 各種微調方式

# (模型微調)

Model	Layer	Classes	Total Mults	Trainable Weights	Training Mults	Time	Accuracy
VGG-16	FC8	5	15,466M	20K	20K	582.8s	80.0%
VGG-16	FC7	5	15,466M	16,798K	16,798K	772.9s	76.1%
VGG-16	FC6	5	15,466M	119,558K	119,558K	2,012.2s	45.9%
VGG-16	Conv5-3	5	15,466M	121,917K	581,980K	2,016.7s	57.6%
VGG-16	All	5	15,466M	134,269K	15,466,189K	3,249.8s	42.7%

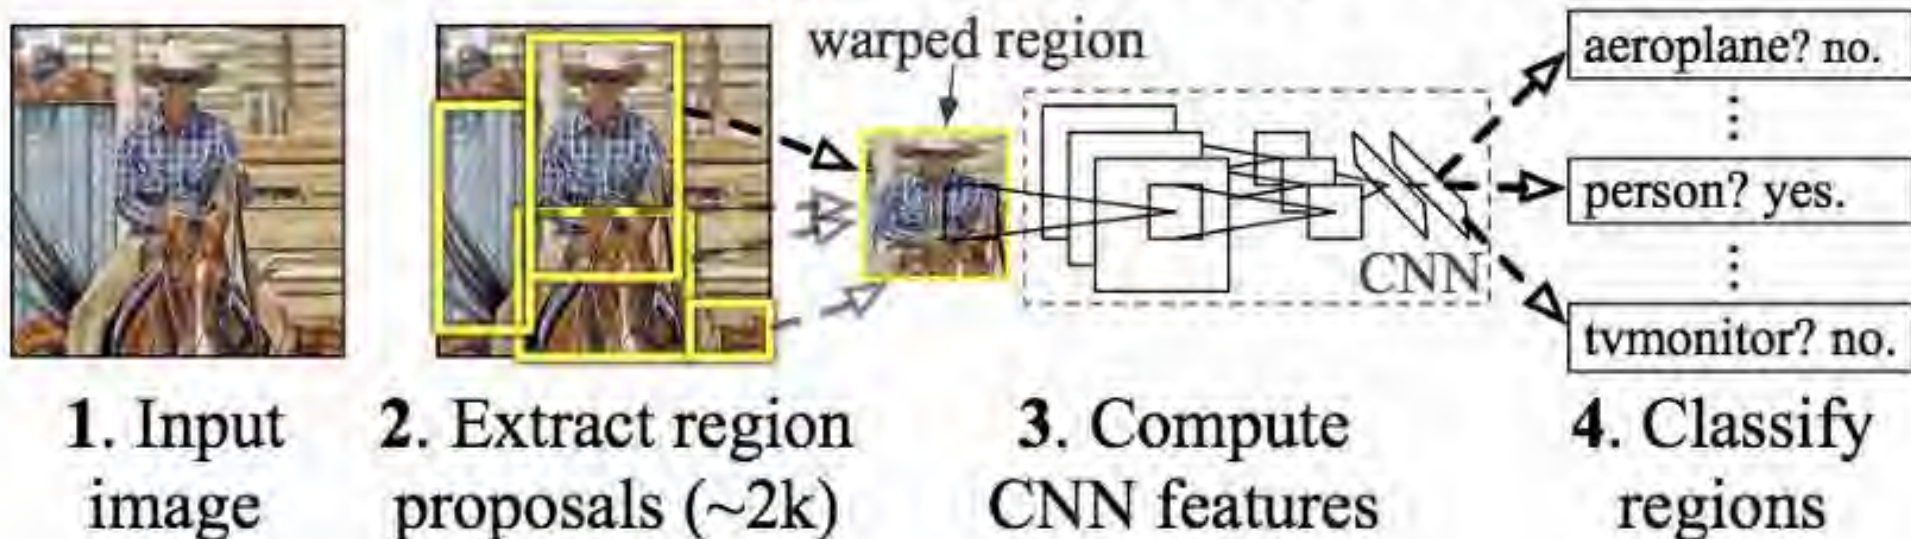
## 模型微調

Comparing fine-tuning VGG-16 performance up to different layers on same Flowers-5 dataset



# 目標檢測


## R-CNN: *Regions with CNN features*



### R-CNN

1. 第一個將深度學習應用到目標檢測的演算法
2. 步驟為提取框,對每個提取框取特徵,圖像分類,非極大化抑制值
3. 傳統方法最高平均精確度mAP為40%,這種R-CNN mAP達58.5%
4. 缺點:一張圖有效區域往往達1000張,訓練耗時

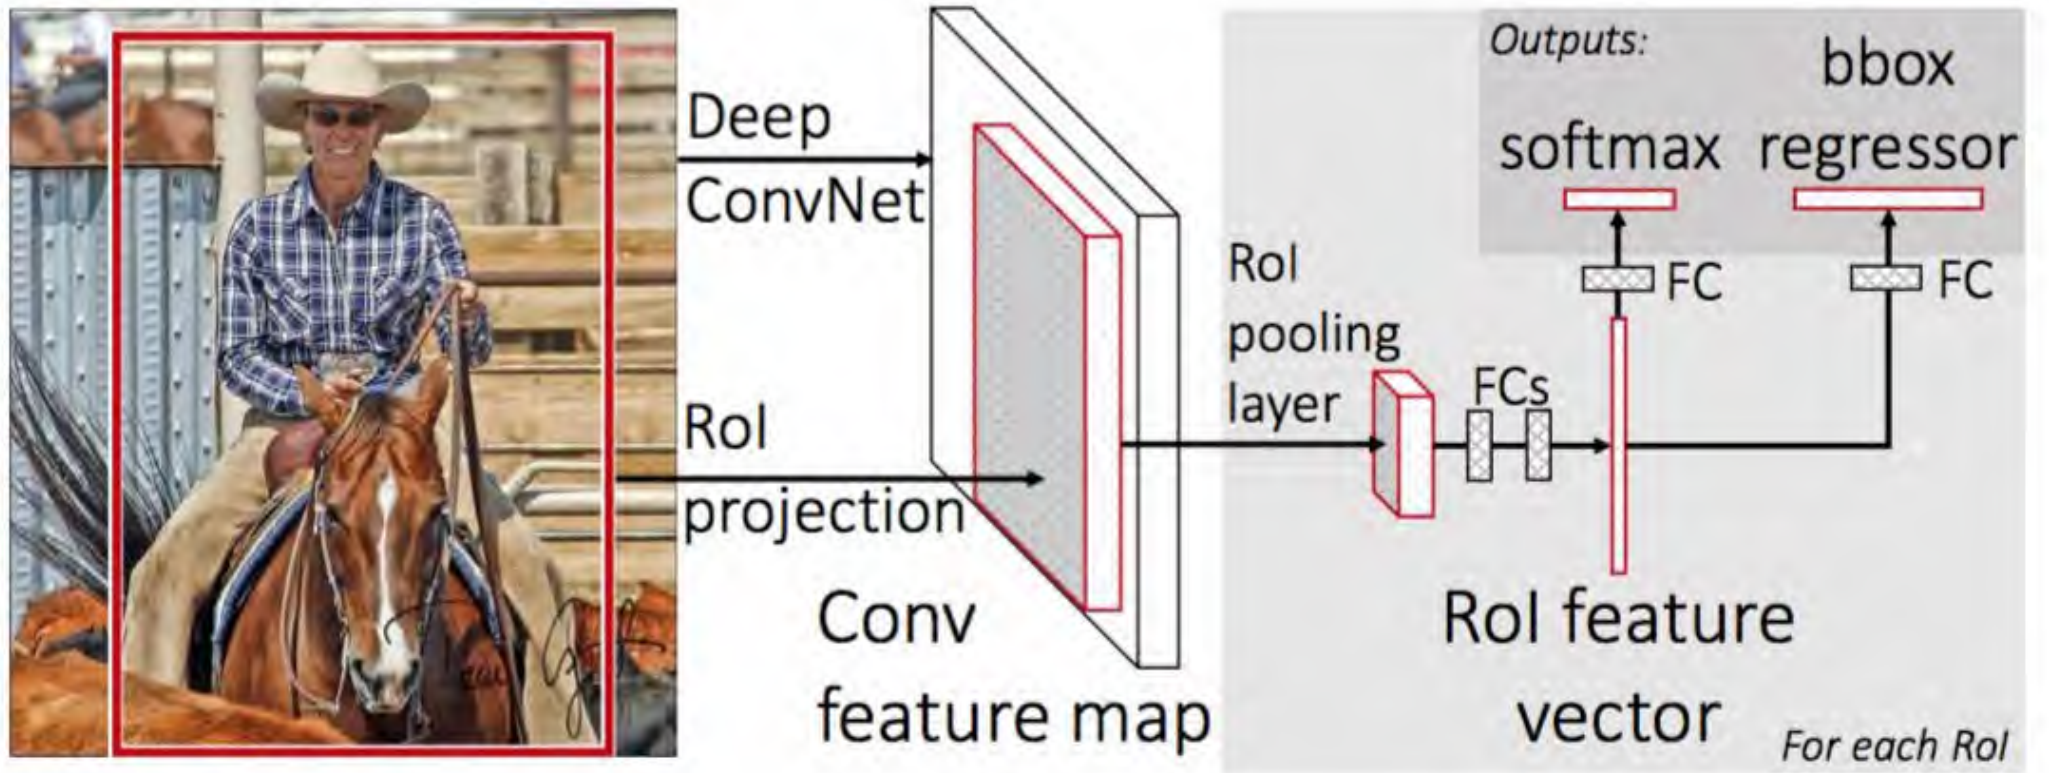
# 目標檢測



## SPPNet

1. 將CNN輸入由固定尺寸,變成任意尺寸
2. R-CNN要對每個區域進行卷積,SPPNet只需計算一次

# 目標檢測

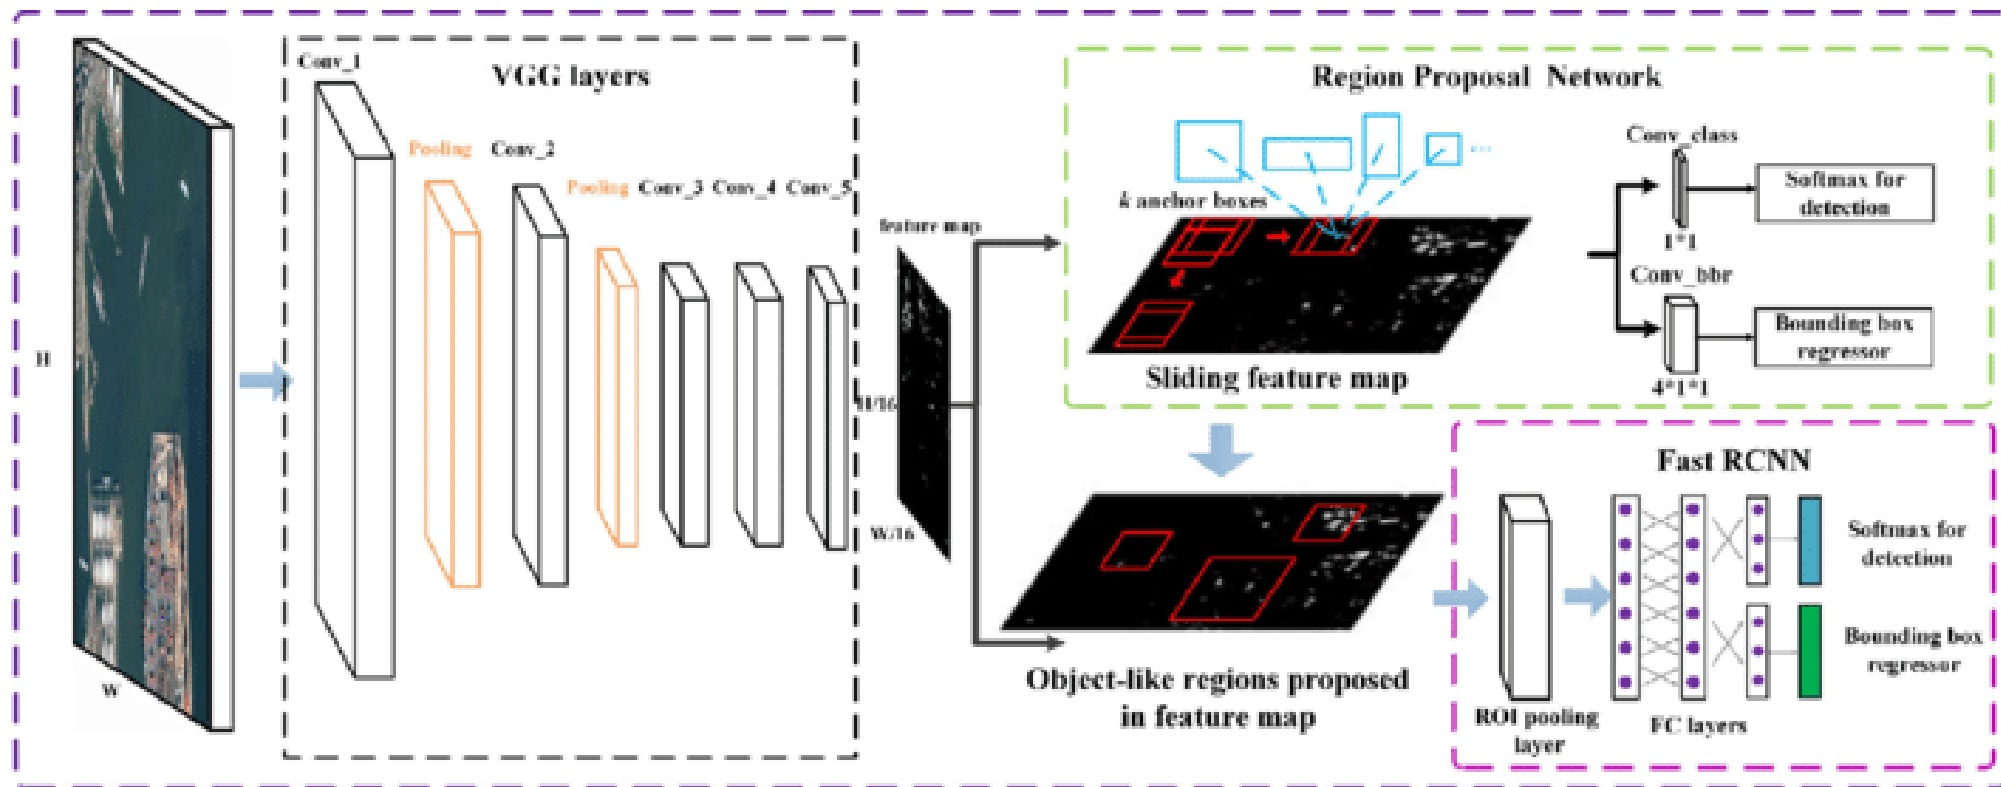


## Fast R-CNN

1. 不再使用SVM作為分類器,而是使用類神經網路作為分類器
2. 同時訓練特徵提取網路和分類網路,因此精確度比SPPNet更好



# 目標檢測






## Faster R-CNN

1. 往往時間是消耗在Selective Search提取框上
2. 使用RPN(Region Proposal Network)取代Selective Search

# 目標檢測

三者速度比較為1x :  
25x :250x

以上為2007年比較資料, 後來mAP右提升到78.8%, 後續可能持續進步




	R-CNN	Fast R-CNN	Faster R-CNN
Test time per image	50 seconds	2 seconds	0.2 seconds
Speed-up	1x	25x	250x
mAP (VOC 2007)	66.0%	66.9%	66.9%

\* Stanford lecture notes on CNN by Fei Fei Li and Andrej Karpathy

# 目標檢測

上一頁看起來天下無敵的Faster-RCNN,又被後來的模型打敗

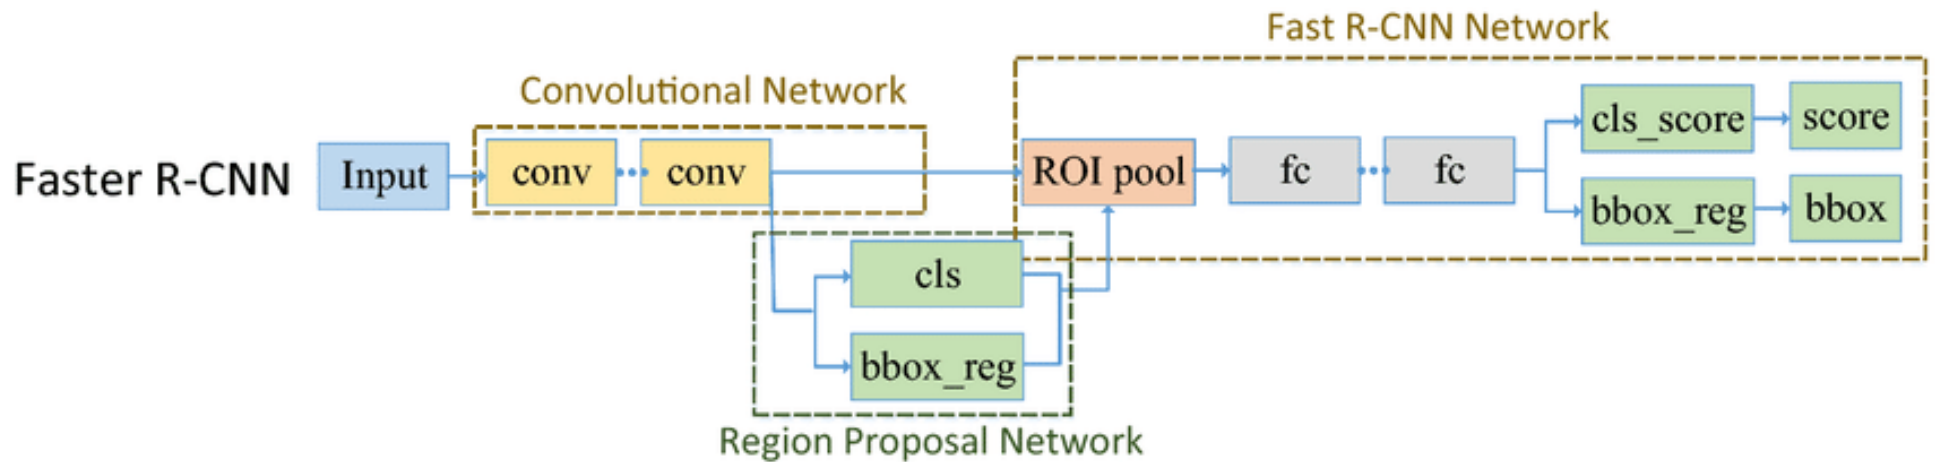


**Figure 6 : Performance of Deep Learning Model**

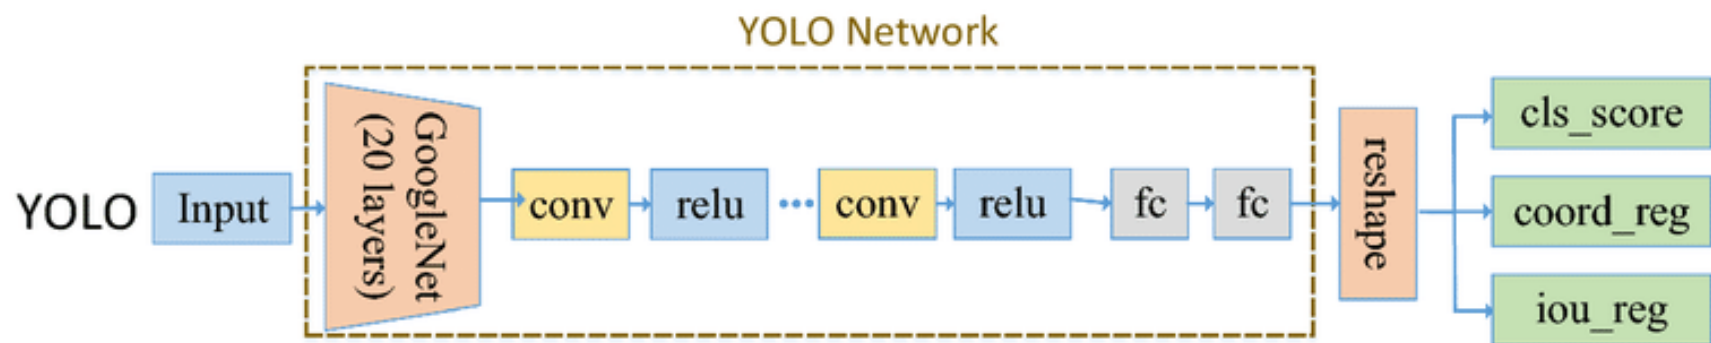


# 目標檢測

Faster-RCNN,  
和YOLO的結構  
比較,YOLO快的  
原因,就有如他  
的縮寫: You  
Only Look  
Once(YOLO)




(a)



(b)

# 目標檢測



Faster-RCNN,和YOLO的時間推移

# AI技術研討

影像辨識AI與應用(電流故障頻譜故障偵測影像辨識等)  
(第二堂課)

中油5G AIoT 推動辦公室

王朝民

2026 年 03 月 24 日





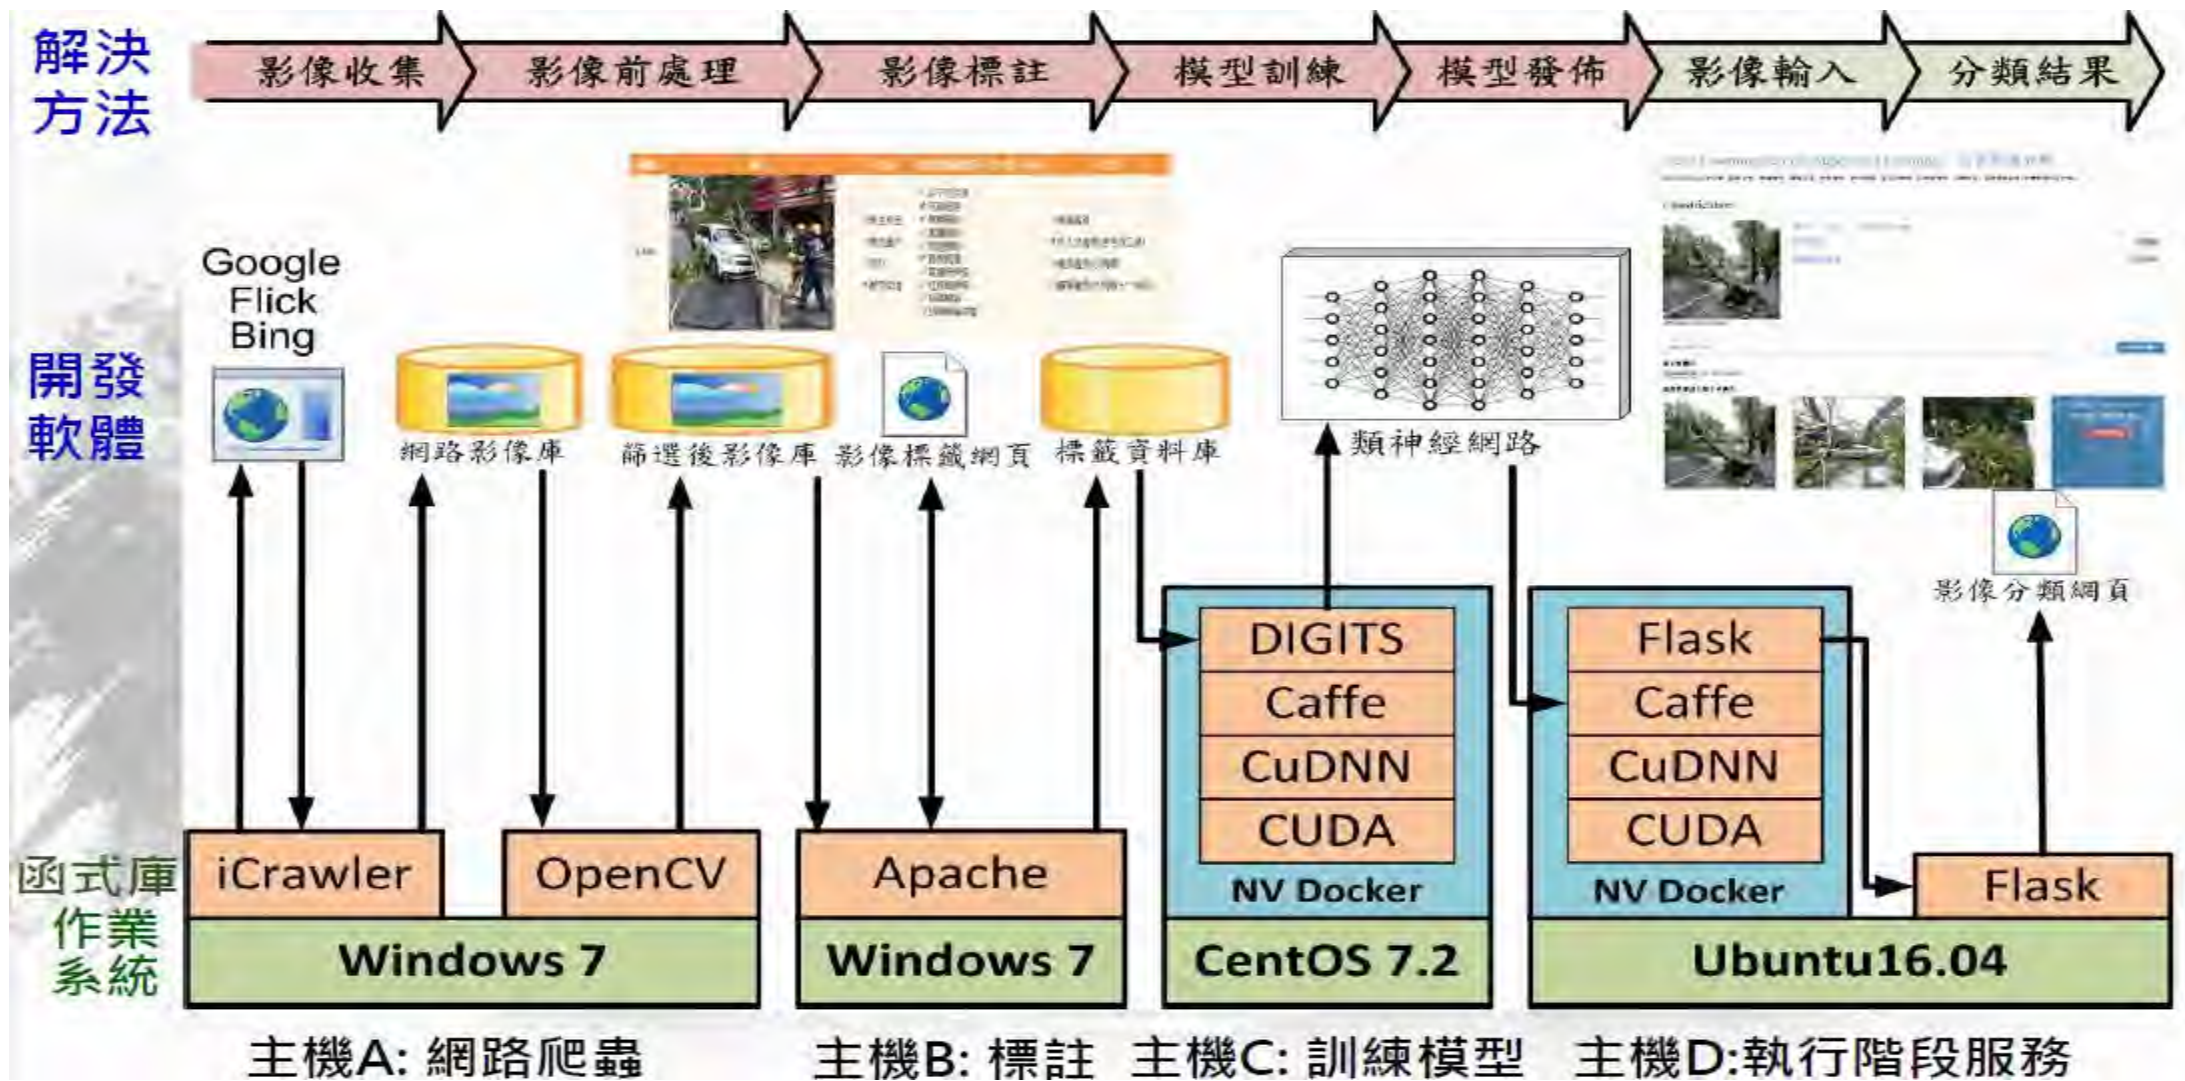
# 如何開發一個影像辨識的AI?

## 監督式深度學習作業流程



# 如何開發一個影像辨識的AI?

## 監督式深度學習使用的工具

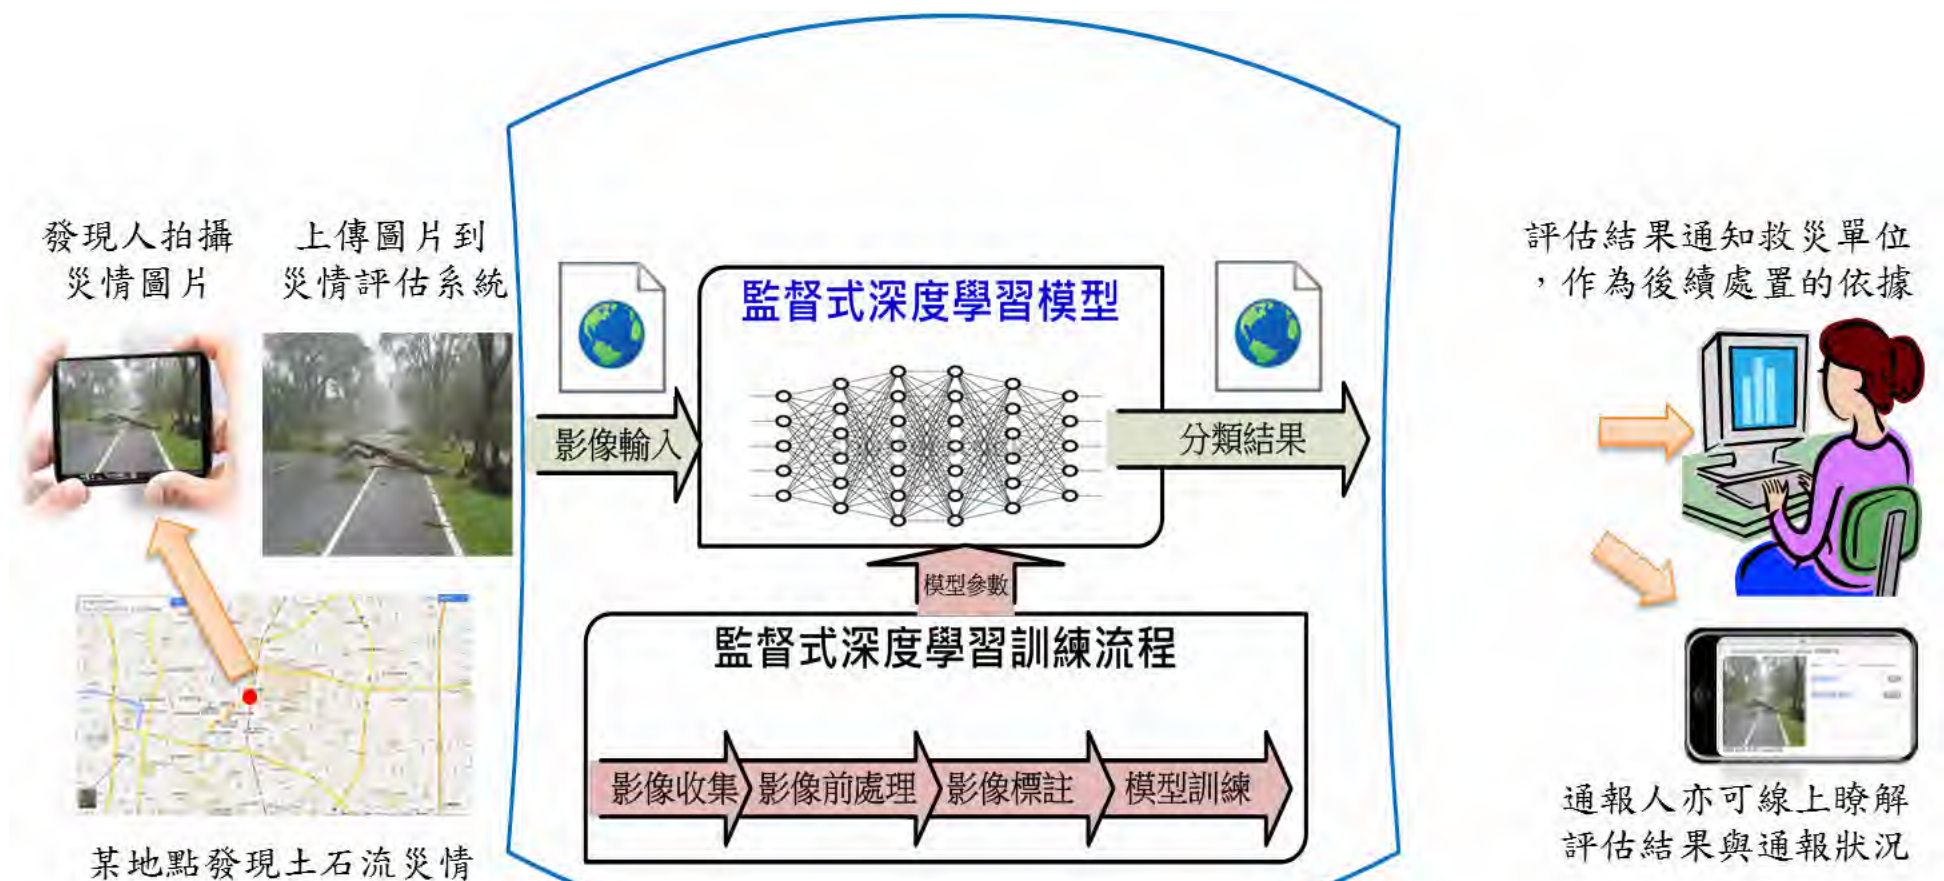




# CNN影像辨識應用案例(1/2)

## 土石坍塌災情威脅評估系統

- 本案比一般僅分析物件或場景的分類技術難度更高，需要具備災情資料分析及數據化專業，才能有效提升災情類型及嚴重性識別的正確率。





# CNN影像辨識應用案例(2/2)

## 土石坍塌災情辨識系統

① 輕度或無災情



② 中度災情: 上邊坡土石坍塌



③ 中度災情: 下邊坡土石坍塌



④ 重度災情: 大面積土石坍塌



# 中油 影像辨識應用介紹

- ✓ 馬達電流頻譜影像辨識AI  
(大林廠#6SRU壓縮機C6301B)



2020年中國石油學會特優論文 2023年中華民國玉山獎 (YOLO V3)

- ✓ 各事業部智慧工安(以CCTV影像辨識)
- ✓ 天然氣事業部北區營業處掛橋管線(YOLO V4)
- ✓ 石化林園廠新三輕現場工業儀表的數值辨識
- ✓ 桃園煉油廠現場儀表讀值辨識寫入CMMS
- ✓ 潤滑油事業部外桶與內容物辨識AI (YOLO)
- ✓ 油品行銷事業部智慧加油
- ✓ 綠能所無人機太陽能板故障辨識
- ✓ 管線外部腐蝕辨識
- ✓ 人事訓練所學員報到(YOLO)
- ✓ 石化前鎮儲運所槽車卸收的影像辨識連鎖智慧工安



# ✓各事業部智慧工安(以CCTV影像辨識)

## (1)CCTV影像辨識 應用於工安

- 人員接近危險區域之警報，例如深坑。
- 危險移動機具靠近人員時警報。
- 個人防護具，如安全帽，安全帶。

## (2)其他工安管理



Source: 鑫蘊林科公司



# 天然氣掛橋管線智慧巡檢系統應用(YOLO V4)

## 無人機選擇和配置

### 使用機型

HJ-X9E 台製單軸無人機: 13kg



嘉義月眉潭橋無人機巡檢



# 天然氣掛橋管線智慧巡檢系統應用

## 管線AI辨識照片(裸露、PE破損)





# 天然氣掛橋管線智慧巡檢系統應用

## 月眉潭橋管線受損修補AI辨識效果



管線受損AI辨識率  
86%





## 潤滑油事業部外桶與內容物辨識AI (YOLO)

- 配合現場作業流程，改用Yolo偵測技術訓練影像辨識模型
- 佈署模型至邊緣AI裝置，解決PC過熱問題



- ✓ 石化林園廠新三輕現場工業儀表的數值辨識
- ✓ 桃園煉油廠現場儀表讀值辨識寫入CMMS

# 全廠智能巡邏系統

## AI辨識技術

APP可自動解讀錶頭內指針數值



## 熱影像辨識



讀取熱像儀數值  
(圖面十字靶心位置)  
並記錄於APP上





✓ 油品行銷事業部智慧加油

# 加油智能化系統現行架構說明



防止加錯油




自動判別車輛油品

 <p><b>工業安全</b> CCTV結合智慧工安</p>	 <p><b>設備維護</b> 靜態機械故障預測 旋轉機械轉軸壽命預測 地下長距離管線漏油 設備故障預測 馬達電流異常</p>	 <p><b>製程優化</b> 設備效能及能源消耗 運轉異常及數據庫建立的 數據分析</p>	 <p><b>綜合項目</b> 前鎮儲運所試煉場域建置 (往後式足給機設備健康 指標)</p>
---	--	---	--



# ✓ 綠能所無人機太陽能板故障辨識



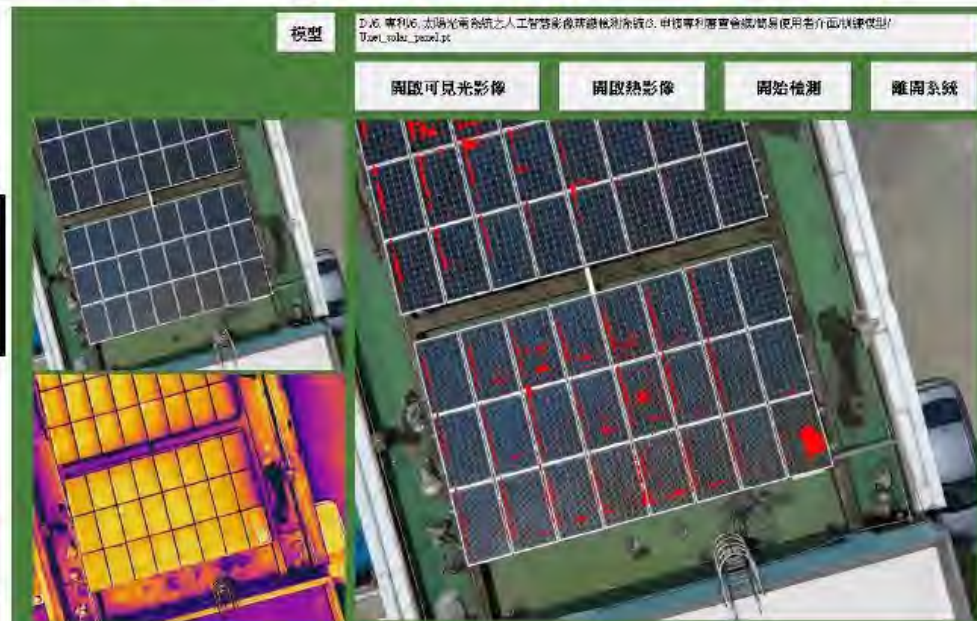
## • AI類神經網路深度學習

訓練週期



## • 使用者介面：判斷疑似缺陷區域

112年中國石油學會論文「銀獎」，專利申請中





# 石化前鎮儲運所槽車卸收的影像辨識連鎖智慧工安

- AI模型辨識核心
  - 設定有效辨識區域並同時判別區域中多個不同項目(安全帽、輪檔、接地線、鑰匙等)。
  - 有效辨識區域多人同時入鏡也可同時受到辨識判斷。



## 石化前鎮儲運所槽車卸收的影像辨識連鎖智慧工安

- 判別司機是否正確擺放接地線，方能開始灌裝作業。
- 若車體上擺放其他物品，不會被辨識為接地線





## 石化前鎮儲運所槽車卸收的影像辨識連鎖智慧工安

### 即時監控-異常發生通知

- 1.儀表板即時警訊通知並搭配現場蜂鳴器。
2. Line即時推播告警通知。



# 馬達電流頻譜影像識別應用於轉動機械之故障診斷與預測

(CNN AI / YOLO V3)

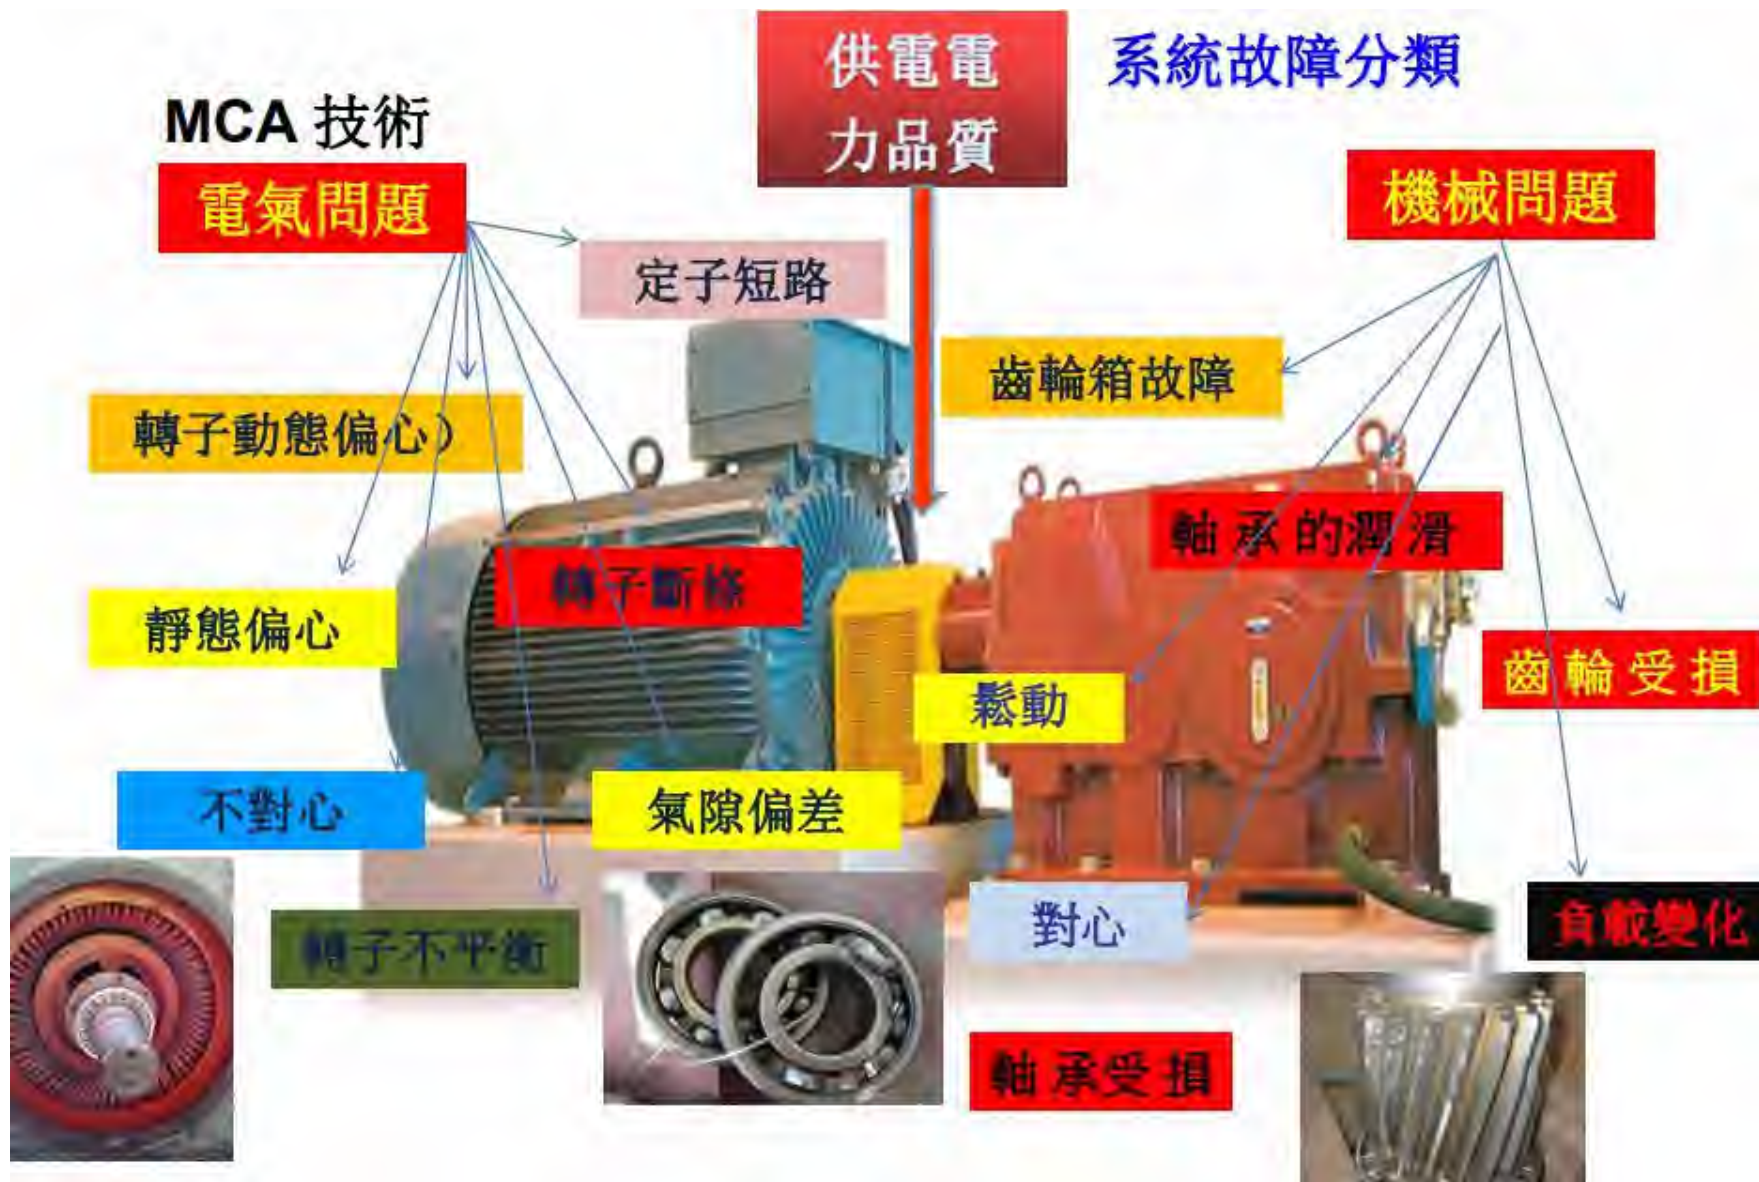
109年中國石油學會特優論文

112年國家玉山獎

113年台北智慧城市創新應用獎




總工程師室儀控轉機中心 + 煉製研究所 + 大林煉油廠儀電組





✓ 馬達電流頻譜分析技術  
MCSA” Motor Current Signal Analysis “




基座

轉子

電氣


## 電流頻譜分析——轉子故障




轉子斷條: 超過-35dB的轉差頻邊帶

# 電流頻譜分析——偏心

## 靜態偏心




## 動態偏心





## 電流頻譜分析——定子匝間短路



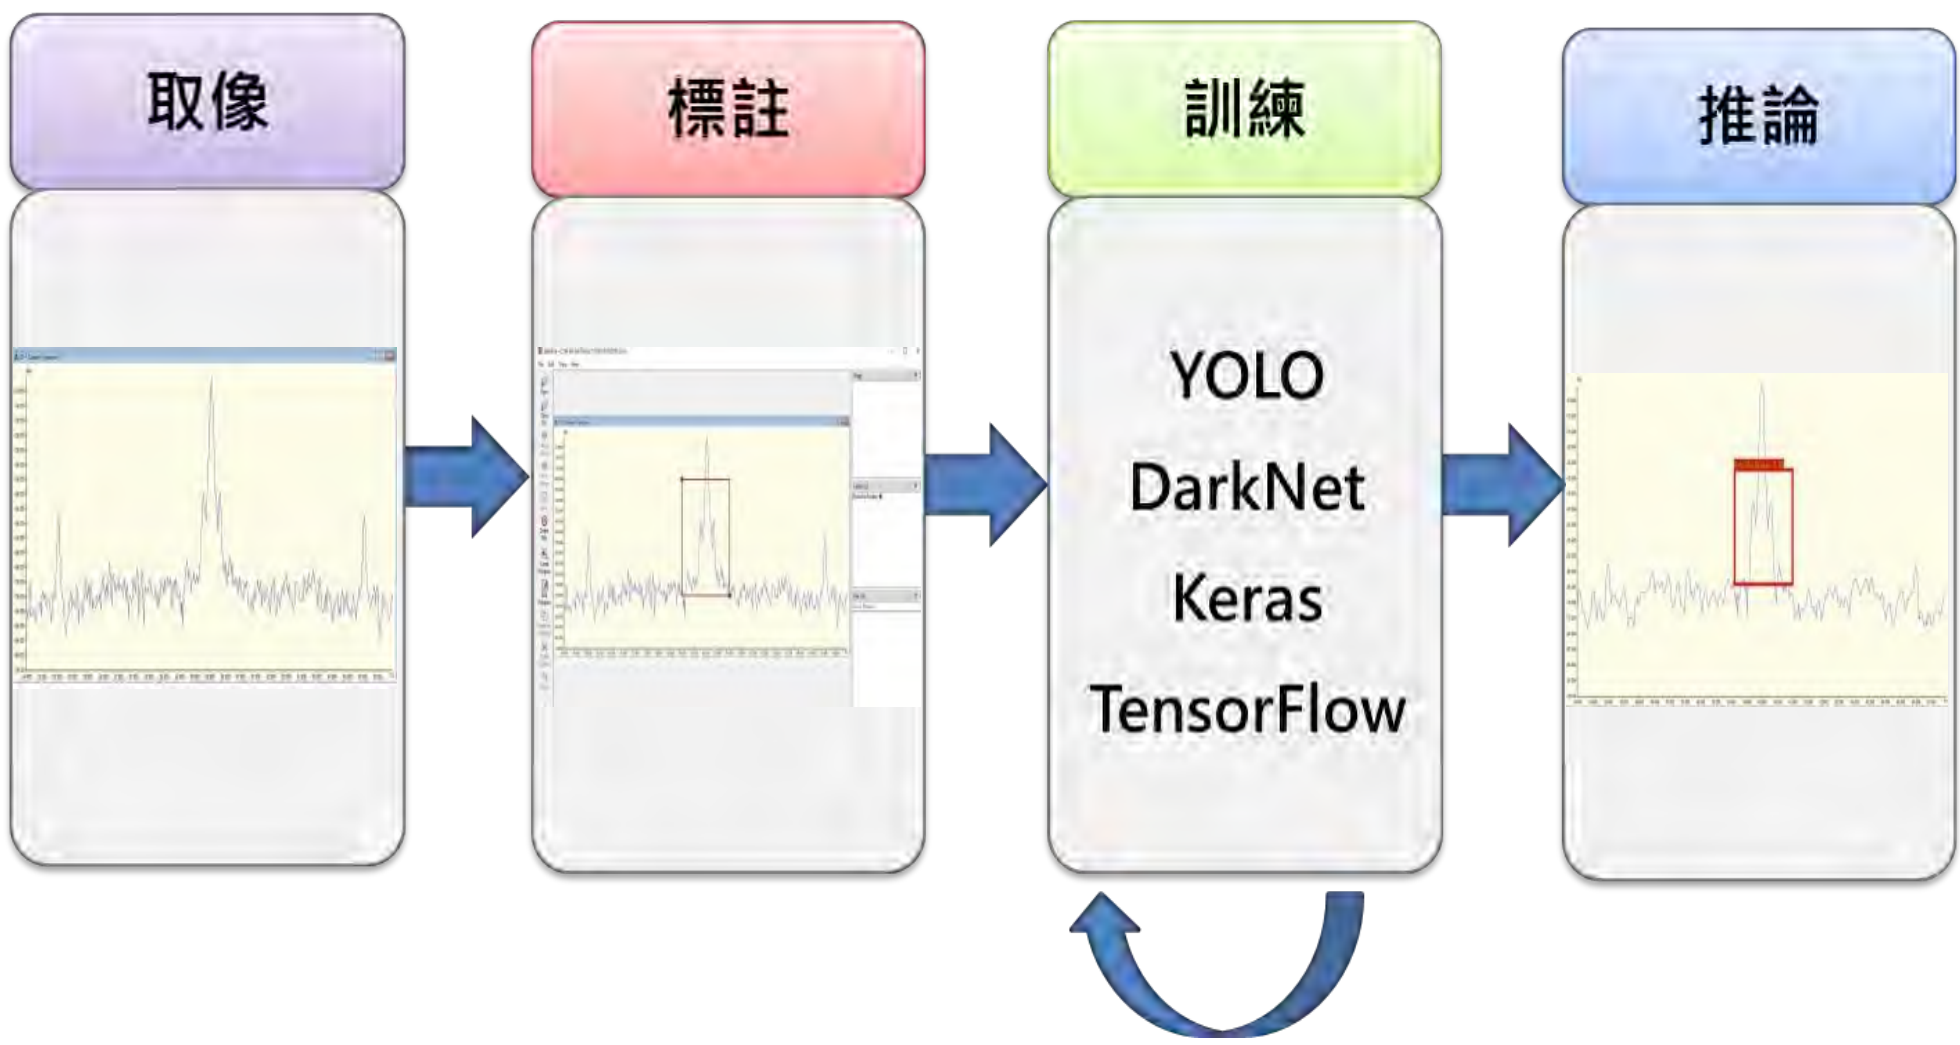
定子槽頻 $CF = \text{轉頻}RF \times \text{定子槽數} = 24.33 \times 48 = 1168\text{Hz}$

## 電流頻譜分析——機械不平衡



$$CF = \text{轉頻} RF \times \text{轉子條數} = 24.33 \times 40 = 973.2\text{Hz}$$

A





# (1) 取像

公用組							
公用-第一動力	C-401	M-806	C-901	G-901(發電機)	P-902B	P-902C	C-1001
公用-第一動力	C-2327	C-1002	C-2001F	FP-404	FP-405	P-2502	P-2504
公用-第一動力	P-2505	P-2506	P-902B	P-2501	FP-403	C-2328	P-2503
第二動力	BM-651	C-2001A	C-2001B	C-2001C	C-2001D	C-2001E	C-2001G
第二動力	M-706	P-2901	P-2902	P-2904	P-2907	P-3001	
第二動力	P-3002	P-3003	P-3004	P-3005	P-3006	P-3007	P-3008
第二動力	P-3009	P-3010	P-3011	P-3012			
煉一組							
第九蒸餾工場	P-901A	P-901B	P-901C	P-952	P-953A	P-953B	
第十蒸餾工場	P-1001A	P-1001C	P-954	P-955A	P-955B	P-956A	P-956B
第十一蒸餾工場	C-101	C-102	C-103	P-101B	P-101C	P-102B	P-102C
第十一蒸餾工場	P-110B	P-110C	P-110D				
第九加氫脫硫工場	C-7301A	C-7301B	P-7001A	P-7001B			
正烷烴 熱油循環	PM-8501A	PM-8501B					
正烷烴 I.D.F	C-8502						
1-FGRS	P-2383A	P-2383B	P-2383A	P-2383A			
煉二組							
第一重油脫硫工場	C-2001A-M	C-2001B-M	C-2001C-M	P-2001A	P-2001B	P-2002A	P-2002B
第一重油脫硫工場	P-2003A-M	P-2003B-M					
第六硫磺工場	C-6301A (SPACE)	C-6301A (運輸中)	C-6301A	C-6301B	C-6301C	C-6301C	
第二氯氣工場	C-2201B	C-2202B	C-2203A	C-2203B	C-2204		
GHDS	CM-2702						
重油裂解工場	C-3102	CM-3101	G-3101	P-3103A			
煉三組							
2GHDS	C-3001A	C-3001B	P-3001A	P-3001B			
3RDS	C-3001B	C-3001C	C-3003A	C-3003B	P-3001B	P-3002A	P-3002B
3RDS	P-3005A	P-3011A	P-3011B	P-3011C			
10SRU	C-1301A	C-1301B	C-1351A	C-1351B			
8SRU	C-3401A	C-3401B	C-3451A	C-3451B			
烷化	C-1001A	C-1001B	C-2001	CM-4001	R-2001A	R-2001B	R-2001C
烷化	R-2001D	R-2001E	R-2001F				
煉四組							
第十加氫脫硫工場	CM-1301A	CM-1301B	PM-1001A	PM-1001B			
第十二蒸餾工場	D-1201	D-1202	D-1230	P-1201A	P-1201B	P-1201C	P-1202A
第十二蒸餾工場	P-1202B	P-1202C	P-1209A	P-1209B	P-1209C	P-1231A	P-1231B
第十二蒸餾工場	C-1203						
12-KHDS	CM3201A	CM3201B	CM3301A	CM3301B	PM3001A	PM3001B	
11-DHDS	CM-2301A	CM-2301B	PM-2001A	PM-2001B			
煉五組							
4HPU	P-6101A	P-6101B	P-6105A	P-6105B			
5RU	C-5201A	C-5201B	C-5302A	C-5302B	C-5302C	C-5303A	C-5303B
5RU	C-5351	P-5153A	P-5153B	P-5153C	P-5155A	P-5155B	P-5155C
5RU	P-5201A	P-5201B					
6RU	C-6201A	C-6201B	C-6302A	C-6302B	C-6302C	C-6303A	C-6303B
6RU	P-6153A	P-6153B	P-6153C	P-6155A	P-6155B	P-6155C	P-6201A
6RU	P-6201B						
RFCC	P-1101A	P-1101C	P-1801A	P-1801B	P-1802A	P-1802B	P-2100A
RFCC	P-2100B	P-2101A	P-2101B	P-2102A	P-2102B	P-2108A	P-2108B
RFCC	P-2109B	P-2203A	P-2302A	P-2302B	P-3151A	P-3151B	P-3151C

公用組							
公用-第一動力	C-401	M-806	C-901				
公用-第一動力							
公用-第一動力							
第二動力	BM-651	C-2001A	C-2001B				
第二動力							
第二動力							
第二動力							
煉一組							
第九蒸餾工場	P-901A						
第十蒸餾工場	P-1001A						
第十一蒸餾工場	C-101						
第十一蒸餾工場							
第九加氫脫硫工場	C-7301A						
正烷烴 熱油循環	PM-8501A						
正烷烴 I.D.F							
1-FGRS	P-2383A						
煉二組							
第一重油脫硫工場	C-2001A-M						
第一重油脫硫工場							
第六硫磺工場	C-6301A (SPACE)						
第二氯氣工場	C-2201B						
GHDS	CM-2702						
重油裂解工場	C-3102						
煉三組							
2GHDS	C-3001A						
3RDS	C-3001B	C-3001C	C-3003A				
3RDS							
10SRU	C-1301A						
8SRU	C-3401A						
烷化	C-1001A	C-1001B					
烷化							
煉四組							
第十加氫脫硫工場	CM-1301A						
第十二蒸餾工場	D-1201	D-1202					
第十二蒸餾工場							
第十二蒸餾工場							
12-KHDS	CM3201A						
11-DHDS	CM-2301A						
煉五組							
4HPU	P-6101A						
5RU	C-5201A	C-5201B	C-5302A	C-5302B			
5RU							
5RU							
6RU	C-6201A	C-6201B					
6RU							



# (1)取像

馬達電流頻譜測量紀錄(all全部) - Excel (產品啟動失敗)

檔案 常用 插入 版面配置 公式 資料 校閱 檢視 告訴我您想要執行的動作... 登入 共用

剪貼簿 字型 對齊方式 數值 樣式 儲存格 編輯

L43

	A	B	C	D	E	F	G	H	I	J	K	L
1	煉製二組		#1	#2	#3	#4	#5	#6	#1備註	#2備註	#3備註	
26	P-2406A											
27	P-2406B											
28												
29	第六硫磺工場6SRU											
30	C-6301A		109年1月	109年3月	109年6月	109年7月	109年9月	109年10月				
31	C-6301B		109年1月	109年3月	109年6月	109年7月	109年8月				轉子斷條	
32	C-6301C		109年1月	109年3月	109年6月	109年7月	109年9月					
33	C-6401		109年3月	109年9月								
34	C-6401S		109年6月									
35	C-6402S											
36	P-6103		109年3月	109年9月								
37	P-6103C		109年6月									
38	P-6103S		109年6月									
39	P-6502		109年3月	109年6月	109年9月							
40												
41	第二氫氣工場2HU											
42	C-2201B		109年1月	109年3月	109年9月							
43	C-2202B		109年1月	109年3月	109年9月							

煉一組 煉二組 煉三組 煉四組 煉五組 公用組 海運組 陸運組

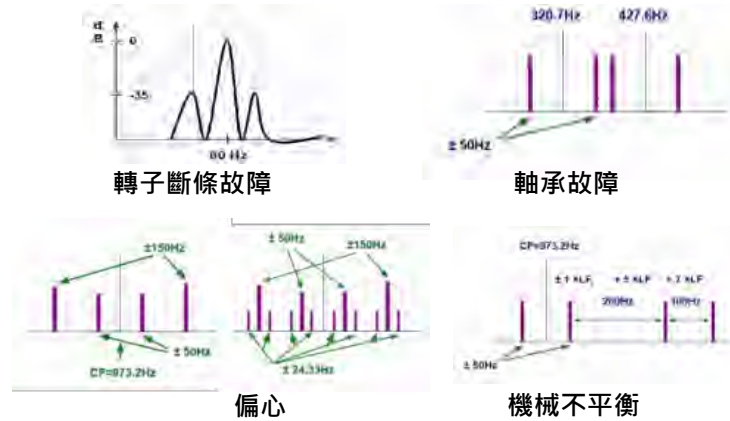
# (1)取像

## 1)收集馬達電流頻譜



以大林廠為例,自2018/11起,每月量測100台,目前超過6500台。

## 2)使用EXCEL區分設備狀況等級

3)將特定故障的頻譜分類,例如轉子斷條,偏心等



四種典型的故障頻譜





## (2) 標註




- 1) 將故障的頻譜, 例如轉子斷條, 將其特徵特點剪出來, 存成特殊檔
- 2) 沒有把特徵特點剪出來, 容易誤判
- 3) 收集越多的故障頻譜越好, 同一台可以檢出多個圖片



# (3) 訓練

1) 將剪出來的特種故障圖檔, 讀入Yolo V3的演算法進行訓練

2) 沒有用GPU的情況下, 大約要訓練4.5小時



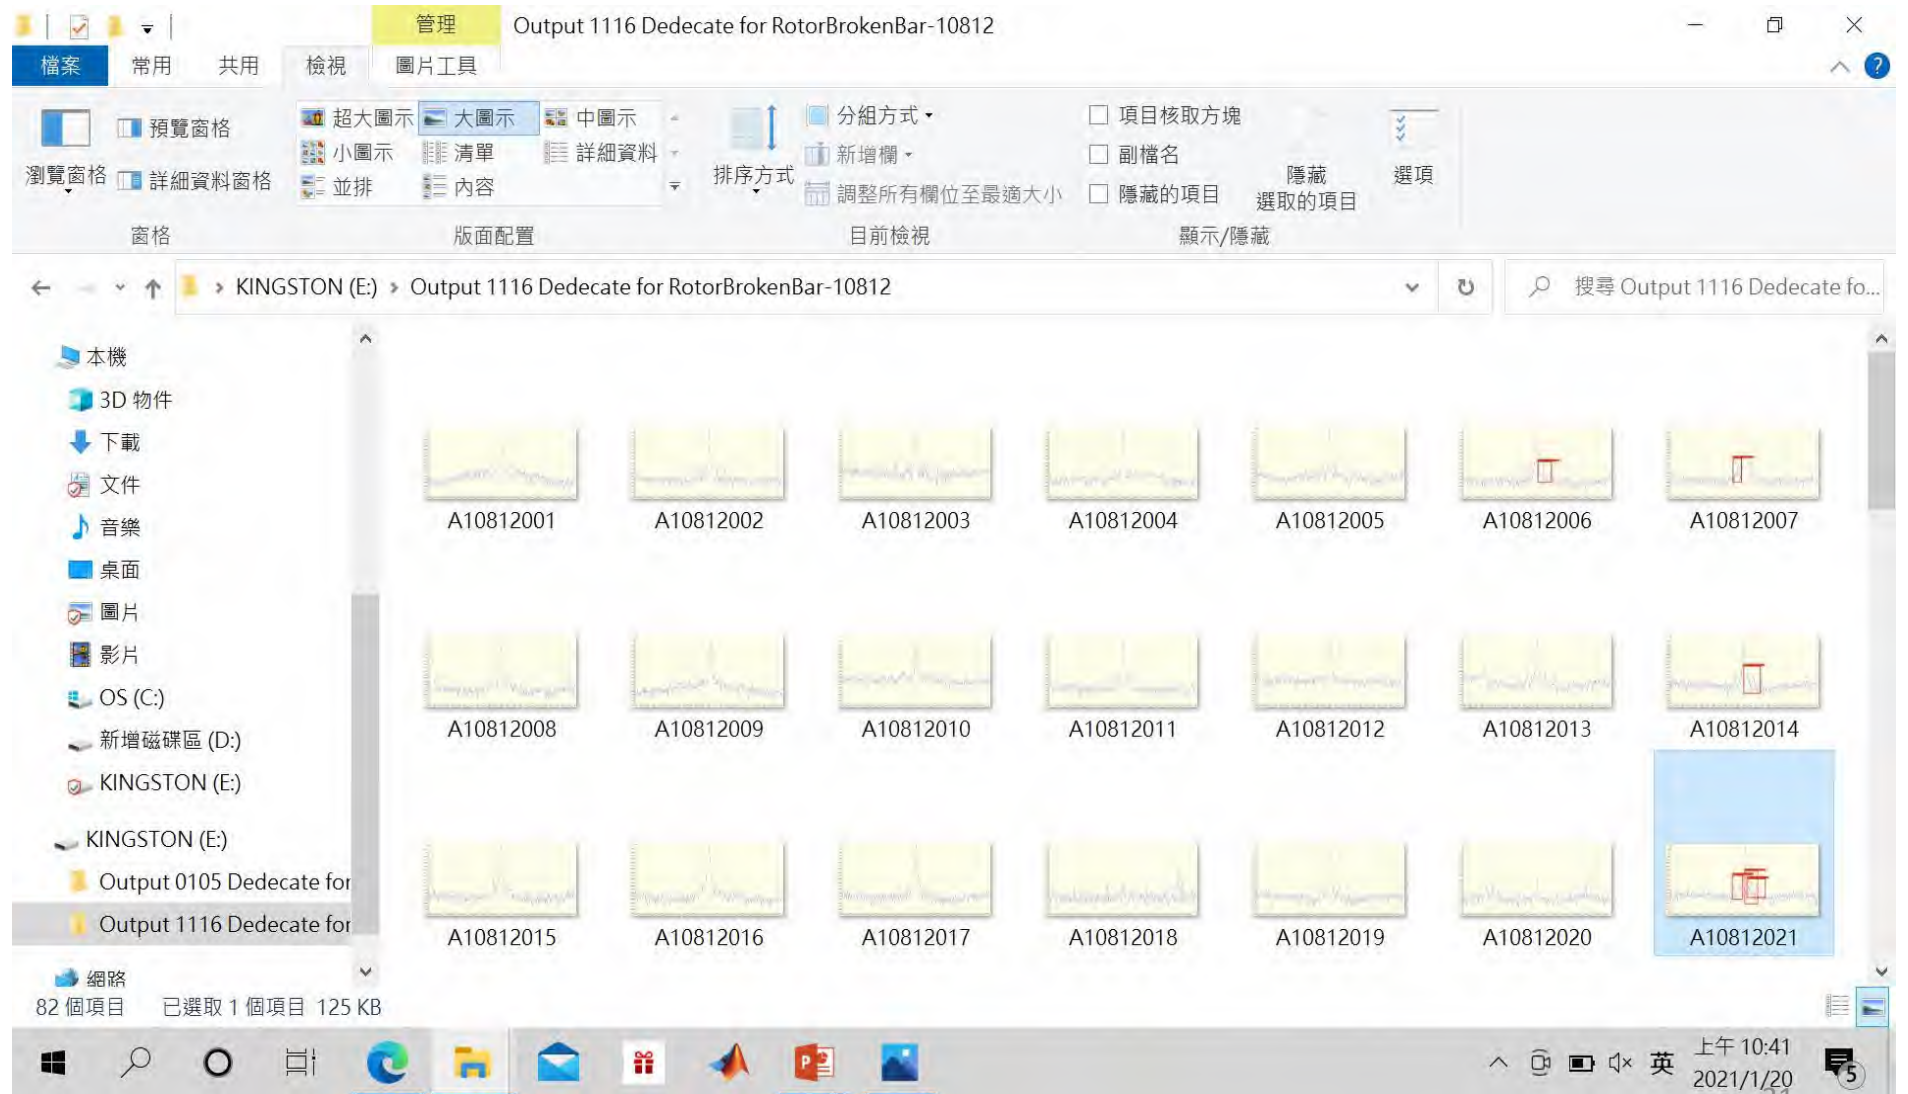


# (4)推論(上線測試)

1)將一個月收集而來的馬達電流頻譜,拷入硬碟

2)執行程式

3)程式會逐一影像辨識出故障頻譜,並且用方框標示出來










## AI 辨識發現硫磺C6301B異常



## 硫磺工場的C6301A/B/C電流頻譜






短路環裂縫：轉子鼠籠條數量46支

負載端異常處：16處：目視有龜裂為基準 自由端異常處：46處：目視有龜裂為基準








107年#1RDS C-2003B，也發生類似狀況，因沒有及時處理，邊環(短路環)炸開，整台馬達報廢。

# 成果

硫磺工場壓縮機無預警跳車，將影響RDS工場停爐及RFCC工場降煉量，預估效益8445萬元。

## 影響性

1. 前一年烷化工場核心壓縮機在故障前振動完全正常，啟動時突然劇烈震動故障，造成21天的停爐及進口汽油巨大損失。
2. 類似這種沒有振動的情況，突然發生故障，以往幾乎沒有辦法避免。




總工程師室 副總工程師 王朝民  
煉研所 燃料及潤滑劑組 王淑麗  
大林廠 黃玠華 李孟鴻  
謝金龍 李英齊 李彥賢

程式撰寫與訓練：王朝民  
資料收集：李孟鴻 謝金龍 李彥賢  
故障頻譜分析：黃玠華 李英齊  
標註：黃玠華  
論文撰寫：王淑麗

# 馬達電流頻譜 AI CNN 影像辨識影片展示





## AI伺服器與 邊緣AI(Edge AI)



# AI伺服器

## 什麼是 AI 伺服器？

(What is an AI Server?)



- 專為處理 AI 與機器學習設計
- 強大 CPU + 核心 GPU/加速卡
- 異質運算

## 功能與重要性

(Functions & Importance)



## 硬體組成

(Hardware Components)



## 功能與重要性

Functions & Importance



## 挑戰與散熱革命

Challenges & Cooling Revolution



## 未來趨勢

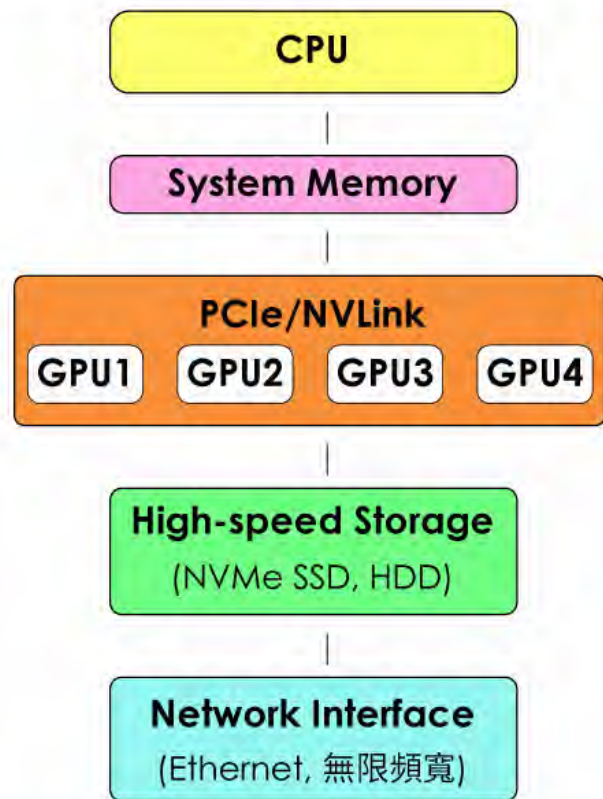
Future Trends





# AI伺服器

## AI 伺服器架構



## 伺服器種類

直立式伺服器  
( Pedestal server )

外觀如桌上型電腦  
體積龐大



機架伺服器  
( Rack server )

外觀按統一規格設計  
空間利用率佳



刀鋒伺服器  
( Blade server )

卡板式機座  
可插置多張單板電腦



圖片來源：iStock



# AI伺服器

## NVIDIA GPU與整機櫃TDP迭代整理

GPU型號	GPU TDP	機櫃型號	總機櫃TDP
H100	700W	HGX H100	≈10 ~ 30kW
B200	1200W	GB200 NVL72	≈130kW
B300	1400W	GB300 NVL72	≈145kW
Rubin	1800W	Vera Rubin NVL144	≈150kW
Rubin Ultra	3600W	Rubin Ultra NVL576	≈600kW

Source : TrendForce ; 拓墾產業研究院整理 ; 2025/07



# Edge AI(邊緣AI)



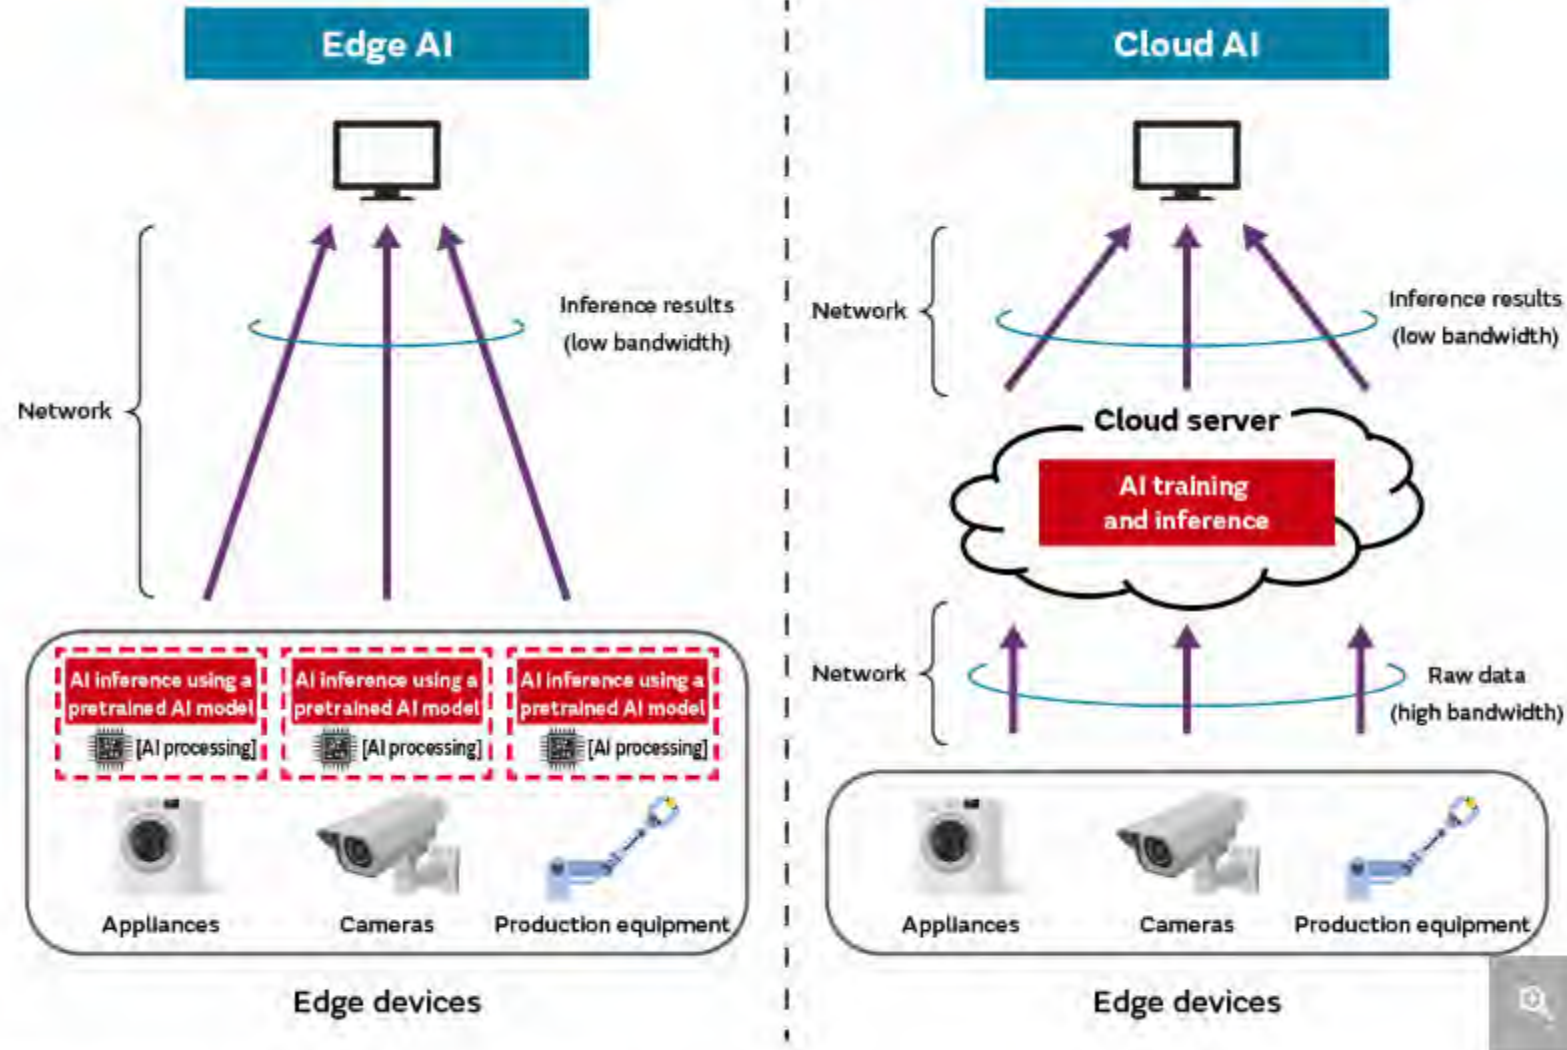
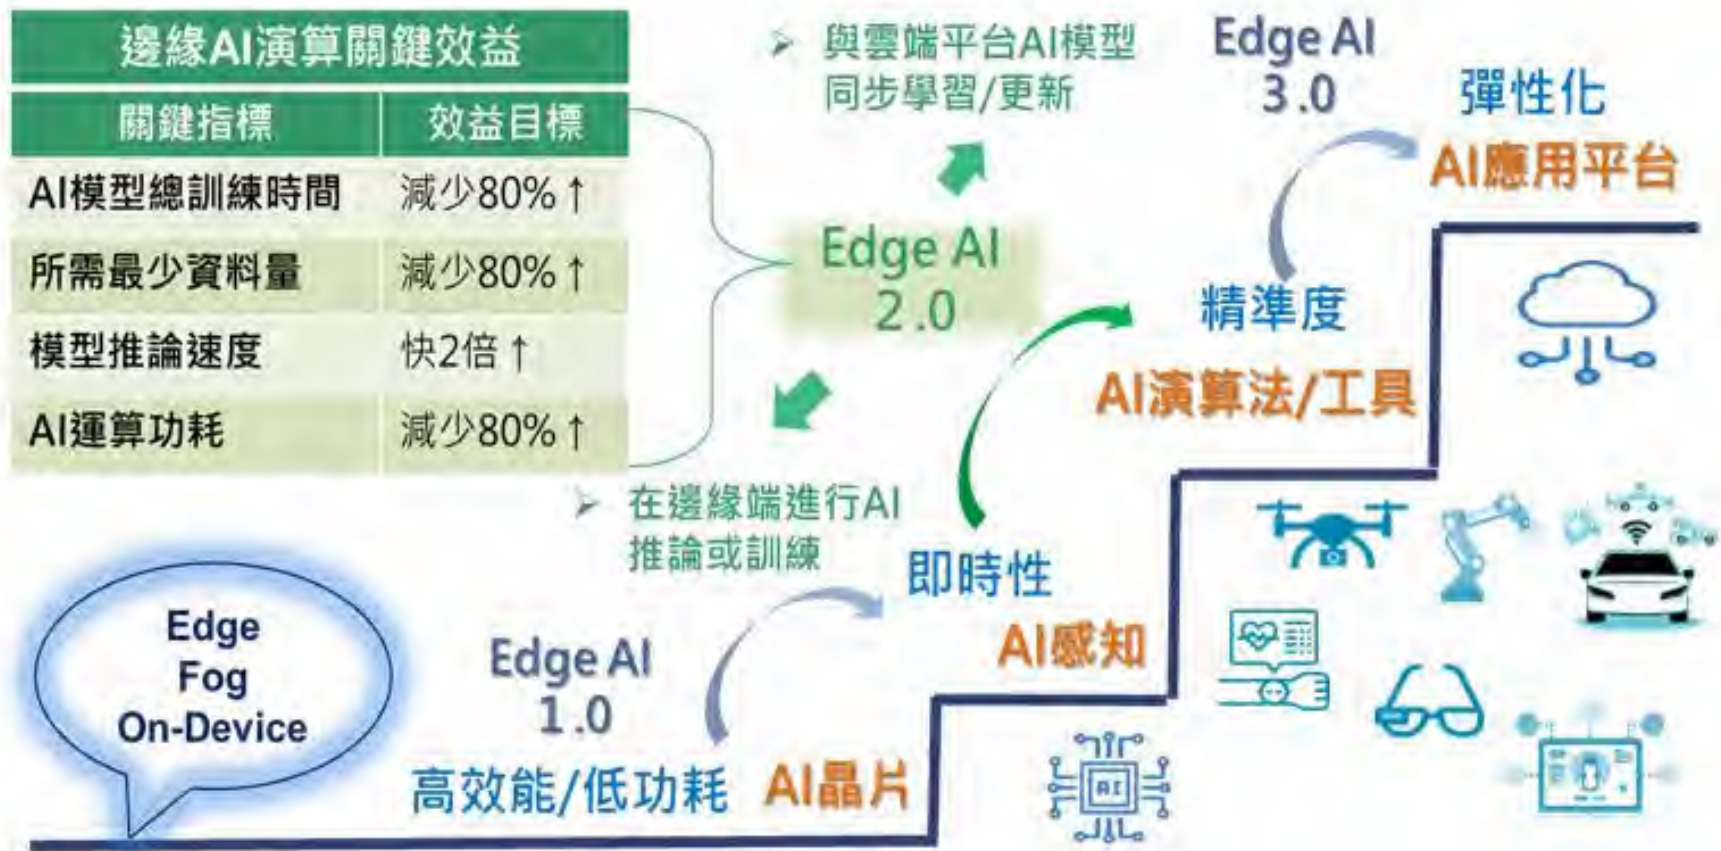
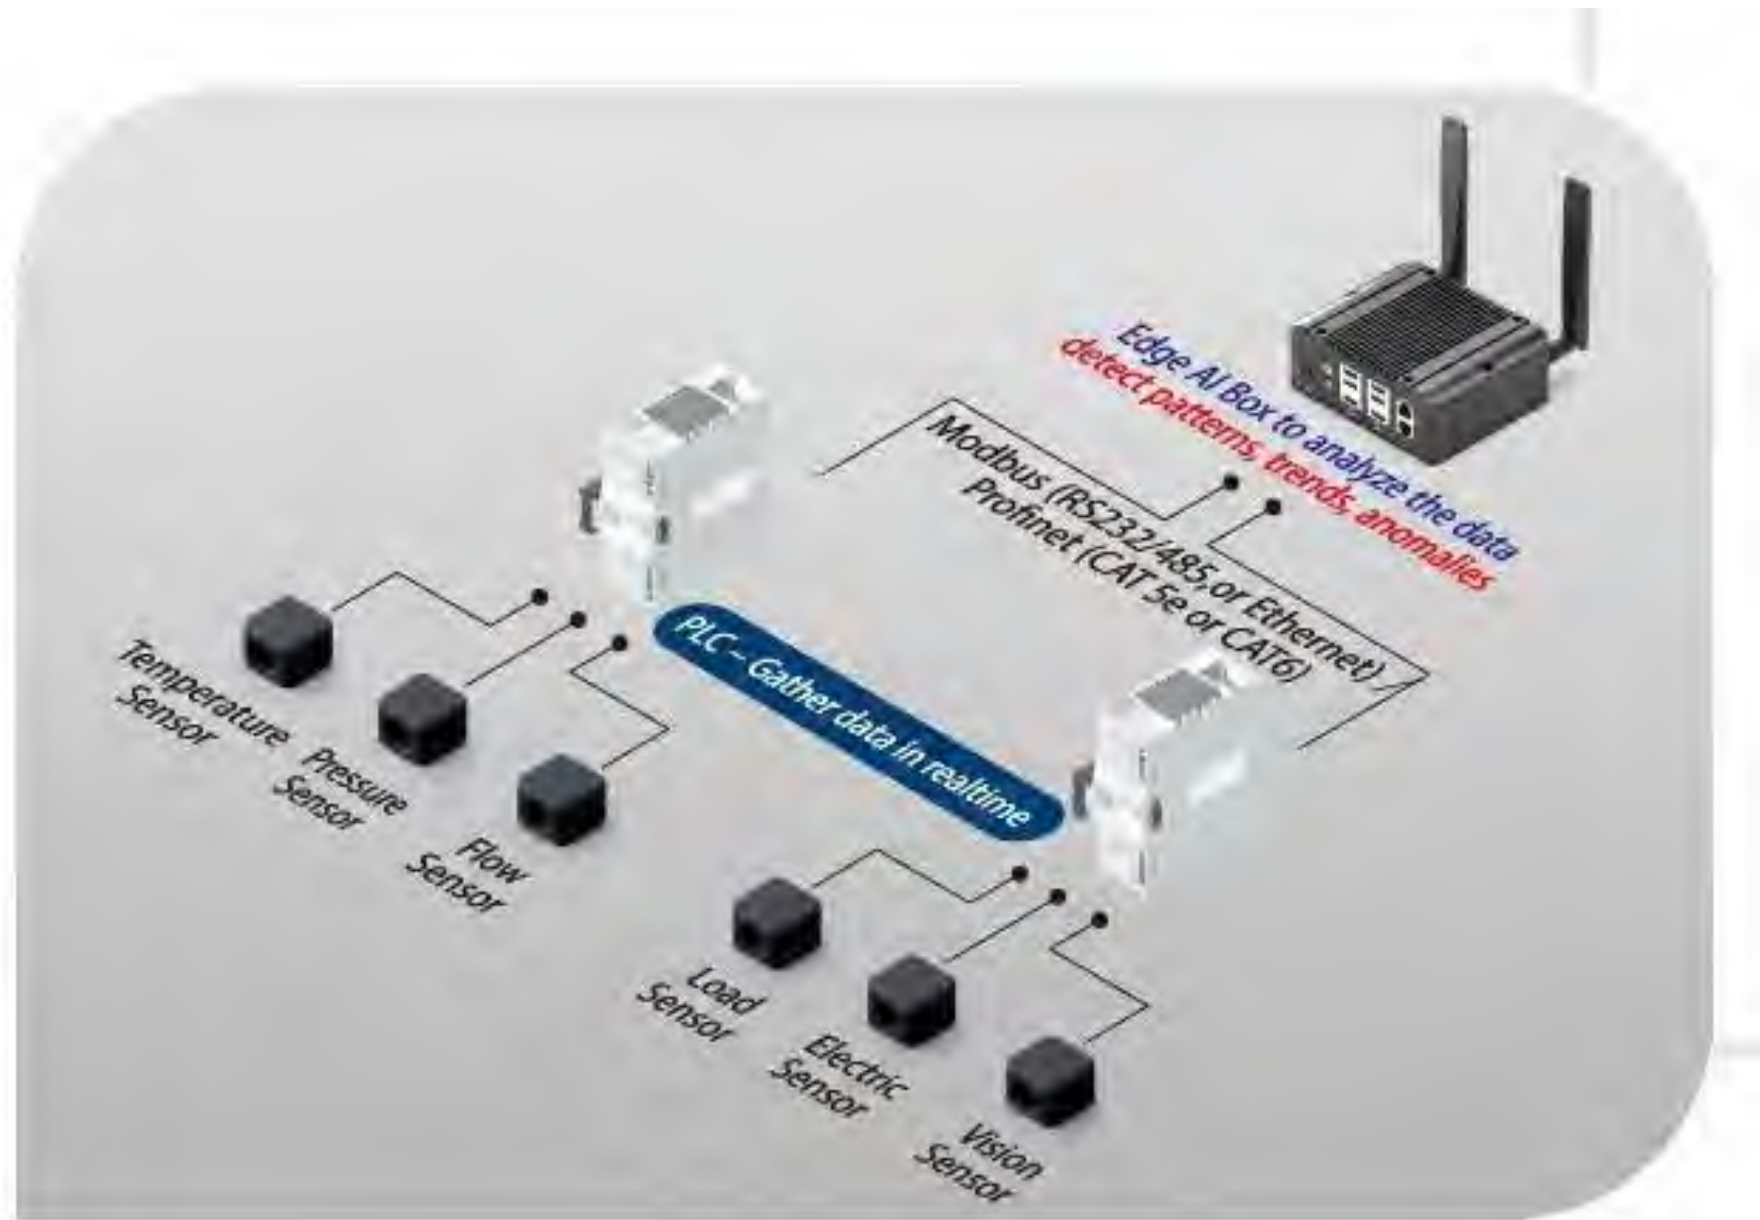



Figure 1 Elements of Edge AI and Cloud AI systems











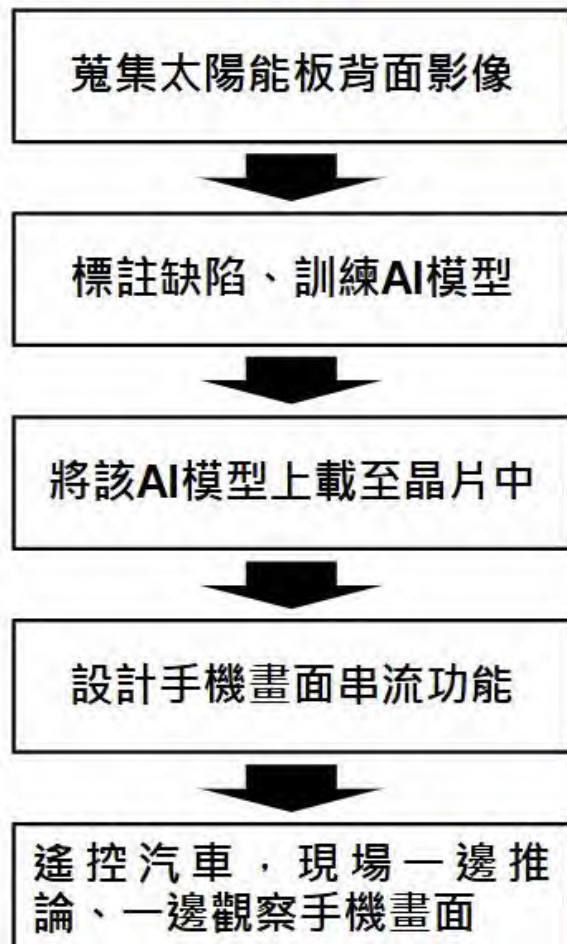
## 潤滑油事業部外桶與內容物辨識AI (YOLO)

- 配合現場作業流程，改用Yolo偵測技術訓練影像辨識模型
- 佈署模型至邊緣AI裝置，解決PC過熱問題



# 自行開發流程及架構(目前已進行的努力)

## 流程



## 具邊緣運算功能之移動載具架構





# PV案場實地測試(1/2)(目前已進行的努力)

## 流程





# AI技術研討

預測型AI與應用(設備預知保養,異常偵測,節能與最佳化)  
(第一堂課)

中油5G AIoT 推動辦公室

王朝民


2026 年 03 月 24 日



## 二、預測：節能省碳/產值提升/故障預測

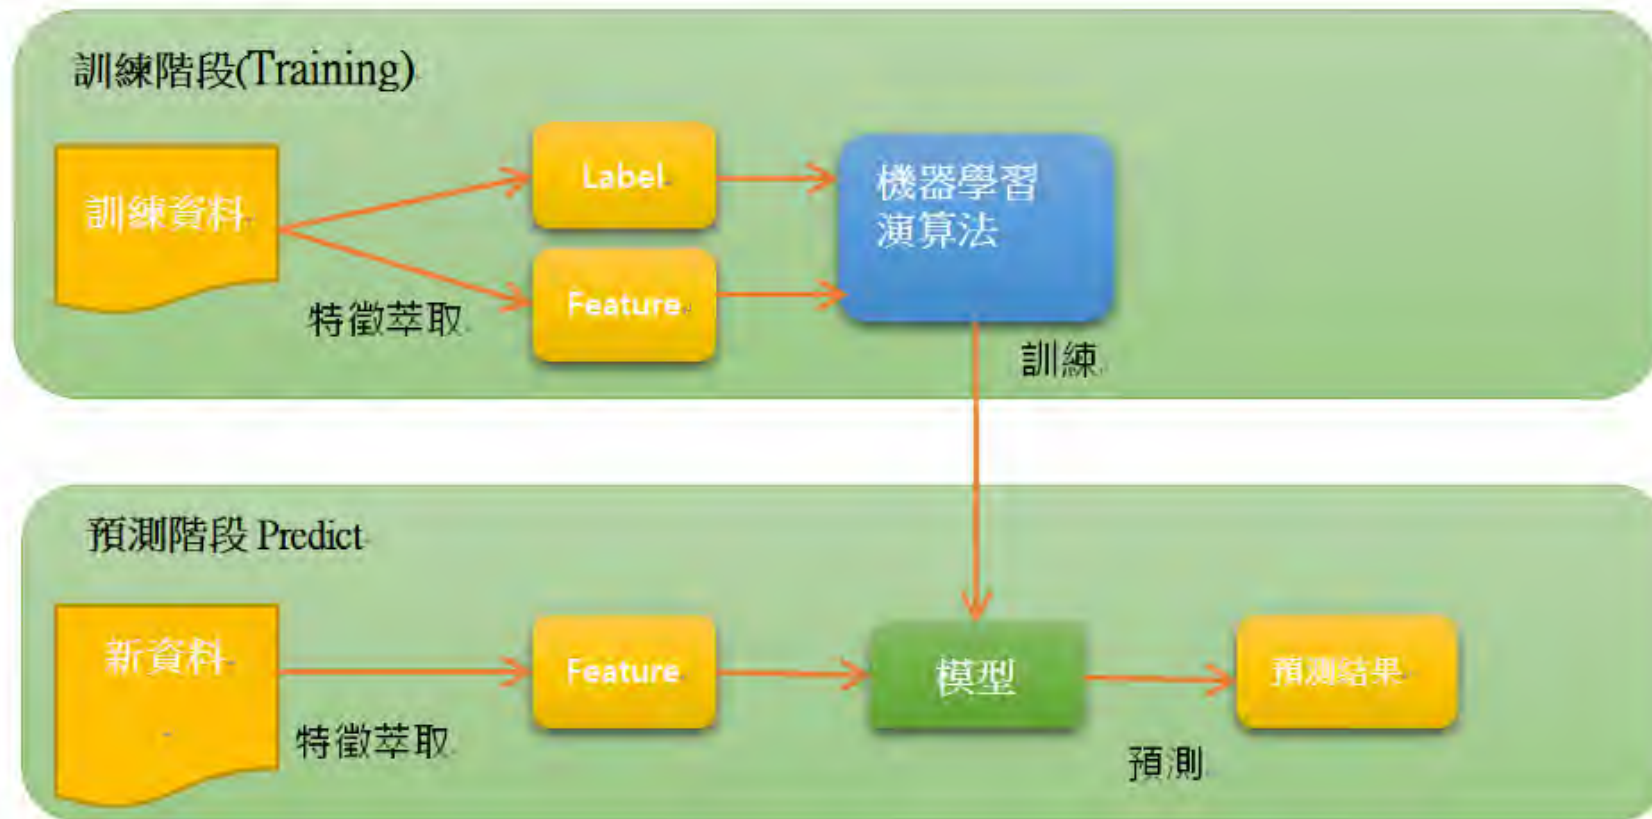


影像辨識  
(CNN)



預測  
(RNN)

# 機器學習的兩個階段





# 數值預測與狀態預測

## 狀態預測:

例如：糖尿病預測,鐵達尼號乘客生還預測,設備故障預測等

## 數值預測:

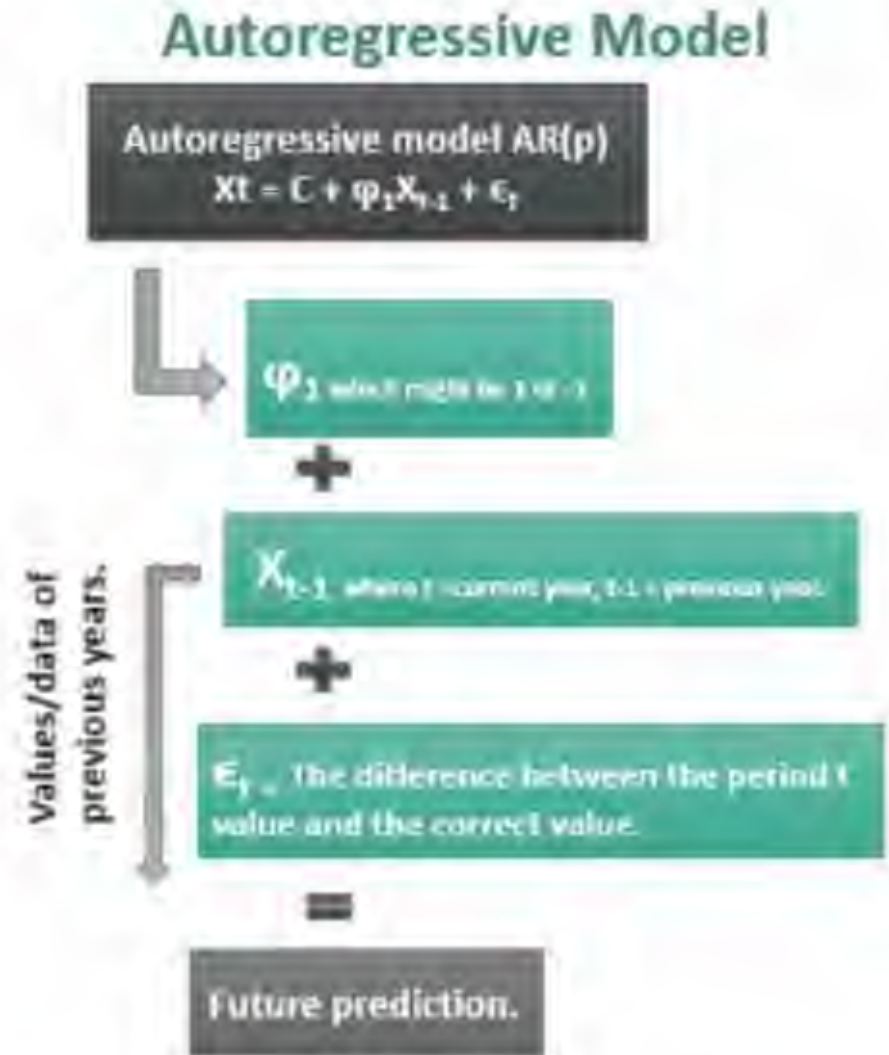
例如：波士頓房價預測,股價預測,化工廠轉化率預測,品質預測

數值預測有分**大數據**及與**時間是否相關**

## AR Modeling: (時間相關)

AR Modeling 可以由收集的歷史資料來預測未來的數值

具有這樣能力的原因是過去和現在具有**相關性(correlation)**



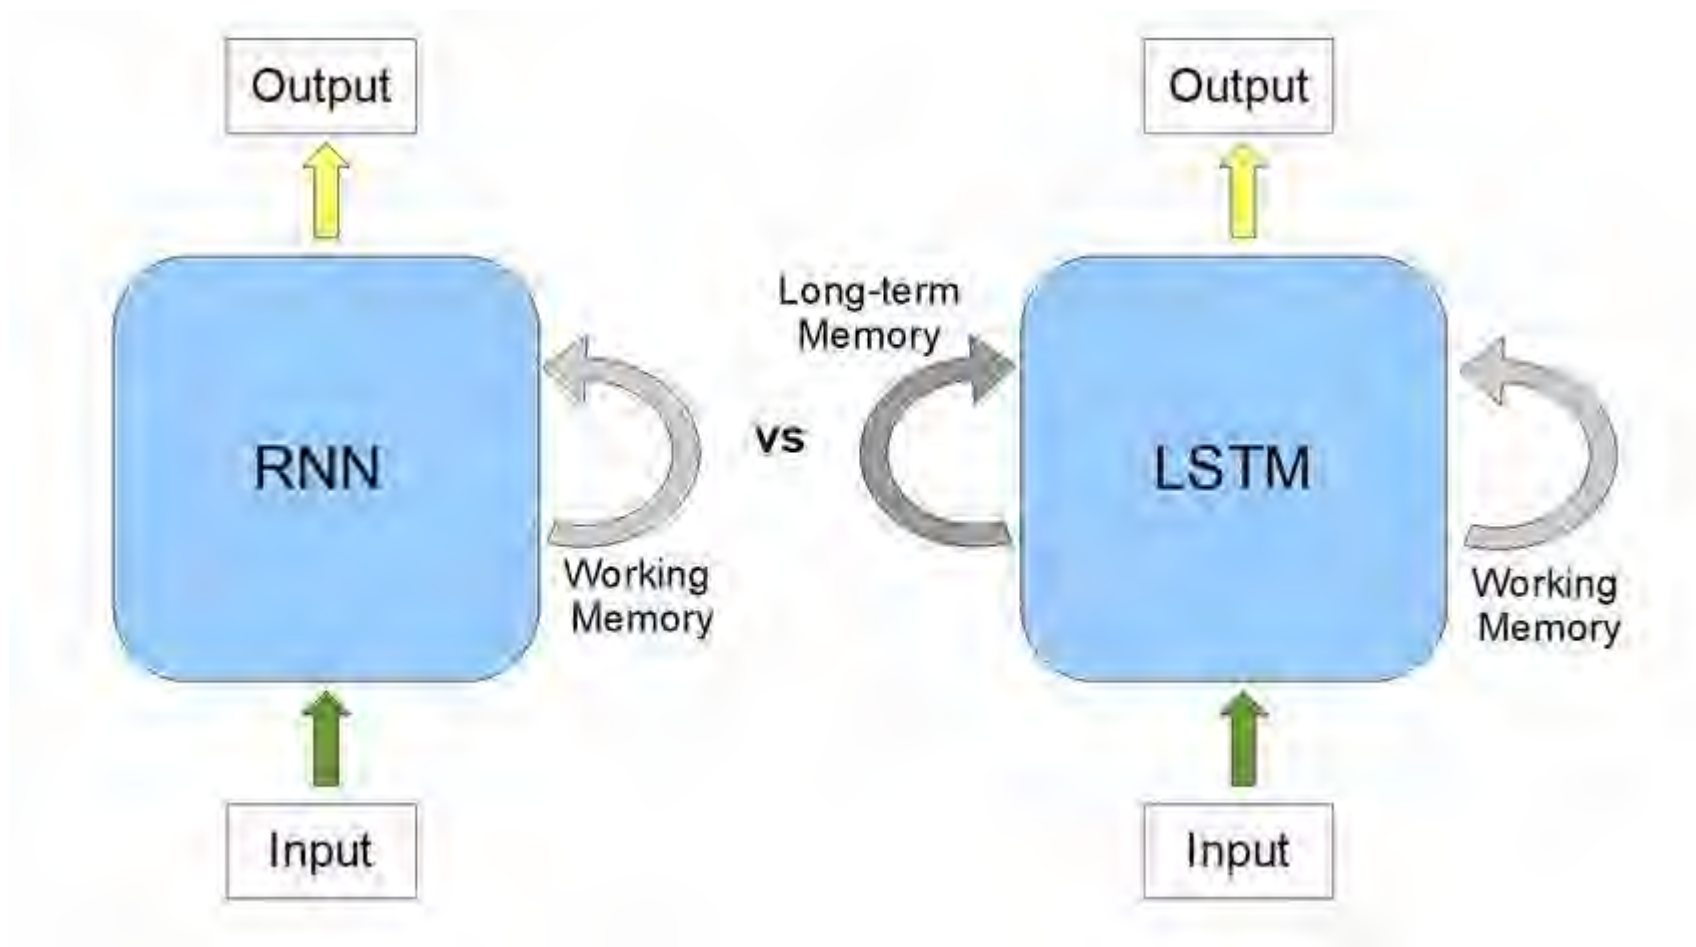
# 數值預測(與時間相關)

## LSTM與RNN

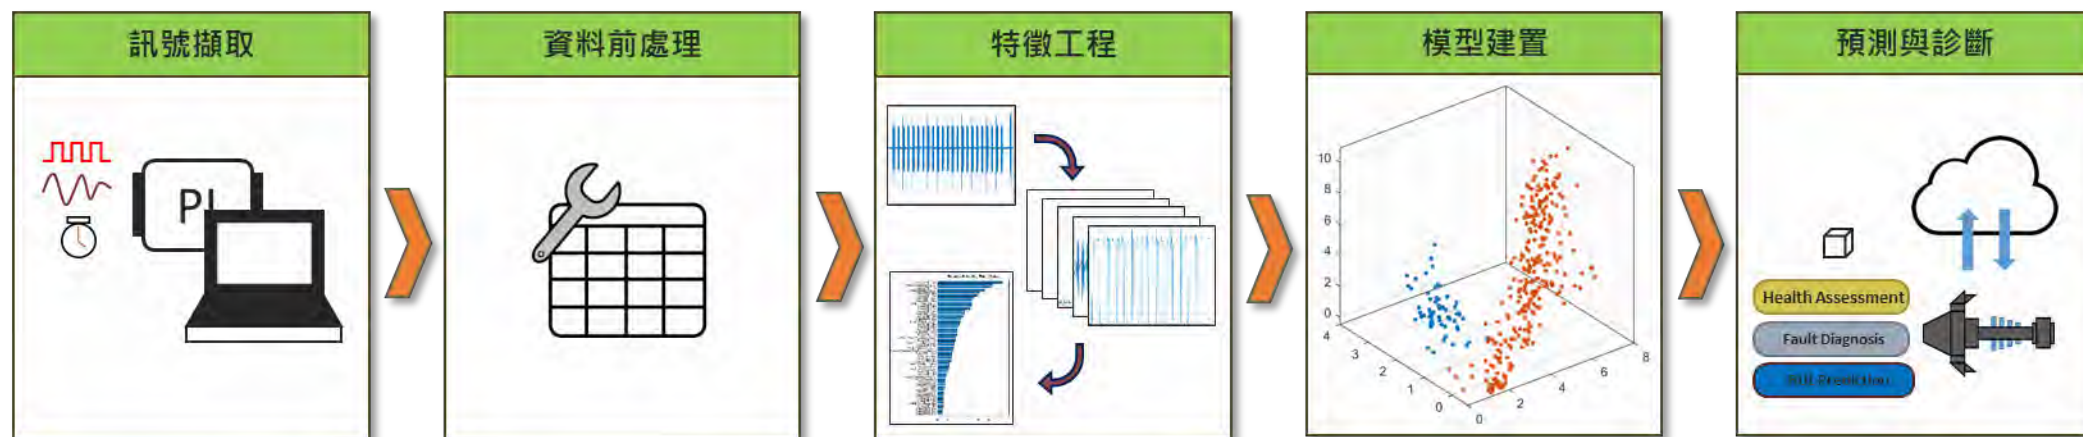
(1)LSTM是RNN的改良版

(2)RNN 會引起梯度爆炸或梯度消失,很難處理“長程依賴”問題

(3) LSTM可以避免梯度消失等問題,使網路學到長程的規律



# AI專案的建置



**訊號擷取：** (1)即時一般訊號(傳送器等) (2)即時超高速(暫態等) (3)歷史資料

**資料前處理：** (1)軟體或硬體濾波 (2)缺項或不合理值去除(資料清洗)

**特徵提取：** (1)理論模型中挑取 (2)執行統計學相關程式挑取 (3)專家經驗

**模型建置：** (1)各種演算法 (2)配套措施

**預測與診斷：** (1)訓練完的模型驗證



## 各種預測型AI專案:

# 中油預測AI應用介紹

- ✓ (1)石化前鎮所C-1304設備故障分類健康指標AI-實際接線  
(石化林園廠前鎮儲運所C-1304) 2021年中國石油學會銀獎論文
- (2)地下長途管線測漏(機械學習、深度學習)-實際接線  
(長途管線處70m IP管線實測成功) (112/2與112/4)  
(39公里長途管線測試成功) (114/02)
- (3)大林廠維修工場廢油泵多重故障預測-實際接線  
(大林煉油廠修護工場) 2022年中國石油學會銀獎論文
- ✓ (4)台中天然氣廠關鍵設備電源供應器性能預測AI-實際接線  
2024年國家品質玉山獎最佳產品及全國首獎
- ✓ (5)大林廠RFCC膨脹機C1201觸媒粉阻塞預測 - PI
- ✓ (6)天然氣事業部林口配氣站熱值摻配最佳化AI
- ✓ (7)大林廠GHDS C8002葉輪斷裂預測AI- PI
- ✓ (8)大林廠第十二蒸餾先進製程控制APC、石化林園廠乙烯降低白贈值提高產能AI
- ✓ (9)探採研究所地熱井地熱預知AI
- ✓ (10)探採事業部油泥噴發預測AI
- (11)台中廠海水泵節能AI
- (12)石化林園廠乙烯降低白贈值提高產能AI
- (13)探採事業部碳封存預測AI 2025年國家品質玉山獎全國首獎
- 其他: (14)使用聲音訊號的壓縮機故障預知





圖 27 預兆診斷模型預測響應



(應用範例一)


## APC 先進製程控制

大林廠#12蒸餾工場APC案例

石化林園廠乙烯降低白贈值提高產能AI

## (一) 預測範例：預測歐元/美元的比值

(1) 由美國聯邦儲備銀行網站抓取2010年至2019年的歐元/美元的比值



The Data



(2)Python的程式,由Keras,兩層LSTM,一個輸出層構成

```
from keras.models import Sequential
from keras.layers import LSTM, Dense
from keras.callbacks import ReduceLROnPlateau #Learning rate scheduler for when we reach
rlrop = ReduceLROnPlateau(monitor='val_loss', factor=0.1, patience=100)

# Reset model if we want to re-train with different splits
def reset_weights(model):
    import keras.backend as K
    session = K.get_session()
    for layer in model.layers:
        if hasattr(layer, 'kernel_initializer'):
            layer.kernel_initializer.run(session=session)
        if hasattr(layer, 'bias_initializer'):
            layer.bias_initializer.run(session=session)

# Epochs and validation split
EPOCHS = 201
validation = 0.05

# Instantiate the model
model = Sequential()

# Add the first layer... the input shape is (Sample, seq_len-1, 1)
model.add(LSTM(
    input_shape = (sequence_length-1, 1), return_sequences = True,
    units = 100))

# Add the second layer... the input shape is (Sample, seq_len-1, 1)
model.add(LSTM(
    input_shape = (sequence_length-1, 1),
    units = 100))

# Add the output layer, simply one unit
model.add(Dense(
    units = 1,
    activation = 'sigmoid'))

model.compile(loss = 'mse', optimizer = 'adam')


# History object for plotting our model loss by epoch
history = model.fit(X_train, y_train, epochs = EPOCHS, validation_split = validation,
    callbacks = [rlrop])
```

## 使用LSTM 進行歐元/美元比值預測

```
Epoch 1/201  
2130/2130 [=====] - 5s 2ms/step - loss: 0.0349 - val_loss: 0.0051  
Epoch 2/201  
2130/2130 [=====] - 4s 2ms/step - loss: 0.0306 - val_loss: 0.0078  
Epoch 3/201  
2130/2130 [=====] - 4s 2ms/step - loss: 0.0307 - val_loss: 0.0070  
Epoch 4/201  
2130/2130 [=====] - 4s 2ms/step - loss: 0.0296 - val_loss: 0.0053  
Epoch 5/201
```

Training the Model

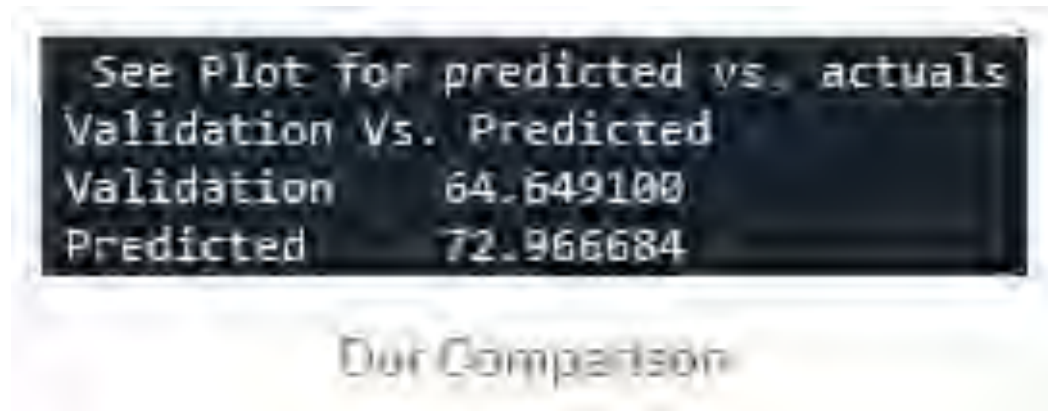
(3)經由多次的訓練  
(Epoch),觀察Loss減少至可接受的值



Model Loss by Epoch

## 使用LSTM 進行歐元/美元比值預測

(4)由LSTM預測的值,  
與實際的值比對,並且  
畫出曲線




Network: Feeding Prediction Back Into the Model




## 使用LSTM 進行歐元/美元比值預測

(5)右圖為執行LSTM  
預測未來15天的結果,  
本方法可以適用於  
股票預測,溫度預測..  
等



(3)LSTM的數值預測,可以取代線上分析儀,或者是成為“獨一無二的軟體分析儀”,弭補化驗資料取得時間太久的缺點

由上面的例子,使用LSTM 預測數值(也可以用各種演算法),搭配適當的工作配套,就可以達到節省能源,提高產能或故障預測






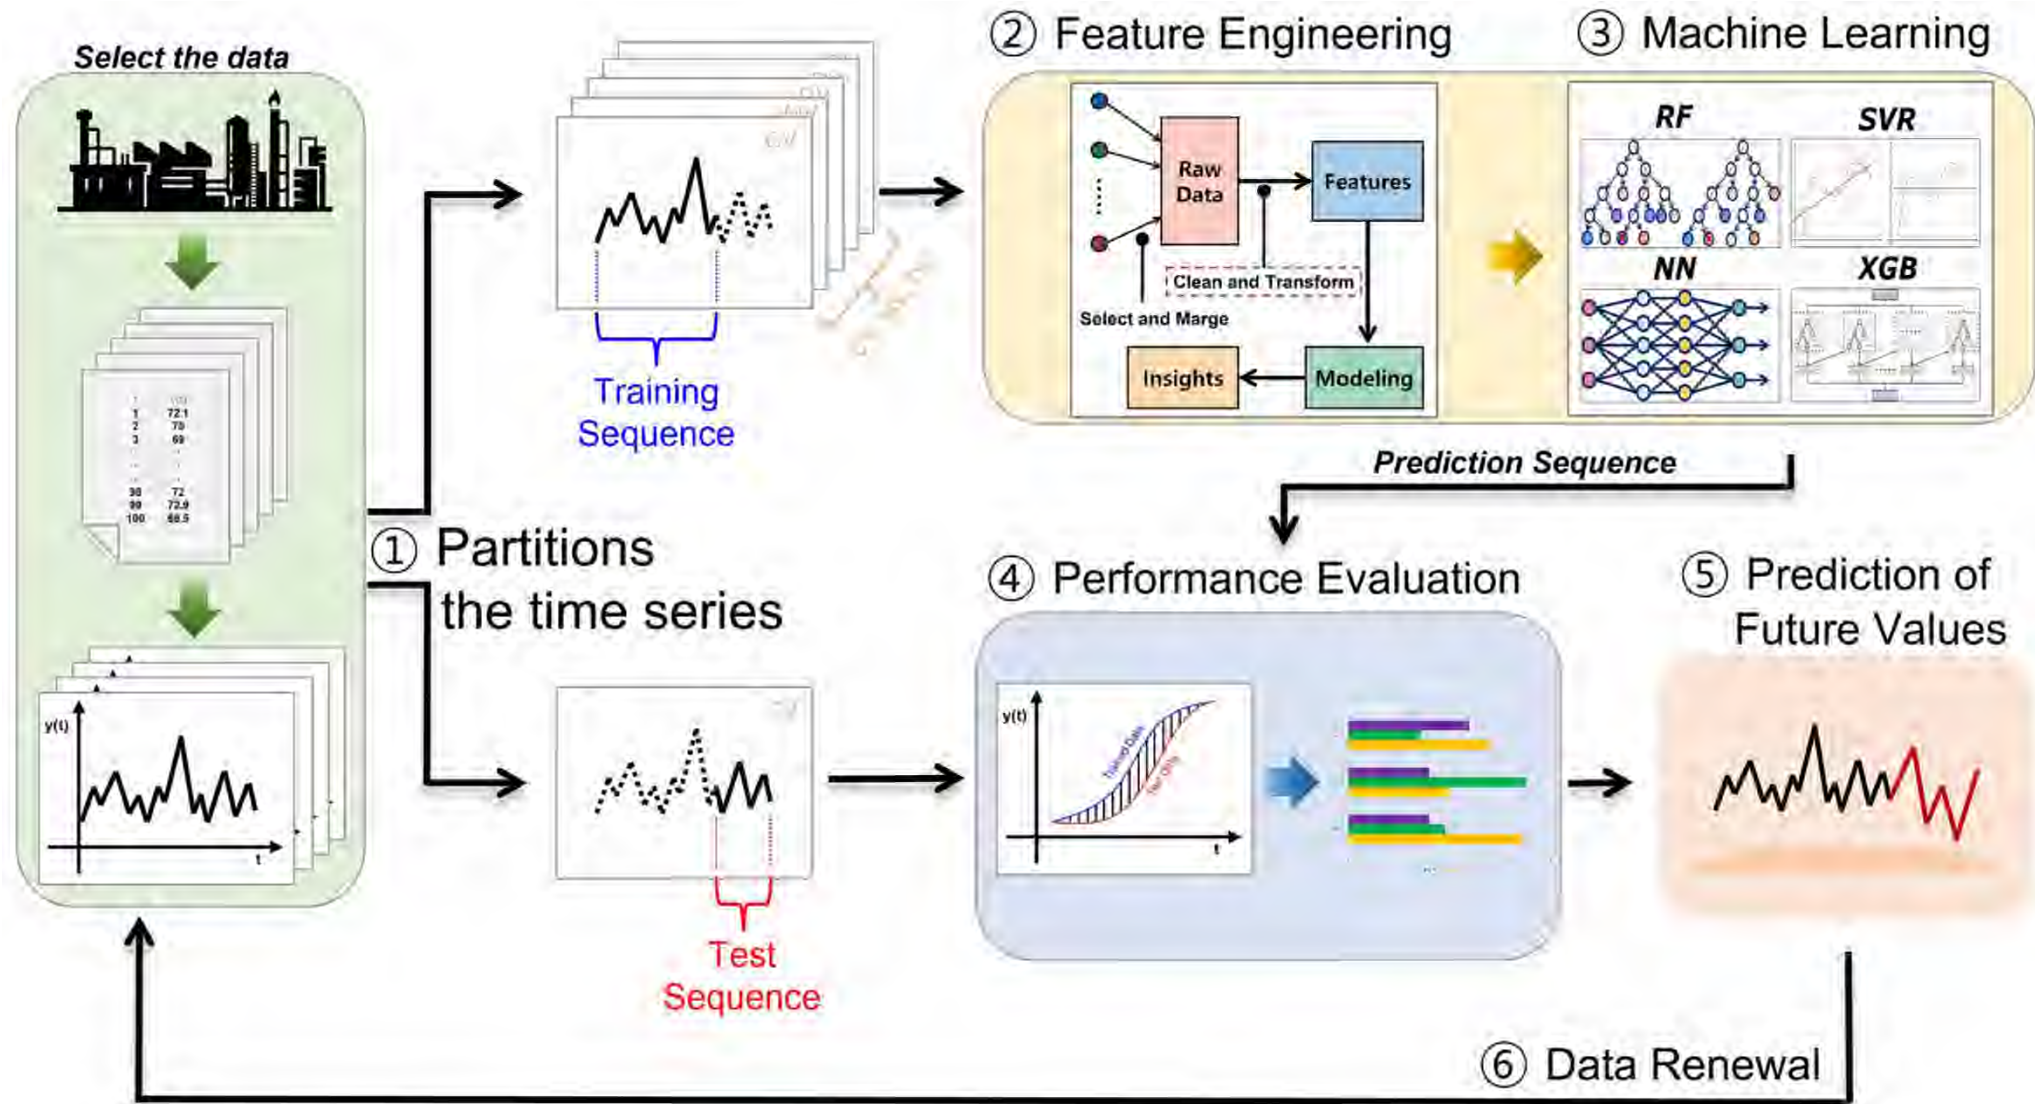


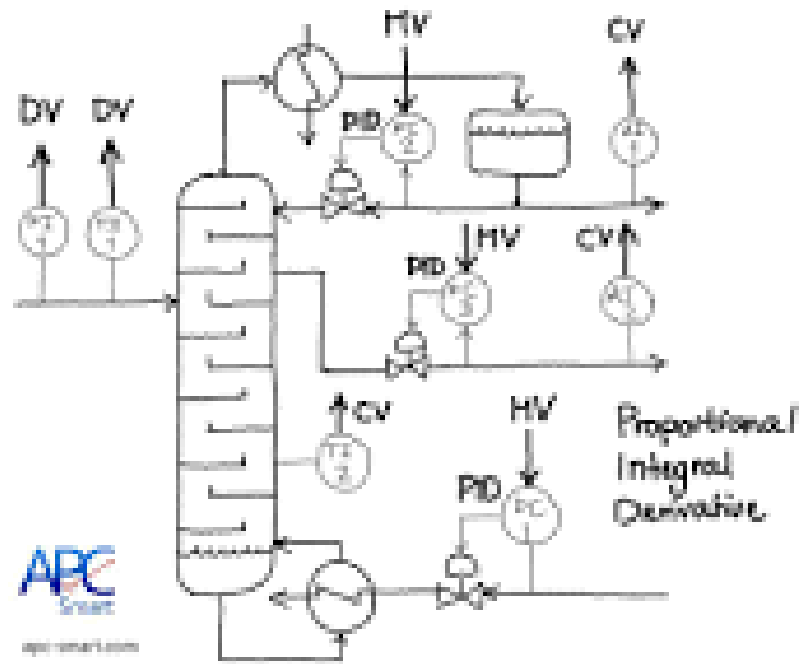
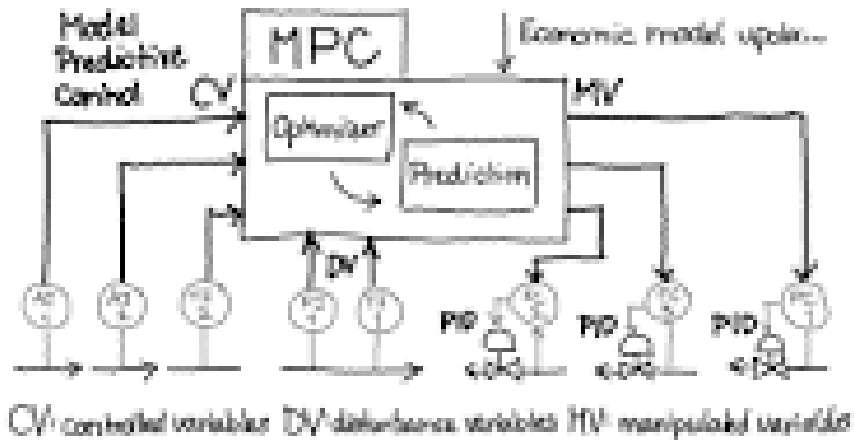
# (4)先進製程控制APC

- **APC** (Advanced Process Control), 利用AI做品質控制, 以軟儀表(Soft Meter, Soft Sensor)的概念, 提高產量, 降低能耗
- APC可以讓控制更精準, 因此避免掉不需要的浪費





# APC






Single-loop controller connections



	CV1	CV2	CV3	CV4	CV5	CV6	CV7	CV8
MV1	+	-		+				
MV2		+				+		-
MV3	-				+		-	
MV4	+		+			-		
MV5				+	+		-	+

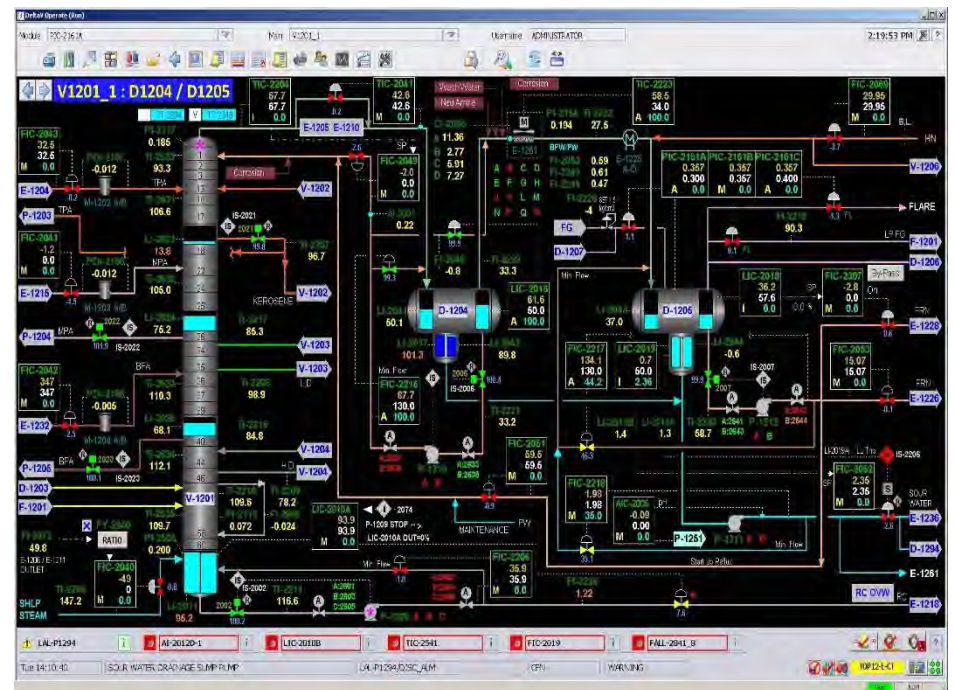
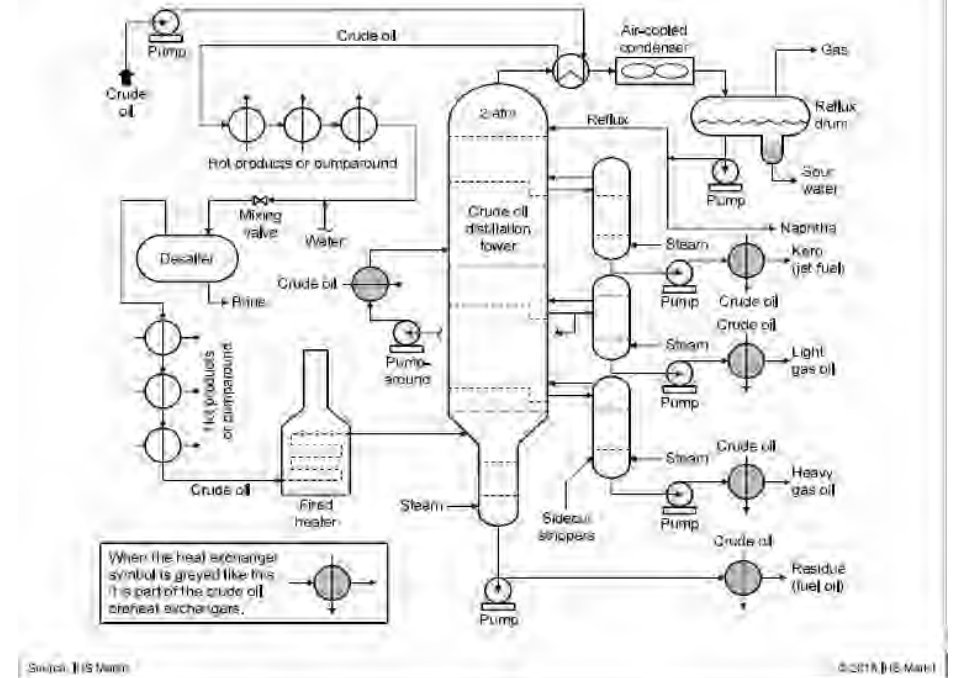




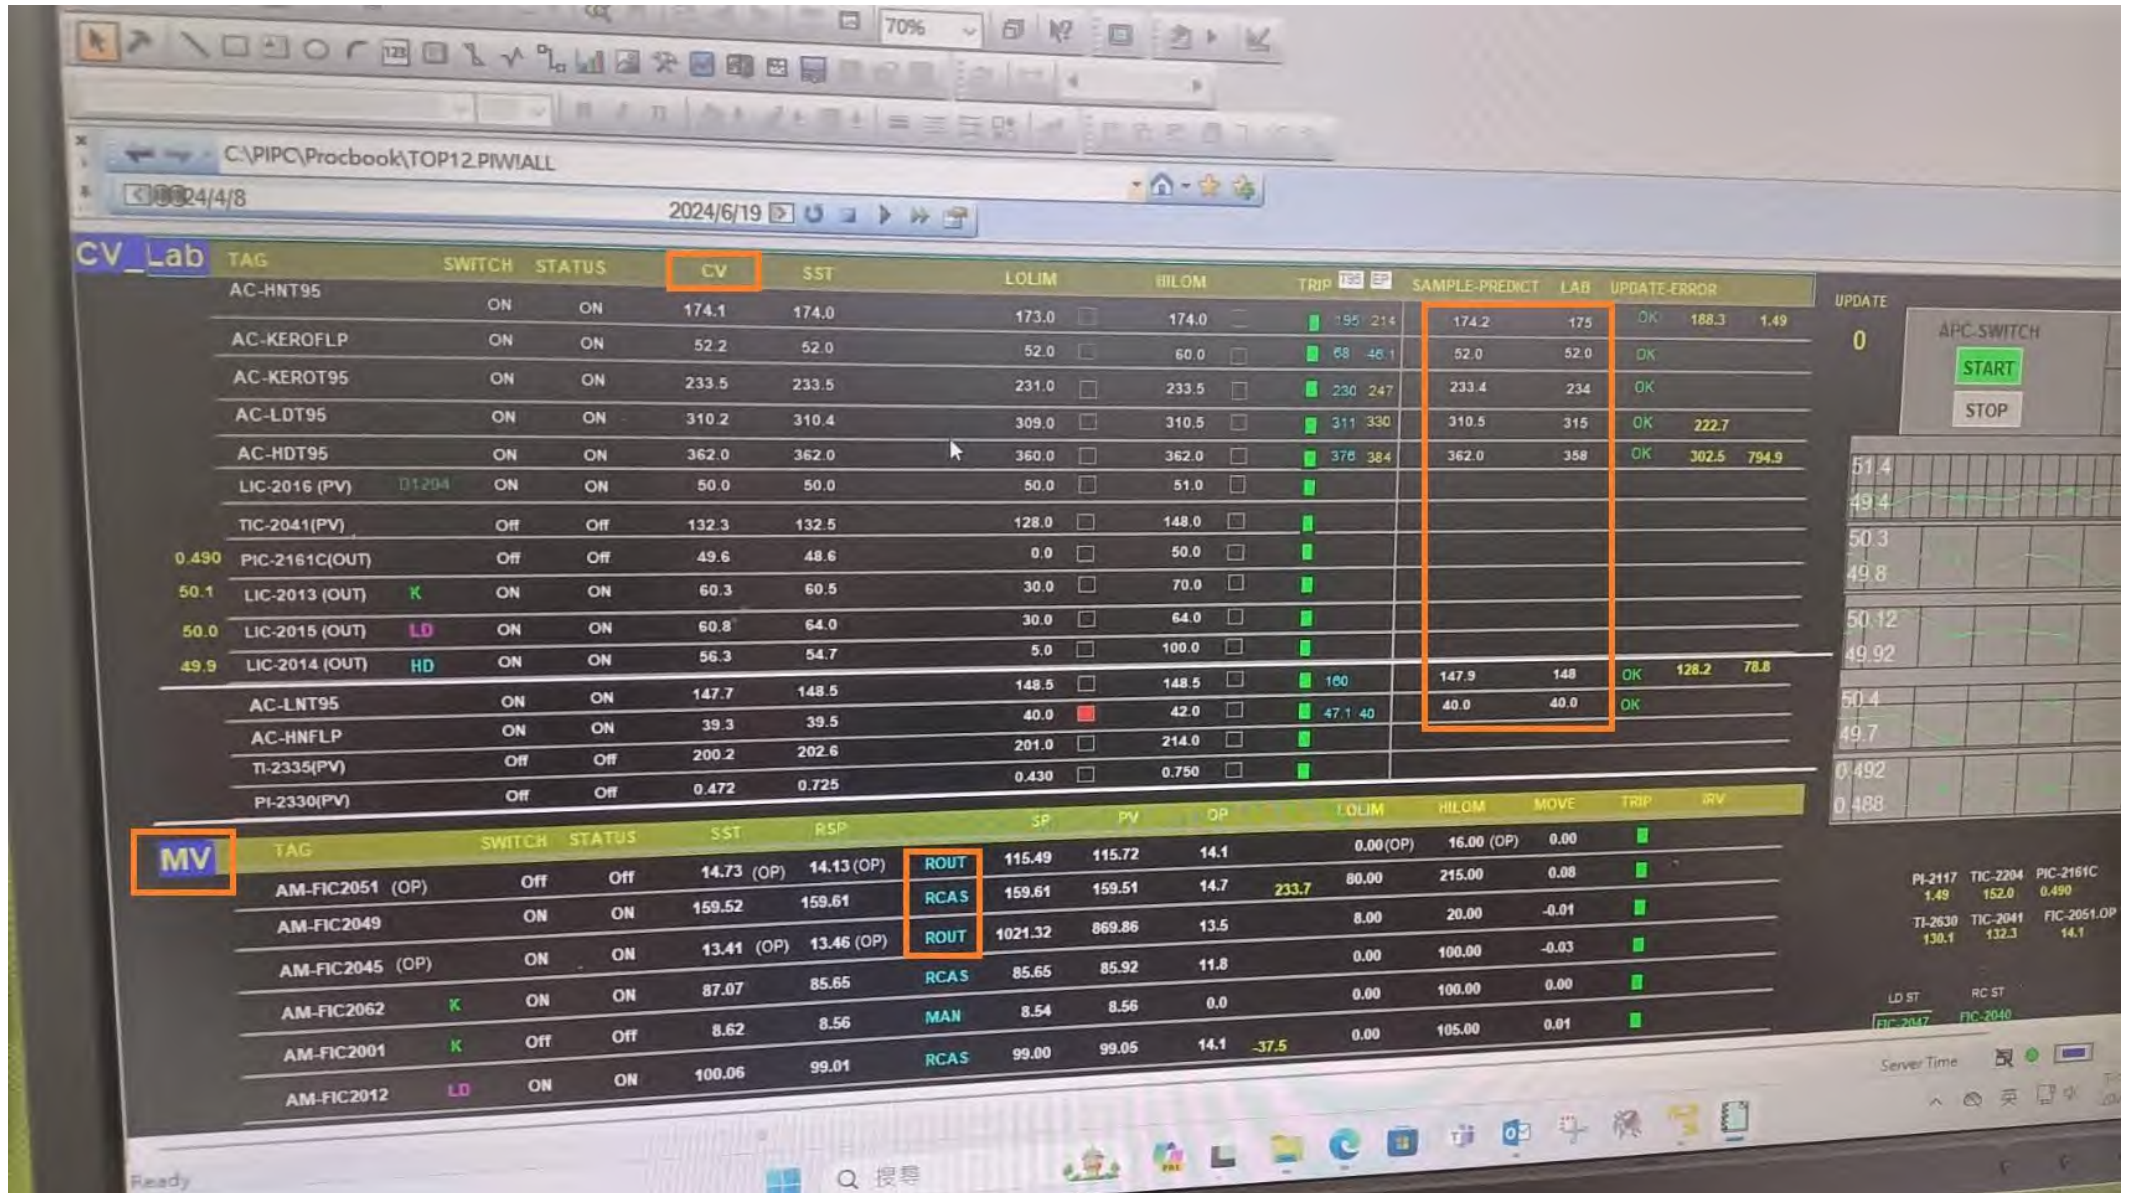
# (4.1)大林廠 12蒸 APC案

## 專案目標

- 1.HN/LN/K/HD/LD T95 軟儀表建立,供操作員調整品質.
2. HN/LN/K/HD/LD T95 標準差較現值下降 20%  
(依油種4.0-6.5 °C)
- 3.可根據市場價格調整較有價值油種的取出量(優化操作)



# 大林廠 12蒸 APC案





# 大林廠 12蒸 APC案

C:\PIPC\Procbook\TOP12.PW\ALL

2024/6/19

Tag	Mode	OP	SP	PV	OF	TRIP
AM-FIC2051	(OP)	ON	ON	14.59	(OP) 14.12	ROUT
AM-FIC2049		ON	ON	157.03	159.38	RCAS
AM-FIC2045	(OP)	ON	ON	12.78	(OP) 13.46	ROUT
AM-FIC2062	K	ON	ON	82.62	85.60	RCAS
AM-FIC2001	K	Off	Off	8.62	8.57	MAN
AM-FIC2012	LO	ON	ON	100.07	99.03	RCAS
AM-FIC2010	LO	Off	Off	93.92	0.00	MAN
AM-FIC2064	HD	Off	Off	40.68	0.00	MAN
AM-FIC2063	HD	ON	ON	26.88	27.62	RCAS
AM-PIC2161C		Off	Off	0.490	0.490	AUTO
AM-FIC2043	TPA	ON	ON	479.90	488.98	RCAS
AM-FIC2041	MPA	ON	ON	273.00	273.16	RCAS
AM-FIC2042	BPA	ON	ON	880.62	886.51	RCAS
AM-FIC2304		ON	ON	158.41	159.25	RCAS
AM-TIC2331	(OP)	Off	Off	100.00	(OP) 100.00	MAN

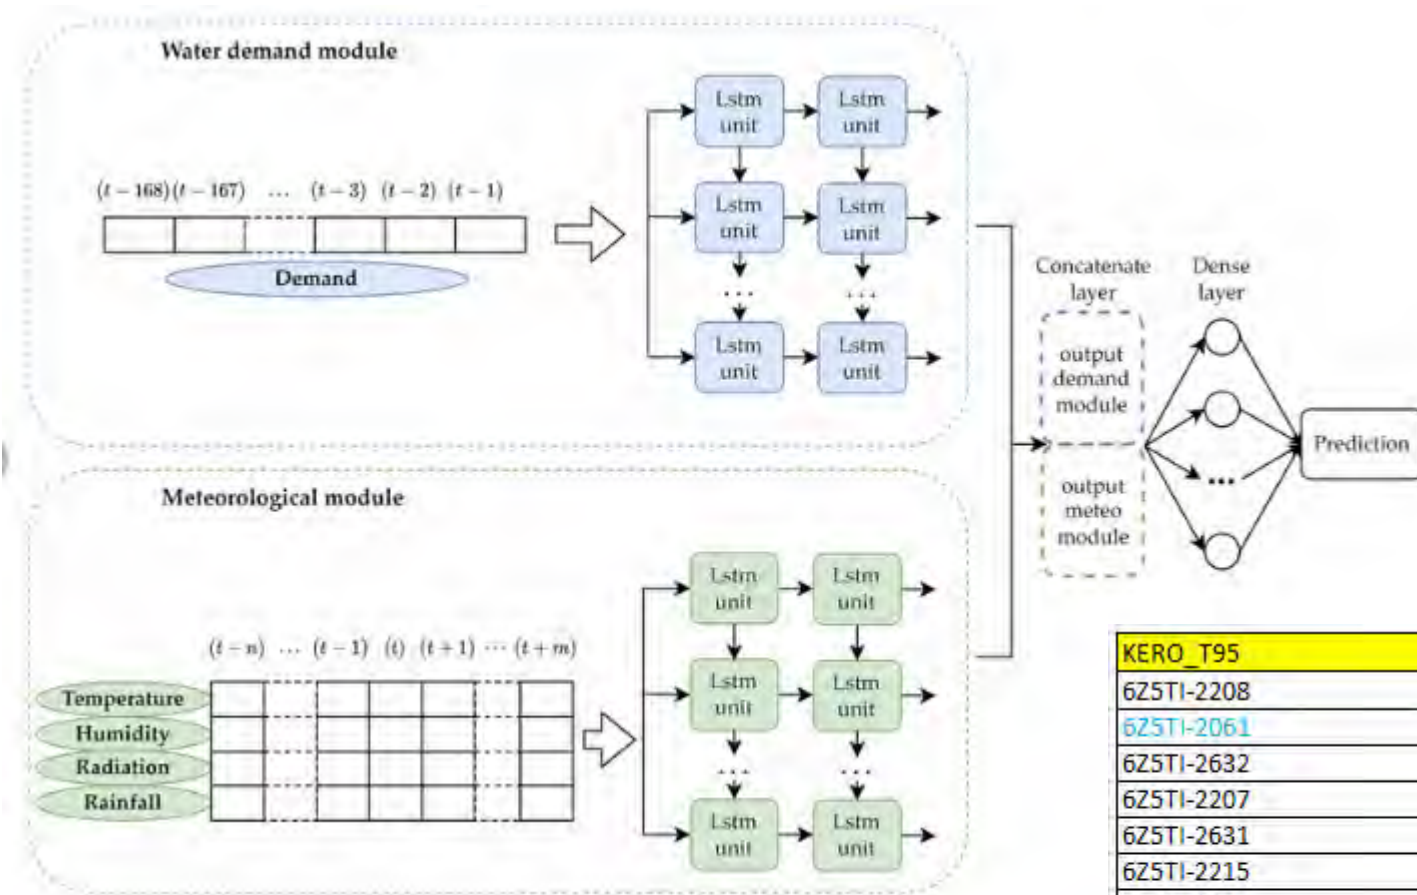
  

FV	TAG	SWITCH	STATUS	SP	PV	OF	TRIP
	AF-FIC2019	FEED	Off	Off	875.48	875.48	122.5
	AF-TIC2189	COT	ON	ON	344.00	343.86	1.2
	AF-FIC2205	RC	ON	ON	200.00	199.71	16.3
	AF-FIC2303	V-1206 FEED	Off	Off	332.25	332.88	74.1

Server Time: 2024/6/19



# 大林廠 12蒸 APC案





KERO_T95	品質
6Z5TI-2208	V1201 to V1203
6Z5TI-2061	V1201 MPA管線
6Z5TI-2632	V1201
6Z5TI-2207	V1201 to V1202
6Z5TI-2631	V1201
6Z5TI-2215	V1202 to V1201
6Z5TI-2218	V1202
6Z5TIC-2204.PV	V1201
6Z5TI-2630	V1201
$(6Z5FIC-2049.PV) / (6Z5FIC-2019.PV)$	(V1201 煙流量 / F1201 流量) 比值
$(6Z5FIC-2062.PV+6Z5FIC-2001.PV) / (6Z5FIC-2019.PV)$	(V1202 KEROSENE 流量 / F1201 流量) 比值
$(6Z5FIC-2012.PV+6Z5FIC-2010.PV) / (6Z5FIC-2019.PV)$	(V1203 LD 流量 / F1201 流量) 比值
$(6z5FIC-2045.pv) / (6z5FIC-2062.pv+6z5FIC-2001.pv)$	(V1202 氣提蒸氣量 / KEROSENE 流量) 比值



# 大林廠APC成效：標準差降低，效益1.18億元

	LNT95	HNT95	KEROT95	LDT95	HDT95	
APC上線前 (2019.01-2019.12)	6.84	4.94	5.50	8.14	7.47	備註
APC上線前 (2020.01~2020.12)	5.04	4.46	5.10	7.25	9.15	
APC上線後 (2021.04~2021.12)	4.27	2.07	2.65	4.16	5.89	
APC上線後 (2022.01~2023.12)	3.35	3.41	3.55	5.9	5.61	
APC上線後 (2023.01-2023.12)	3.42	2.46	2.55	4.3	6.51	




## (4.2) 林園廠

- 林園廠的APC(Honeywell),使乙烯的純度上升,每月有58萬的效益

### 石化林園廠高階控制 (APC)自動調整效果

投用 APC 後，當製程發生擾動，產品不純物含量仍可以回穩達到要求。



### 高階控制 (APC) 投用效益

Tag	描述	APC投用前(均值)	APC投用後(均值)
AI13801D1.PV	V-1370 C2- (C <sub>2</sub> H <sub>6</sub> )	342.6ppm	655.5ppm

- 655.5ppm – 342.6 ppm = 312.9 ppm ← 不純物(乙烷) 增加值

- 效益可增加 581,025 NTD/Month

$$312.9 \text{ (ppm)} \times 2181 \text{ (ton/day)} \\ \times 860 \text{ (USD/ton)} \times 33 \text{ (NTD/USD)} \times 30 \text{ (day)} \\ = 581,025 \text{ (NTD/Month)}$$





## (4.3) 桃園廠

- 桃園煉油廠的APC(Emerson),共有8個品質控制項的軟儀表,類似的作法,以柴油為例,標準差由4.78降為3.93,降低17.8%,節能效益每年有1320萬元,柴油增產每年有2181萬元,合計每年有3501萬元節能效益.

### 二蒸APC效益計算 (柴油增取)

柴油增產效益		
	標準差	T95溫度
APC上線前	4.78	355.7
APC上線後	3.93	357.9
改善成效	降低17.8%	提升2.2°C



### 二蒸APC總效益

二蒸APC整體效益	
柴油增產年效益(萬元)	2181
節能年效益(萬元)	1320
總效益(萬元)	3501



**(應用範例二)**

**地熱井熱源預知**

# 解法：預測範例：糖尿病預測

- 共768的受試者資料
- 前面8個數據為輸入
- Outcome為輸出

```
Pregnancies  Glucose  BloodPressure  ...  DiabetesPedigreeFunction  Age  Outcome
0           6       148           72  ...                0.627  50       1
1           1        85           66  ...                0.351  31       0
2           8       183           64  ...                0.672  32       1
3           1        89           66  ...                0.167  21       0
4           0       137           40  ...                2.288  33       1

[5 rows x 9 columns]
(768, 9)


Process finished with exit code 0
```

上述糖尿病数据集共有 9 个字段，其说明如下。

- Pregnancies: 怀孕次数。
- Glucose: 两小时后口服葡萄糖耐受测试的血液葡萄糖浓度。
- BloodPressure: 血压的舒张压 (单位为 mmHg)。
- SkinThickness: 三头肌皮肤摺层厚度 (单位为 mm, 是临床上反映营养状况的指标)。
- Insulin: 血清胰岛素 (单位为  $\mu\text{U}/\text{mL}$ )。
- BMI: 身体质量指数。
- DiabetesPedigreeFunction: 病患本身家族成员有得糖尿病的病史。
- Age: 年龄。
- Outcome: 5 年是否有得糖尿病, 1 是有; 0 是没有。



# 預測範例：糖尿病預測




- 預測糖尿病準確率  
0.69

```
model = Sequential()
model.add(Dense(10, input_shape=(8,), activation="relu"))
model.add(Dense(8, activation="relu"))
model.add(Dense(1, activation="sigmoid"))
model.summary() # 显示模型摘要信息
编译模型
model.compile(loss="binary_crossentropy", optimizer="sgd",
```

Ch5\_2\_2

```
↑
10/768 [.....] - ETA: 0s - loss: 0.7121 - acc: 0.5000
↓
768/768 [=====] - 0s 60us/step - loss: 0.5717 - acc: 0.6849
Epoch 150/150
↑
10/768 [.....] - ETA: 0s - loss: 0.4754 - acc: 0.8000
↓
768/768 [=====] - 0s 66us/step - loss: 0.5710 - acc: 0.6849
↑
32/768 [>.....] - ETA: 0s
↓
768/768 [=====] - 0s 59us/step
准确度 = 0.69
```

# 預測範例：糖尿病預測



- 預測糖尿病準確率  
0.8


```
# 特征标准化
X -= X.mean(axis=0)
X /= X.std(axis=0)
# 定义模型
model = Sequential()
model.add(Dense(10, input_shape=(8,), activation="relu"))
model.add(Dense(8, activation="relu"))
model.add(Dense(1, activation="sigmoid"))
# model.summary() # 显示模型摘要信息
# 编译模型
model.compile(loss="binary_crossentropy", optimizer="sgd")
```

Ch5\_2\_3

```
C:\Users\user\Anaconda3\python.exe "C:/Tensor flow+keras
C:\Users\user\Anaconda3\lib\site-packages\h5py\__init__
from ._conv import register_converters as _register_co
Using TensorFlow backend.
2024-12-09 14:03:22.285211: I tensorflow/core/platform/c
32/768 [>.....] - ETA: 0s
768/768 [=====] - 0s 43us/step
准确度 = 0.80

Process finished with exit code 0
```

# 預測範例：糖尿病預測



- 預測糖尿病準確率  
0.84

```
X -= X.mean(axis=0)
X /= X.std(axis=0)
# One-hot编码
Y = to_categorical(Y)
# 分割训练和测试数据集
X_train, Y_train = X[:690], Y[:690] # 训练数据前690条
X_test, Y_test = X[690:], Y[690:] # 测试数据后78条
# 定义模型
model = Sequential()
model.add(Dense(10, input_shape=(8,), activation="relu"))
model.add(Dense(6, activation="relu"))
model.add(Dense(2, activation="softmax"))
```

Ch5\_2\_4

```
↑ Using TensorFlow backend.
↓ 2024-12-09 14:06:41.899225: I tensorflow/core/platform/cpu...
32/690 [>.....] - ETA: 0s
690/690 [=====] - 0s 50us/step
训练数据集的准确度 = 0.84
```



# 資料及判斷任務說明

- 地熱資料包含TC-14、TC-15、TC-17、TC-19鑽井設備，讀取數據如下：


- 鑽探深度

- 泥漿出口溫度：

1. 鑽井中，井內會維持泥漿循環，出口溫度為泥漿自地底循環後，流出井口時所測得的溫度，通常會高於入口溫度。
2. 假設其它因素維持恆定，則1).地層越高溫，泥漿溫度越高；2).井深越深或循環流速(泵量)越慢，泥漿因受地層加熱時間增加，溫度越高；3).使用泥漿冷卻系統時，出入口溫度同時降低；4).地層或地表有高或低溫流體加入時，將影響溫度。


- 泥漿入口溫度：

1. 此為從地面泥漿槽測量，即將泵入井內循環之泥漿溫度，通常低於泥漿出口溫度，且與泥漿出口溫度有連動關係。
2. 假設其它因素恆定，則1).新調製之泥漿或清水加入時，溫度降低；2).使用泥漿冷卻系統時，溫度降低；3).天候可能會影響地表泥漿系統之入口溫度



輸入三個數值(深度、出口溫度，入口溫度)，讓AI判斷出是否在高溫區間。

TC-20鑽井現場設備配置 (示意圖)



# 資料標註

	A	B	C	D	E	F	G	H	I	J	K	L
131436	45196.00	0.75	63.6	2023/9/27	18:01:54			45230.00	0.59	60.5	2023/10/31	14:12:01
131437	45196.00	0.75	63.6	2023/9/27	18:02:54			45230.00	0.59	60.3	2023/10/31	14:13:01
131438	45196.00	0.75	63.7	2023/9/27	18:03:54			45230.00	0.59	60.2	2023/10/31	14:14:01
131439	45196.00	0.75	63.7	2023/9/27	18:04:54			45230.00	0.59	60	2023/10/31	14:15:01
131440	45196.00	0.75	63.6	2023/9/27	18:05:54			45230.00	0.59	59.9	2023/10/31	14:16:01
131441	45196.00	0.75	63.7	2023/9/27	18:06:54			45230.00	0.60	59.7	2023/10/31	14:17:01
131442	45196.00	0.76	63.7	2023/9/27	18:07:54			45230.00	0.60	59.6	2023/10/31	14:18:01
131443	45196.00	0.76	63.7	2023/9/27	18:08:54			45230.00	0.60	59.4	2023/10/31	14:19:01
131444	45196.00	0.76	63.7	2023/9/27	18:09:54			45230.00	0.60	59.2	2023/10/31	14:20:01
131445	45196.00	0.76	63.7	2023/9/27	18:10:54			45230.00	0.60	59.1	2023/10/31	14:21:01
131446	45196.00	0.76	63.7	2023/9/27	18:11:54			45230.00	0.60	58.9	2023/10/31	14:22:01
131447	45196.00	0.76	63.7	2023/9/27	18:12:54			45230.00	0.60	58.7	2023/10/31	14:23:01
131448	45196.00	0.76	63.7	2023/9/27	18:13:54			45230.00	0.60	58.6	2023/10/31	14:24:01
131449	45196.00	0.76	63.7	2023/9/27	18:14:54			45230.00	0.60	58.4	2023/10/31	14:25:01
131450	45196.00	0.76	63.8	2023/9/27	18:15:54			45230.00	0.60	58.2	2023/10/31	14:26:01
131451	45196.00	0.76	63.8	2023/9/27	18:16:54			45230.00	0.60	58.1	2023/10/31	14:27:01
131452	45196.00	0.76	63.8	2023/9/27	18:17:54			45230.00	0.60	58	2023/10/31	14:28:01
131453	45196.00	0.76	63.9	2023/9/27	18:18:54			45230.00	0.60	57.8	2023/10/31	14:29:01
131454	45196.00	0.76	63.9	2023/9/27	18:19:54			45230.00	0.60	57.7	2023/10/31	14:30:01
131455	45196.00	0.76	63.8	2023/9/27	18:20:54			45230.00	0.60	57.5	2023/10/31	14:31:01
131456	45196.00	0.77	63.9	2023/9/27	18:21:54			45230.00	0.61	57.3	2023/10/31	14:32:01
131457	45196.00	0.77	63.9	2023/9/27	18:22:54			45230.00	0.61	57.2	2023/10/31	14:33:01
131458	45196.00	0.77	63.9	2023/9/27	18:23:54			45230.00	0.61	57	2023/10/31	14:34:01
131459	45196.00	0.77	63.9	2023/9/27	18:24:54			45230.00	0.61	56.9	2023/10/31	14:35:01
131460	45196.00	0.77	63.9	2023/9/27	18:25:54			45230.00	0.61	56.8	2023/10/31	14:36:01
131461	45196.00	0.77	63.9	2023/9/27	18:26:54			45230.00	0.61	56.7	2023/10/31	14:37:01
131462	45196.00	0.77	63.9	2023/9/27	18:27:54			45230.00	0.61	56.4	2023/10/31	14:38:01
131463	45196.00	0.77	63.9	2023/9/27	18:28:54			45230.00	0.61	56.2	2023/10/31	14:39:01
131464	45196.00	0.77	63.8	2023/9/27	18:29:54			45230.00	0.61	56.1	2023/10/31	14:40:01
131465	45196.00	0.77	63.9	2023/9/27	18:30:54			45230.00	0.61	55.9	2023/10/31	14:41:01
131466	45196.00	0.77	63.9	2023/9/27	18:31:54			45230.00	0.61	55.8	2023/10/31	14:42:01
131467	45196.00	0.77	63.9	2023/9/27	18:32:54			45230.00	0.61	55.7	2023/10/31	14:43:01
131468	45196.00	0.77	63.9	2023/9/27	18:33:54			45230.00	0.61	55.5	2023/10/31	14:44:01
131469	45196.00	0.77	63.9	2023/9/27	18:34:54			45230.00	0.61	55.4	2023/10/31	14:45:01
131470	45196.00	0.77	63.9	2023/9/27	18:35:54			45230.00	0.62	55.2	2023/10/31	14:46:01
131471	45196.00	0.78	63.9	2023/9/27	18:36:54			45230.00	0.62	55	2023/10/31	14:47:01

1380	71.5	63.9	1426	0	9999	17
1390	70.5	55.7	1426	0	9999	16
1400	70.0	56.3	1426	0	9999	15
1410	69.3	58.4	1426	0	9999	14
1420	69.0	58.6	1426	0	9999	13
1430	67.2	56.5	1426	0	9999	12
1440	63.0	50.8	1426	0	9999	11
1450	65.6	53.6	1426	0	9999	10
1460	68.3	59	1426	0	9999	9
1470	69.4	60.6	1426	0	9999	8
1480	71.6	59.9	1426	0	9999	7
1490	70.9	61.2	1426	0	9999	6
1500	70.6	61	1426	0	9999	5
1510	69.3	59.8	1426	0	9999	4
1520	69.0	59.8	1426	0	9999	3
1530	69.7	59.7	1426	0	9999	2
1540	71.0	57.8	1426	0	9999	1
1550	N/A	59.2	1426	1	9999	0
1560	N/A	57.5	1426	1	9999	0
1570	69.0	58.4	1426	1	9999	0
1580	71.0	60.7	1426	1	9999	0
1590	68.9	56.4	1426	1	9999	0
1600	69.0	59.1	1426	1	9999	0
1610	70.1	60.2	1426	1	9999	0
1620	70.2	57.9	1426	1	9999	0
1630	70.2	60.1	1426	1	9999	0
1640	69.2	59.5	1426	1	9999	0
1650	70.6	60.5	1426	1	9999	0
1660	70.4	60.1	1426	1	9999	0
1670	70.2	57.4	1426	1	9999	0
1680	69.8	58.7	1426	1	9999	0
1690	72.4	62.3	1426	1	9999	0

# 成果說明

- 訓練指標介紹

- 混淆矩陣

- 混淆矩陣是一種用來評估分類模型效能的工具，展示了模型的預測結果與實際結果之間的關係。矩陣的四個主要區塊分別為：

- TP (True Positive): 正確預測為正類的樣本數量
      - TN (True Negative): 正確預測為負類的樣本數量
      - FP (False Positive): 錯誤預測為正類的樣本數量
      - FN (False Negative): 錯誤預測為負類的樣本數量

		實際值	
		正	負
預測值	正	TP (True Positive)	FP (False Positive)
	負	FN (False Negative)	TN (False Negative)



# 成果說明

## • 訓練指標介紹

### • 精確率(Precision)

• 精確率表示的是模型預測為故障事件的樣本中，實際為故障事件的比例。計算公式為：

$$\bullet \text{ Precision} = \frac{\text{TP}}{\text{TP}+\text{FP}}$$

• 精確率越高，表示模型預測的故障事件越準確。

### • 召回率(Recall)

• 召回率表示的是實際為故障事件的樣本中，模型正確預測為故障事件的比例。計算公式為：

$$\bullet \text{ Recall} = \frac{\text{TP}}{\text{TP}+\text{FN}}$$

• 召回率越高，表示模型能夠識別更多的故障事件。

### • F1 score

• F1 score是精確率與召回率的調和平均數，能夠綜合考慮兩者。F1 score越高，表示模型在平衡精確率和召回率方面表現越好。計算公式為：

$$\bullet \text{ F1 score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

		實際值	
		故障事件	正常事件
預測值	故障事件	TP (True Positive)	FN (False Negative)
	正常事件	FP (False Positive)	TN (False Negative)

# 進度說明及成果

- 使用**TC-14及TC-17中60%**的資料作為訓練資料，來預測其餘設備資料包含**TC-14及TC-17中的40%**、**TC-15全部資料**、**TC-19全部資料**。

TC-14		實際值	
		高溫	正常
預測值	高溫	110	3
	正常	1	144

TC-15		實際值	
		高溫	正常
預測值	高溫	27	1
	正常	0	87

TC-17		實際值	
		高溫	正常
預測值	高溫	18	3
	正常	2	59

TC-19		預測值	
		高溫	正常
實際值	高溫	113	14
	正常	2	73

TC-14 (258筆)	
Accuracy	98.45%
Precision	97.96%
Recall	99.31%
F1-score	98.63%

TC-15 (115筆)	
Accuracy	99.13%
Precision	98.86%
Recall	100.00%
F1-score	99.43%

TC-17 (82筆)	
Accuracy	93.90%
Precision	95.16%
Recall	96.72%
F1-score	95.93%

TC-19 (202筆)	
Accuracy	92.08%
Precision	83.91%
Recall	97.33%
F1-score	90.12%

- 本AI模型在預測的精準度與完整性上取得卓越平衡，其關鍵綜合指標 F1-score 於**四種設備上均達到90%以上**的優異水準。
- 該結果僅需利用**兩項設備的60%資料進行訓練**，即可成功泛化至所有測試設備，展現了模型卓越的訓練效率與穩健的跨設備預測能力。

讀取資料及相關設定介面

團隊設計之GUI介面：圖中紅點代表模型判斷為『高溫』的鑽探深度，其預測機率皆高於50%的判斷基準；綠點則為『常溫』。從TC-15的案例中可清楚看見，模型對兩種溫度區間的鑑別能力極強，其綜合效能指標 F1-score 高達99.4%，印證了預測結果的高度可靠性。

Control Panel



Equipment Type Pipeline

Model Selection GroundHeat

Language Switch Language

Load Data Export Chart

Clear Data Exit



高於50%表示為高溫區間

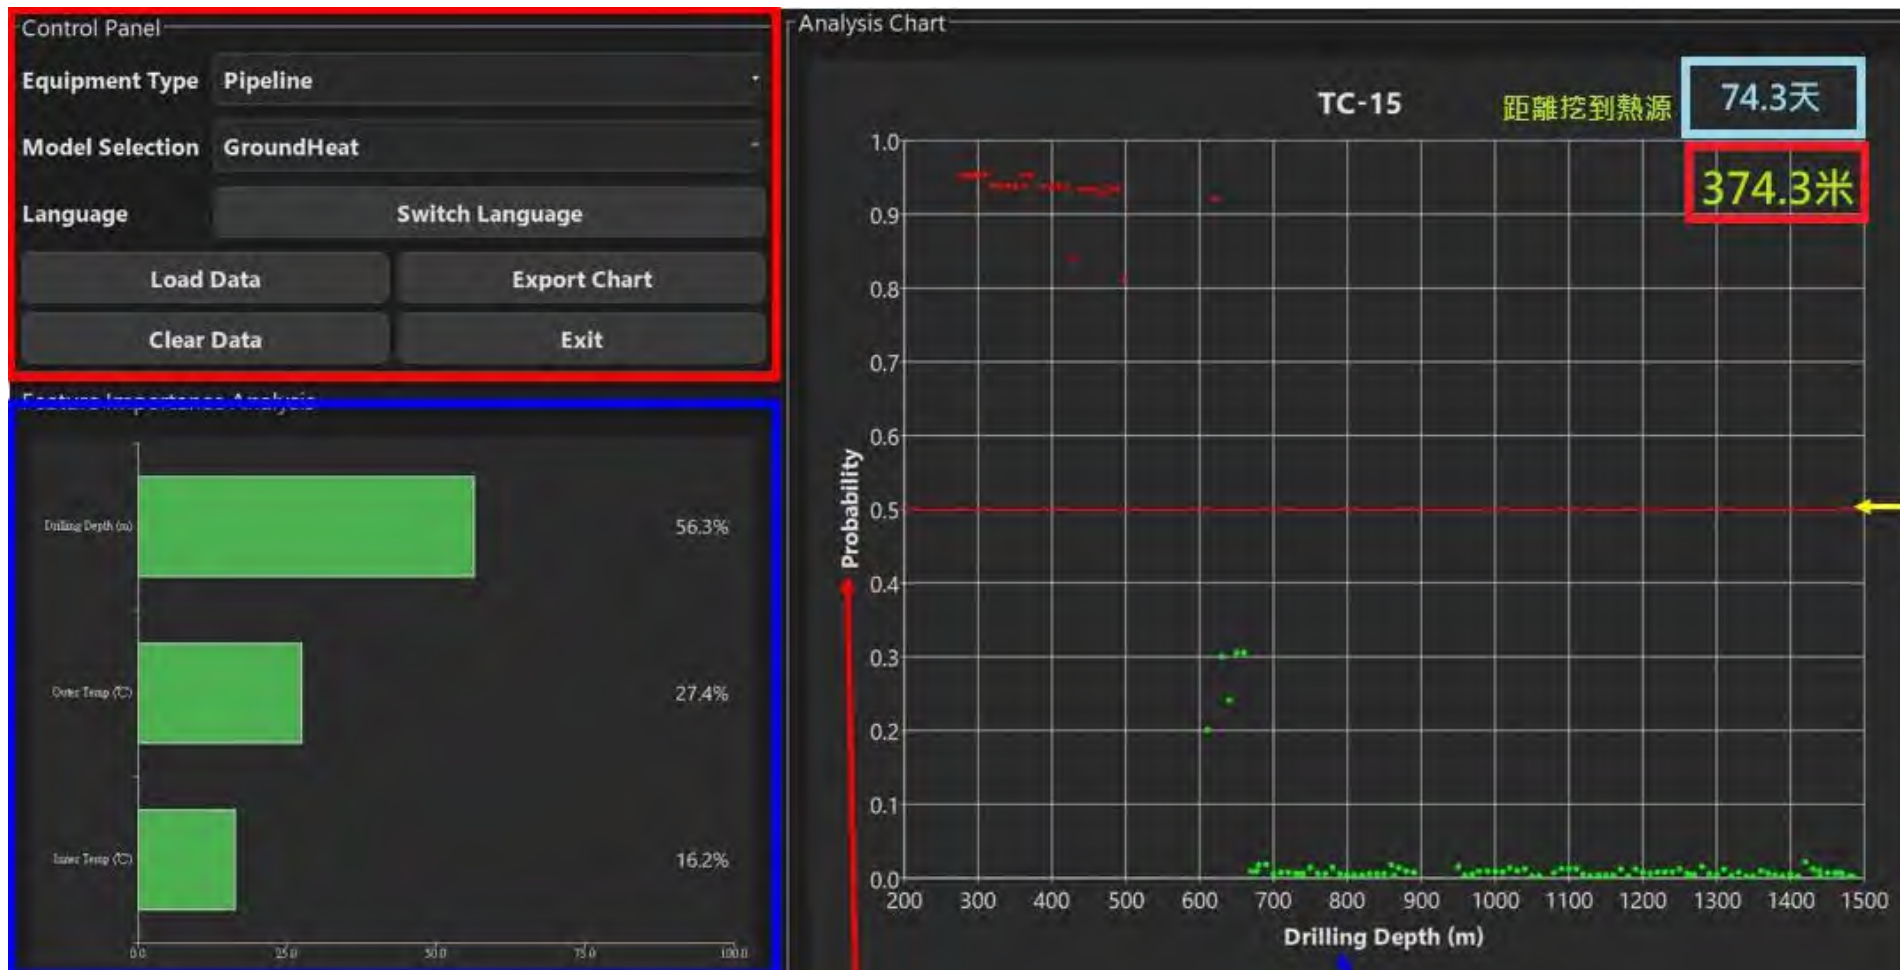
特徵重要性可視化

是否為高溫區間機率

鑽探深度



# 10種演算法的輸出(預測和實際)









- 右上角預測74.3天挖到,誤差約7%
- 或者是還有幾公尺挖到

# 程式執行結果(預測還有幾天挖到或還有幾公尺挖到)

```
10 AI predict(Heat)with plot
(1)Linear Regression - Mean Squared Error: 1283.5947566078717
(1)Linear Regression - Mean Absolute Error: 28.508563235329206
31
31
(2)Decision Tree - Mean Squared Error: 737.258064516129
(2)Decision Tree - Mean Absolute Error: 14.225806451612904
from numpy.core.umath_tests import inner1d
(3)Random Forest - Mean Squared Error: 598.2324032258066
(3)Random Forest - Mean Absolute Error: 13.602903225806456
(4)SVM - Mean Squared Error: 1497.3770272528286
(4)SVM - Mean Absolute Error: 29.572390405322363
(5)KNN - Mean Squared Error: 691.5174193548386
(5)KNN - Mean Absolute Error: 14.038709677419355
(6)Gradient Boosting - Mean Squared Error: 533.2188290231942
(6)Gradient Boosting - Mean Absolute Error: 13.565405666811554
(7)Neural Network - Mean Squared Error: 617.8729361157715
(7)Neural Network - Mean Absolute Error: 17.07417237281319
% self,max_iter, ConvergenceWarning)
(8)Bayesian Ridge - Mean Squared Error: 1265.8842635694389
(8)Bayesian Ridge - Mean Absolute Error: 28.49880468099553
(9)XGBoost - Mean Squared Error: 549.5205498607006
(9)XGBoost - Mean Absolute Error: 12.925006358854231
(10)LightGBM - Mean Squared Error: 514.0547750923372
(10)LightGBM - Mean Absolute Error: 16.158338523631688
```

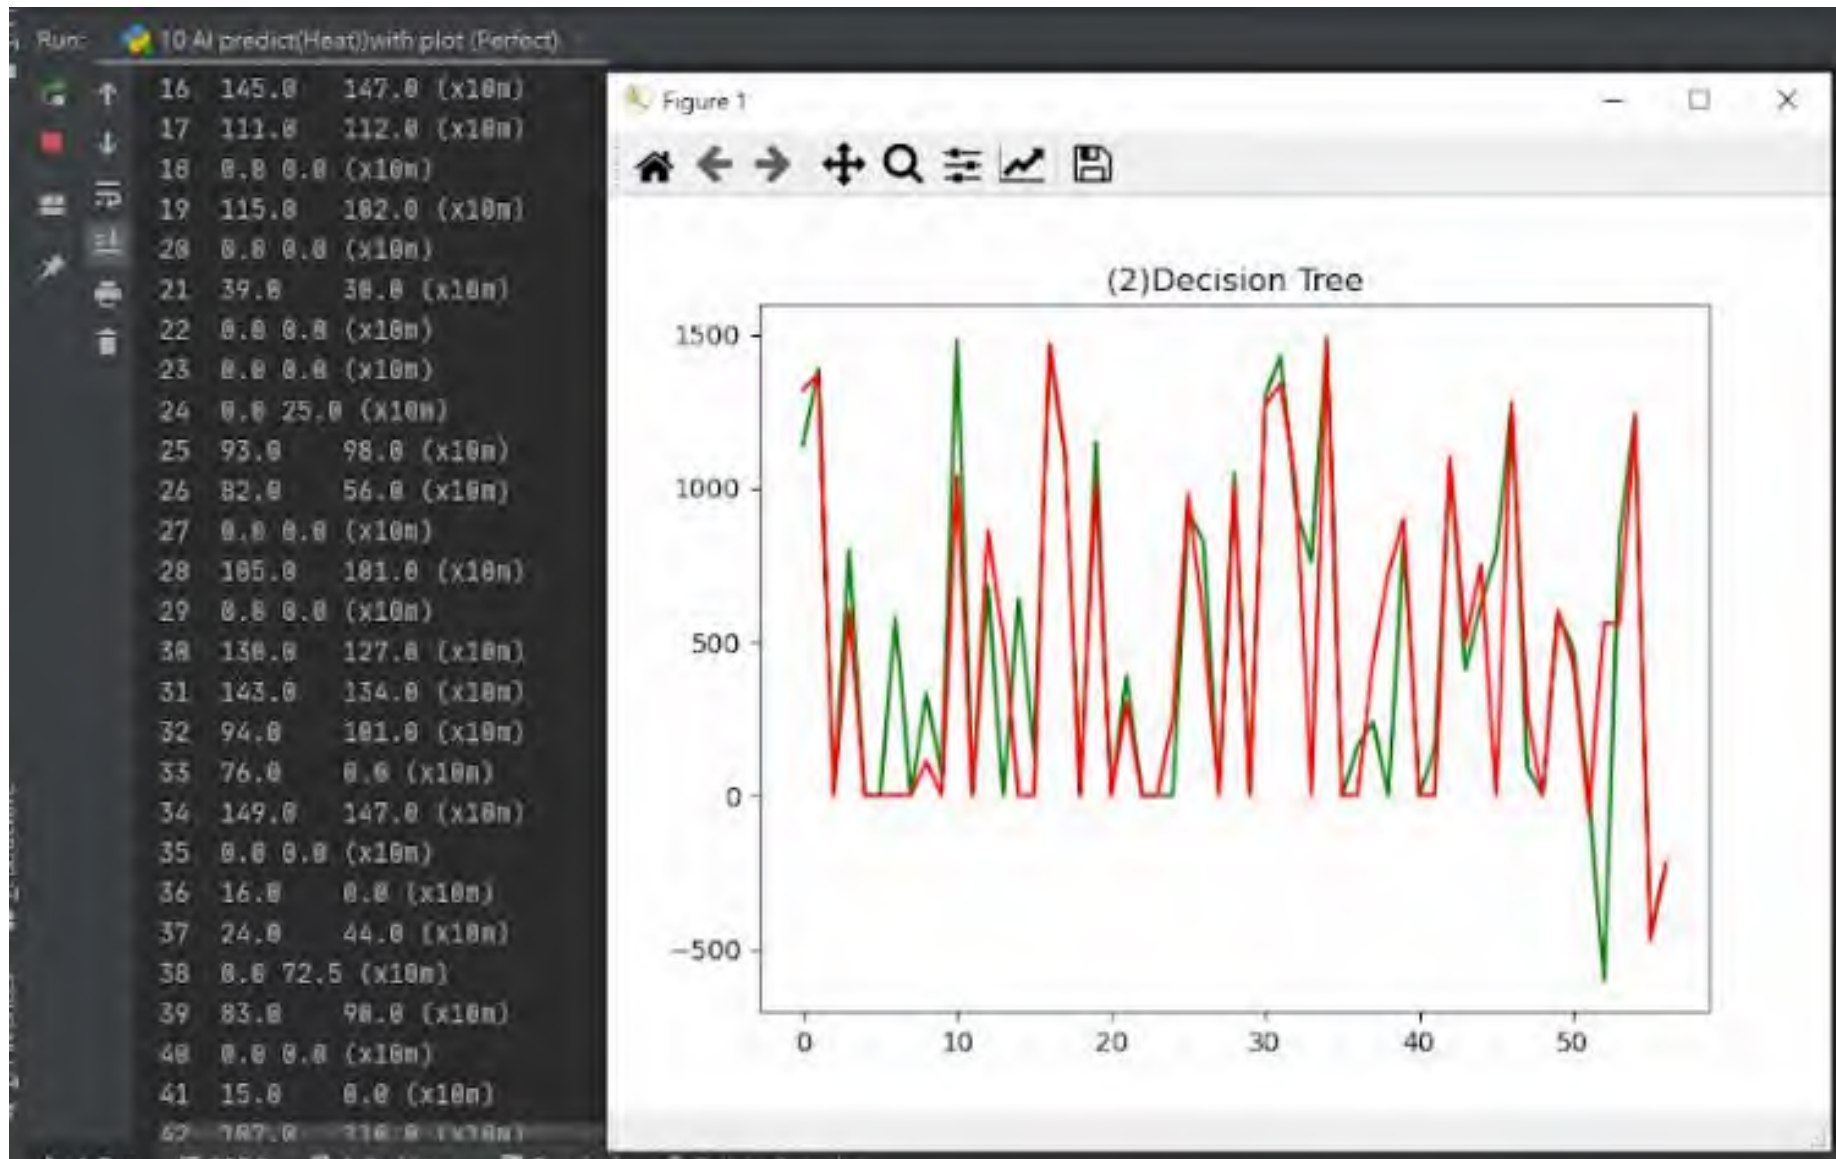
- 使用TC-19地熱井
- 170筆預測,51筆測試(資料量極少)
- 使用10種演算法預測,MAE 12.9-29.57
- 準確率約93%
- 資料補強,或其他地熱井一起訓練,可以提高準確率
- 可以預測其他新挖的地熱井或測試位成功的地熱井

# 10種演算法的輸出(預測和實際)

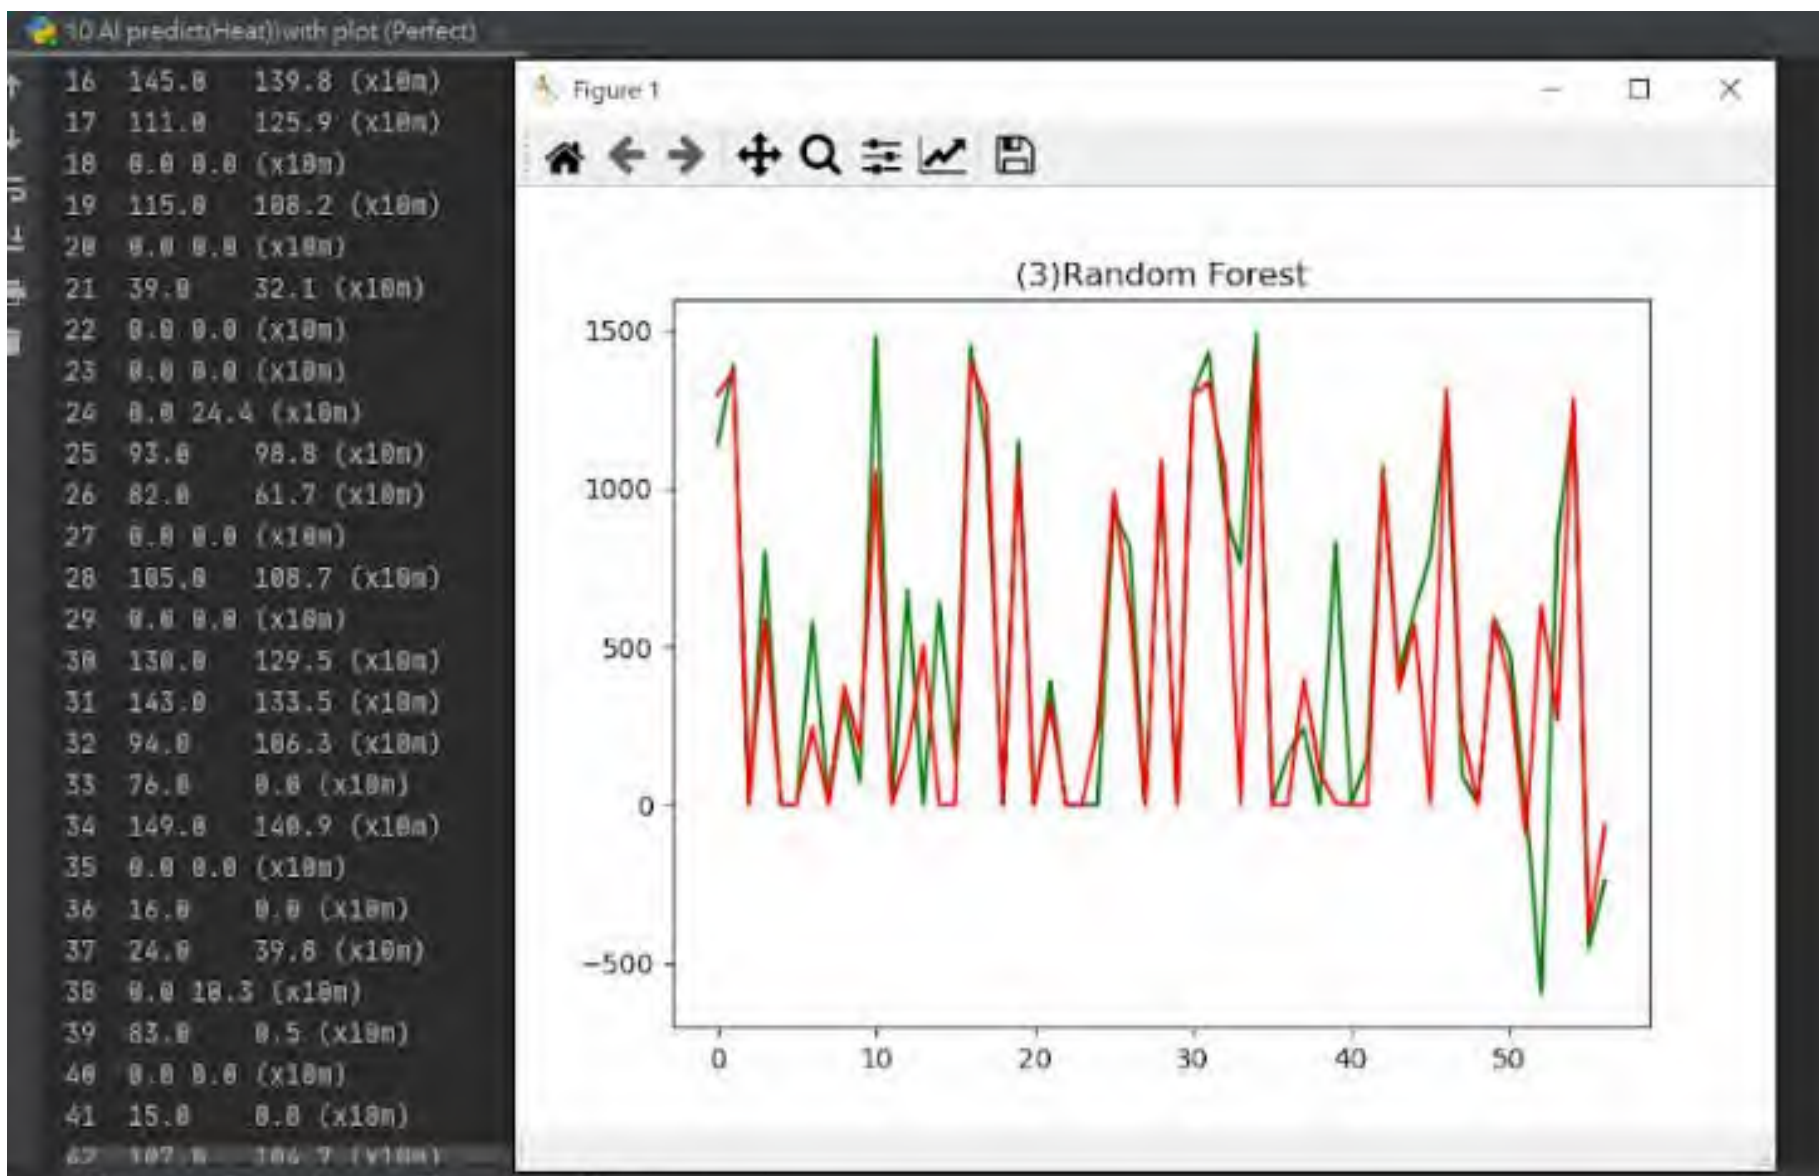




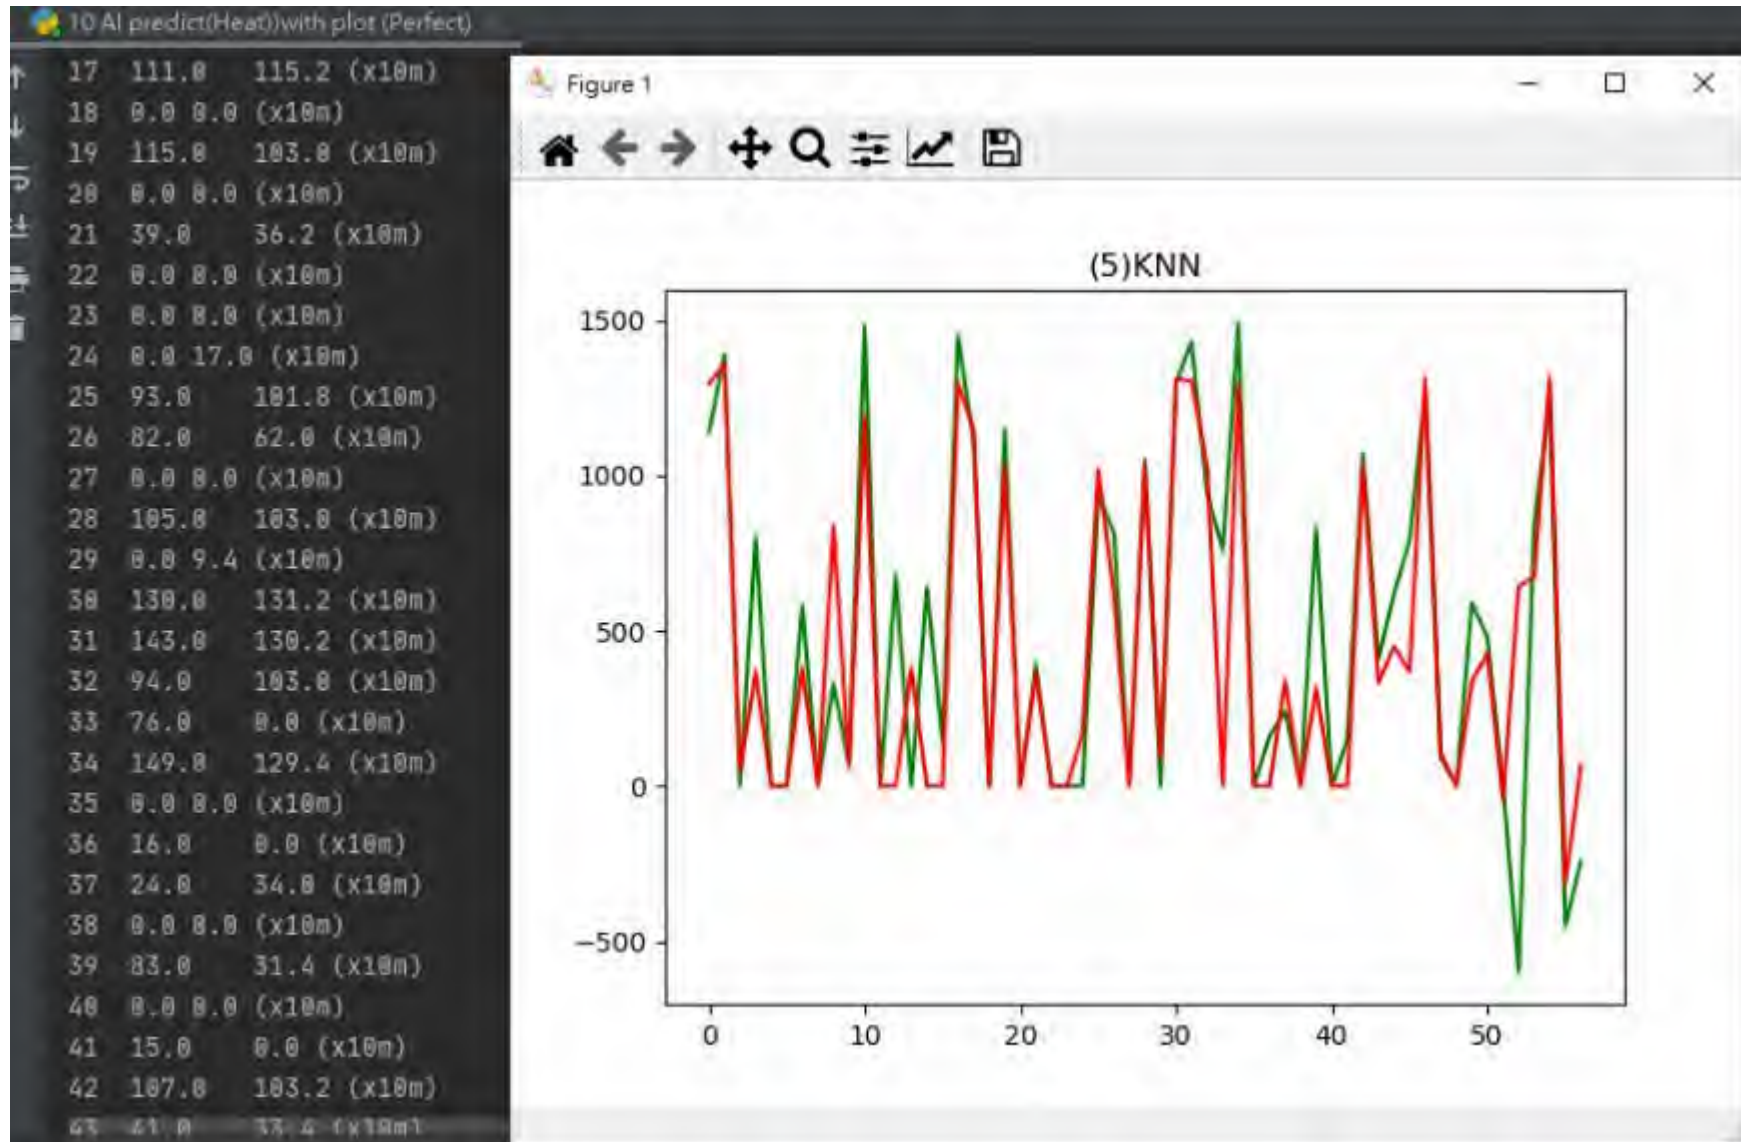
## 10種演算法的輸出(預測和實際-Decision Tree)



## 10種演算法的輸出(預測和實際-Random Forest)




# 10種演算法的輸出(預測和實際-KNN)





# 10種演算法的輸出(預測和實際-XGBoost)

```
16 145.0 120.4 (x10m)
17 111.0 105.8 (x10m)
18 0.0 1.9 (x10m)
19 115.0 100.1 (x10m)
20 0.0 0.0 (x10m)
21 39.0 51.2 (x10m)
22 0.0 0.0 (x10m)
23 0.0 0.0 (x10m)
24 0.0 27.8 (x10m)
25 93.0 90.1 (x10m)
26 82.0 5.8 (x10m)
27 0.0 0.0 (x10m)
28 105.0 102.8 (x10m)
29 0.0 0.0 (x10m)
30 130.0 139.1 (x10m)
31 143.0 142.9 (x10m)
32 94.0 100.3 (x10m)
33 76.0 0.0 (x10m)
34 149.0 111.2 (x10m)
35 0.0 0.0 (x10m)
36 16.0 0.0 (x10m)
37 24.0 46.3 (x10m)
38 0.0 0.0 (x10m)
39 83.0 3.2 (x10m)
40 0.0 10.3 (x10m)
41 15.0 1.2 (x10m)
42 107.0 89.1 (x10m)
```



## 10種演算法的輸出(預測和實際-XGBoost)

0 114.0 128.9 (x10m)  
1 139.0 137.0 (x10m)  
2 0.0 0.0 (x10m)  
3 80.1 58.3 (x10m)  
4 0.0 0.0 (x10m)  
5 0.0 0.0 (x10m)  
→ 6 58.0 0.0 (x10m)  
7 0.0 0.0 (x10m)  
8 33.0 12.1 (x10m)  
9 7.0 0.0 (x10m)  
10 148.0 109.8 (x10m)  
11 0.0 0.0 (x10m)  
12 68.0 64.7 (x10m)  
→ 13 0.0 52.7 (x10m)  
→ 14 64.0 0.0 (x10m)  
15 14.0 0.0 (x10m)

16 145.0 129.9 (x10m)  
17 111.0 121.7 (x10m)  
18 0.0 0.0 (x10m)  
19 115.0 108.0 (x10m)  
20 0.0 0.0 (x10m)  
21 39.0 30.0 (x10m)  
22 0.0 0.0 (x10m)  
23 0.0 0.0 (x10m)  
24 0.0 21.2 (x10m)  
25 93.0 98.8 (x10m)  
26 82.0 79.4 (x10m)  
27 0.0 0.0 (x10m)  
28 105.0 106.2 (x10m)  
29 0.0 0.0 (x10m)  
30 130.0 130.8 (x10m)  
31 143.0 131.0 (x10m)

→ 32 94.0 110.9 (x10m)  
→ 33 76.0 0.0 (x10m)  
34 149.0 130.4 (x10m)  
35 0.0 0.0 (x10m)  
36 16.0 0.0 (x10m)  
37 24.0 43.1 (x10m)  
38 0.0 0.0 (x10m)  
→ 39 83.0 31.6 (x10m)  
40 0.0 0.0 (x10m)  
41 15.0 0.0 (x10m)  
42 107.0 109.5 (x10m)  
43 41.0 40.5 (x10m)  
44 62.0 83.9 (x10m)  
→ 45 79.0 21.8 (x10m)  
46 126.0 129.9 (x10m)  
47 9.0 20.5 (x10m)  
48 0.0 0.0 (x10m)  
49 59.0 52.9 (x10m)

**初步成功  
待優化**

- 說明:50筆盲測資料,左邊是實際距離熱源的值,右邊是預測的值,0.0表示到達熱源
- 有些資料缺項,自行想像補上,造成上面的紅箭頭
- 用不到200筆資料訓練,十分有成效



## (應用範例三)

前鎮儲運所C-1304壓縮機故障預知(健康指標)



# 預知保養及設備剩餘壽命預估(Health Index)

## 國際煉廠AI應用實例

### 案例一：最佳化觸媒壽命與確保產品品質

YOKOGAWA之網頁

【一家生產乙烯的公司】

為防止加氫反應的觸媒性能不佳，因此定時更換觸媒，造成兩種情況：一種是觸媒尚可使用即更換，造成很大的浪費，一種是更嚴重的狀況，觸媒已經不能再使用卻未更換，造成產品不合格等巨大的損失。

藉由AI的深度學習，得到健康指標(Health Index)，可以最大化觸媒壽命並且避免緊急停爐。



- 資料來源：<https://www.oilandgaseng.com/articles/artificial-intelligence-identifies-process-abnormality-causes/>


# 預知保養及設備剩餘壽命預估(Health Index)

## 國際煉廠AI應用實例 案例二：裂解爐的控制改善

裂解爐為防止過度裂解，需控制溫度小於35度，2019年突然變得無法控制。利用2018-2019年的資料，AI運算冷卻水流速與溫度，由AI模型建立健康指標(Health Index)，讓設備恢復正常。

資料來源：

<https://www.oilandgaseng.com/articles/artificial-intelligence-identifies-process-abnormality-causes/>

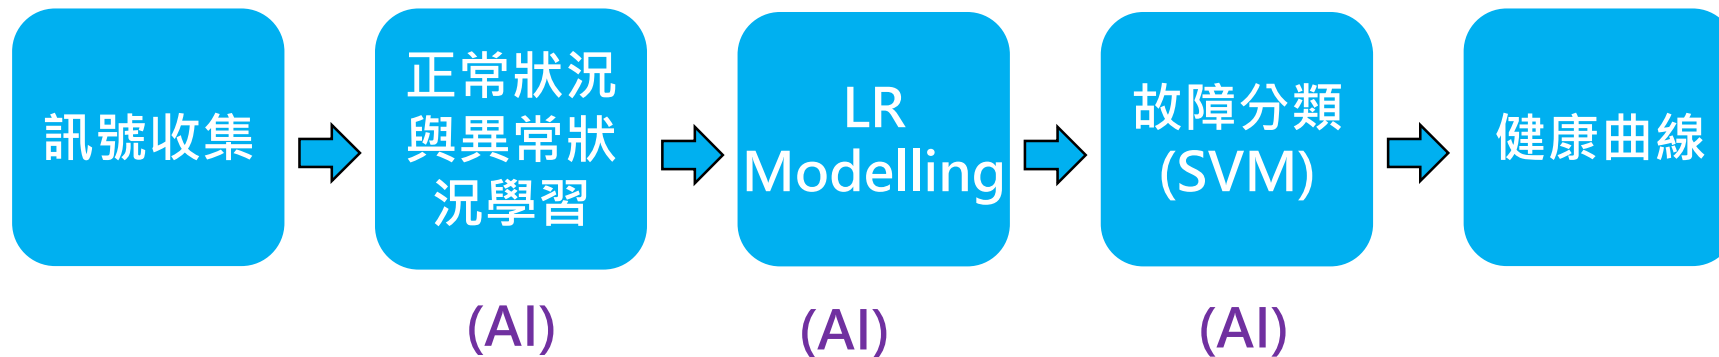


# 工業界應用案例1 :前鎮儲運所 C - 1 3 0 4 壓縮機故障預知

- 所謂AI，需透過一定數據學習後方能使用

## 有異常就能預測

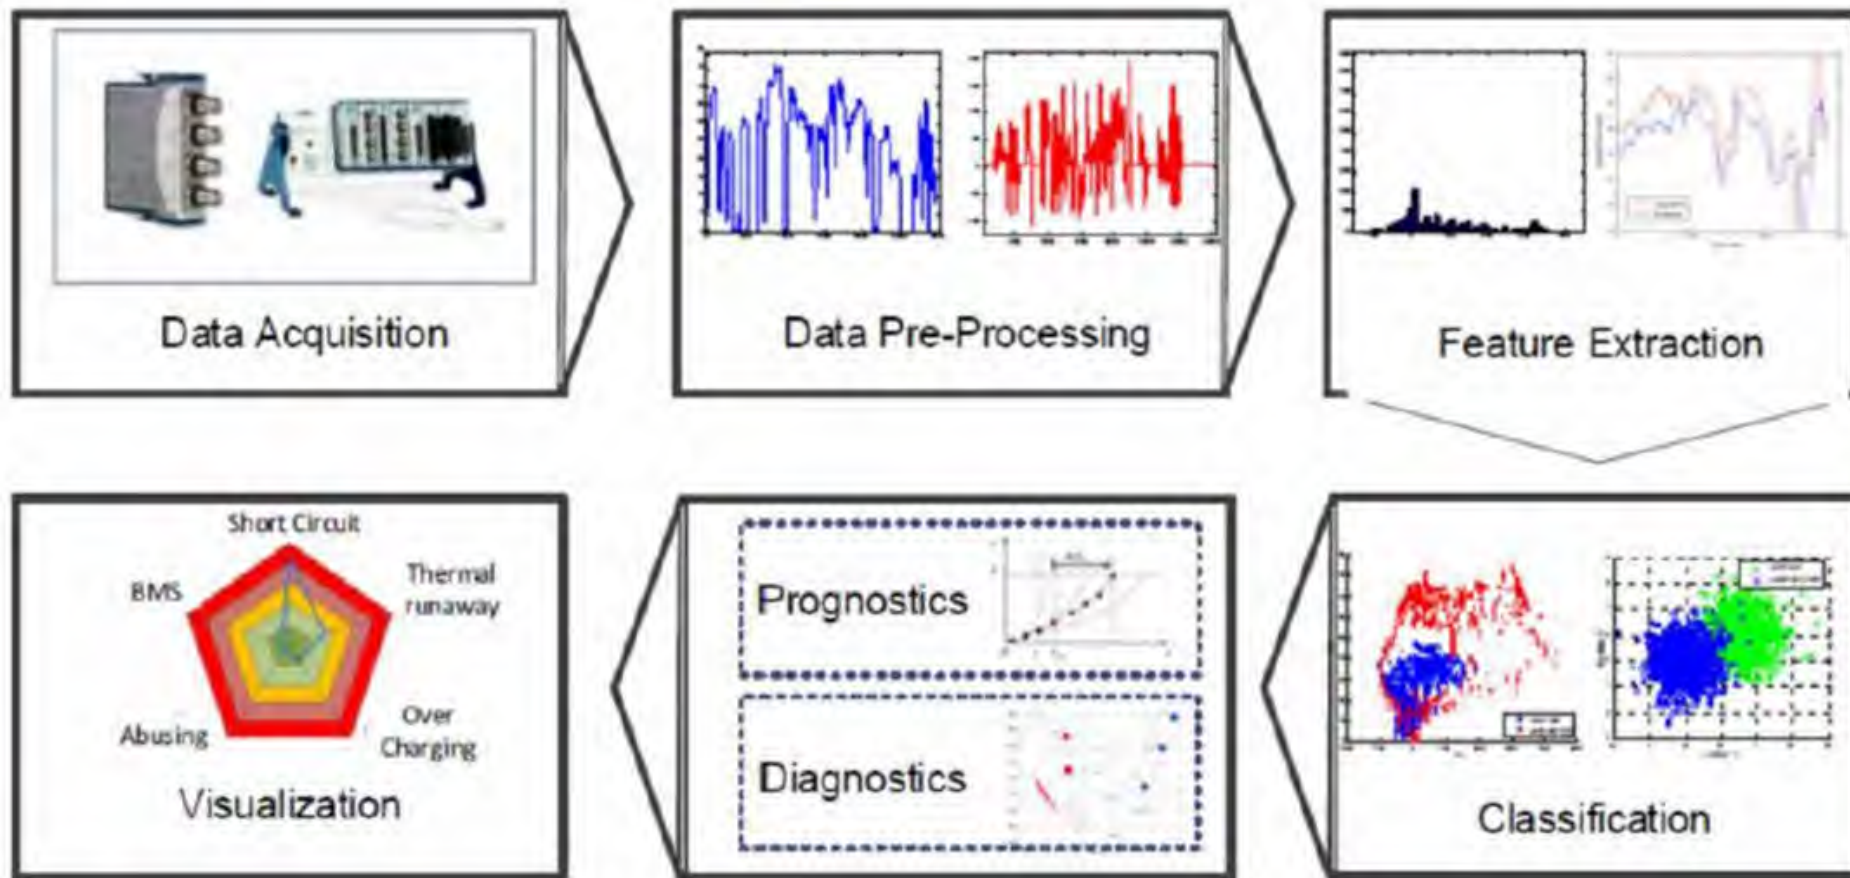
- 設備故障預測的AI，通常使用RNN，或LSTM/AR Modelling/LR Modelling(邏輯回歸)



前鎮儲運所C-1304壓縮機



# 設備故障預測之 AI 技術方塊圖



# 設備故障預測方塊圖




# (A)資料收集系統架構圖




加速規安裝位置



電流、溫度、壓力數據擷取



數據擷取程式



數據源與壓縮機示意



## (B)資料收集


### 數據說明

模型使用壓縮機於4/12至5/16期間產生之振動、電流、溫度與壓力數值紀錄進行開發。部分訊號轉為電流輸出，其資訊列於表1。

表1 訊號轉換資訊

	電流	溫度	壓力
原始	0~1000A	-100~+200°C	PT-341: 0~ 1 kg PT-342: 0~25kg PT-343: 0~10kg
輸出	4~20mA	4~20mA	4~20mA


# (A)資料收集




振動數據




電流數據




溫度數據 (TT-341)



溫度數據 (TT-342)



壓力數據 (PT-341)




壓力數據 (PT-342)



壓力數據 (PT-343)

# (C)資料清洗(前處理)

## 數據前處理





# (D)特徵提取

# 第一次事件分類

## 提取特徵

表2 提取特徵

Features	
Time domain	Mean
	Variance
	Median
	Kurtosis
	Skewness
	Peak Value
	Peak to Peak
	Crest Factor
	Impulse Factor
	Shape Factor
	Clearance Factor
	Margin Factor
	Energy
	Entropy

表3 衰退趨勢關鍵特徵


Sequence	Feature	Explanatory Power (%)
1	TT-342 - Energy	8.76
2	TT-342 - Entropy	8.74
3	TT-342 - Peak Value	8.73
4	TT-342 - Mean	8.69
5	TT-342 - Median Value	8.68
6	PT-342 - Energy	5.17
7	PT-342 - Entropy	5.15
8	PT-342 - Mean	5.05
9	PT-342 - Median Value	5.05
10	PT-342 - Peak Value	5.03
⋮		

53.92%

## (D) 特徵提取

## 第二次事件分類(控制閥故障)

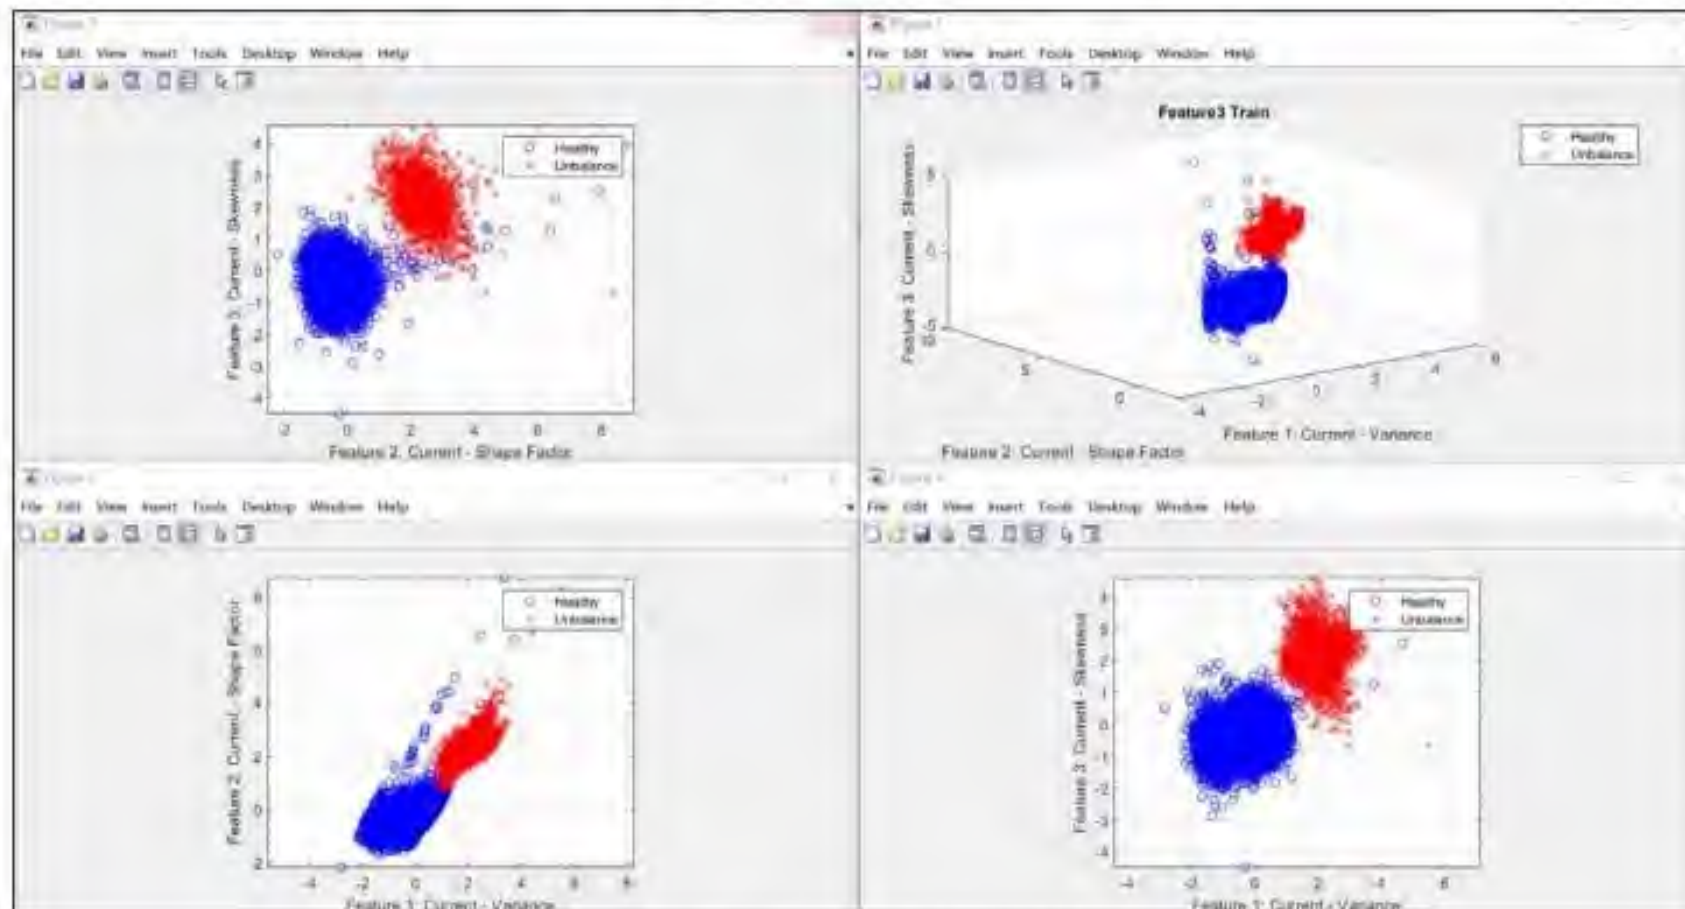
(解釋力)



Sequence	Feature	Explanatory Power (%)
1	IT-1304 - Variance	24.05
2	IT-1304 - Shape Factor	10.90
3	IT-1304 - Skewness	9.90
4	PT-342 - Median Value	3.26
5	PT-342 - Mean	3.26
6	PT-342 - Entropy	3.26
7	PT-342 - Energy	3.26
8	PT-342 - Peak Value	3.24
9	Vibration - Median Value	2.64
10	Vibration - Shape Factor	2.48
	⋮	

# (E)測試結果(定性) - 測試結果:健康與故障分區圖(SVM分類)

## 不同關鍵特徵與分類模型結果



特徵三維分布 (前3名)



## (E)測試結果(定性) - 測試結果:第二次事件(控制閥故障)


### 診斷模型結果

- 使用SVM Classification建立模型
- 分類準確率  
Cross-validation: 99.81%  
Confusion Matrix: 99.83%



SVM 狀態分類

# 健康指標操作平台





## (應用範例四)

(4.1)無故障歷史資料之異常預測(P-1002B)桃園煉油廠

(4.2)驗證(C2001與C4001)大林煉油廠



## (4.1)無故障歷史資料之異常預測(P-1002B)桃園煉油廠

### • 資料說明

- 使用桃園廠P1002B數據做為模型訓練資料
- 感測器數據：來自11個感測器數值，共 876,963 筆時序數據
- 時間範圍：2019.10.22 至 2024.10.21，每3分鐘一筆數據
- 感測器資訊如下：

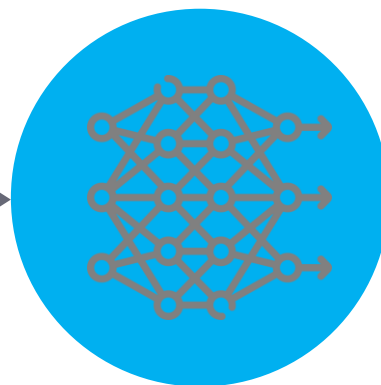
滑油壓力A點	滑油壓力B點	滑油壓力C點	滑油壓力點	滑油溫度	泵浦出口壓力值	馬達電流值	泵浦出口流量	重油進料API	重油進料運動黏度	重油進料比重
(kgf/cm <sup>2</sup> G)	(kgf/cm <sup>2</sup> G)	(kgf/cm <sup>2</sup> G)	(kgf/cm <sup>2</sup> G)	(°C)	(kgf/cm <sup>2</sup> G)	(A) 僅從2023-12月-20日開始有資料	(M <sup>3</sup> /hr)	999為停機數值	(cST) 999為停機數值 1m <sup>2</sup> /s=1,000,000cST	由api計算 =(141.5/(API+131.5))
2RDS1PI_353APV	2RDS1PI_353BPV	2RDS1PI_353CPV	2RDS1PI_354PV	2RDS1TI_395PV	2RDS1PI102BPV	2RDS1II_P1002BPV	2RDS1FI103PV	2A8D1001O0053	2A8D1001OD0027	HeavyOilFeedDensity

# 研究方法及進行步驟




## 資料讀取

收集來自中油PI資料和維修紀錄，以確認設備故障時間。透過資料清洗和前處理來優化輸入資料，提升系統分析準確性。



## 模型訓練

根據訓練資料設計並訓練模型，預計輸出設備健康度。



## 可視化驗證

設計一個可視化界面，輸入PI資料後顯示設備的健康度。

# 資料讀取

## • 資料清洗

1. 剔除空數值：處理**缺失值**（如 Null、No Data、Error），刪除異常資料。
  - ✓ 2RDS1II\_P1002BPV(空數值過多, 佔資料集約**72萬多筆**)
  - ✓ 2A8D100100053(停機數值999以及空數值較多, 佔資料集約**10萬多筆**)
  - ✓ 2A8D10010D0027 (停機數值999以及空數值較多, 佔資料集約**11萬多筆**)
2. 感測器資料處理：檢查感測器數據**是否異常**，並決定是否需要**剔除不可靠**的資料。
  - ✓ 重油進料比重(數據對故障事件**無影響**)


滑油壓力A點	滑油壓力B點	滑油壓力C點	滑油壓力點	滑油溫度	泵浦出口壓力值	馬達電流值	泵浦出口流量	重油進料API	重油進料運動黏度	重油進料比重
(kgf/cm <sup>2</sup> G)	(kgf/cm <sup>2</sup> G)	(kgf/cm <sup>2</sup> G)	(kgf/cm <sup>2</sup> G)	(°C)	(kgf/cm <sup>2</sup> G)	(A) 僅從2023-12月-20日開始有資料	(M <sup>3</sup> /hr)	999為停機數值	(cST) 999為停機數值 1m <sup>2</sup> /s=1,000,000 cST	由api計算 =(141.5/(API+131.5))
2RDS1PI_353APV	2RDS1PI_353BPV	2RDS1PI_353CPV	2RDS1PI_354PV	2RDS1TI_395PV	2RDS1PI102BPV	2RDS1II_P1002BPV	2RDS1FI103PV	2A8D100100053	2A8D10010D0027	HeavyOilFeed Density



# 資料讀取

- 資料清洗

- 重油進料比重(數據對故障事件**無影響**)
  - 團隊以其他異常值的集合為基礎來進行分析，發現重油進料比重的數據波動與設備損壞較無直接的影響。
  - 推斷該感測器的數據特性與故障事件的**相關性較低**，因此在後續分析考慮中剔除該感測器，以簡化模型並提高整體訓練效率。



# 資料讀取

- 資料前處理

- 資料正規化:

- Min-Max normalization [1]:此方法將數據x縮放到 [0, 1] 範圍，公式如下：

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

- 定義故障事件

- 為了有效識別潛在的故障事件，我們採用統計學中的 **四分位距法 (IQR)** [2]作為數據分散程度的衡量指標。IQR 是 **第三四分位數 (Q3)** 與 **第一四分位數 (Q1)** 的差值，公式如下：

$$\text{IQR} = \text{Q3} - \text{Q1}$$

- 根據統計經驗法則，數據若 **超出 1.5 倍 IQR** 的範圍，則可視為潛在的異常或故障事件，計算方式如下：

$$\text{下限} = \text{Q1} - 1.5 \times \text{IQR}$$

$$\text{上限} = \text{Q3} + 1.5 \times \text{IQR}$$

[1] Islam, M. J., Ahmad, S., Haque, F., Reaz, M. B. I., Bhuiyan, M. A. S., & Islam, M. R., "Application of min-max normalization on subject-invariant EMG pattern recognition," *IEEE Transactions on Instrumentation and Measurement*, vol. 71, pp. 1–12, 2022.

[2] Swami, R., Dave, M., & Ranga, V., "IQR-based approach for DDoS detection and mitigation in SDN," *Defence Technology*, vol. 25, pp. 76–87, 2023.

# 資料讀取

- 資料前處理

- 資料來源：桃園廠 P1002B
- 資料清洗後數據資料概況：
  - 有7個感測器資料
  - 788,063筆時序數據
  - 時間範圍：2019.10.22 至 2024.10.21
- 定義故障事件：
  - 利用IQR來定義潛在的故障事件，並結合維修紀錄時間。
    - 正常事件: 744,472筆
    - 故障事件: 43,591筆



# 模型訓練

## • 模型建立

### • 長短期記憶網絡(Long Short Term Memory Network, LSTM)[3]:

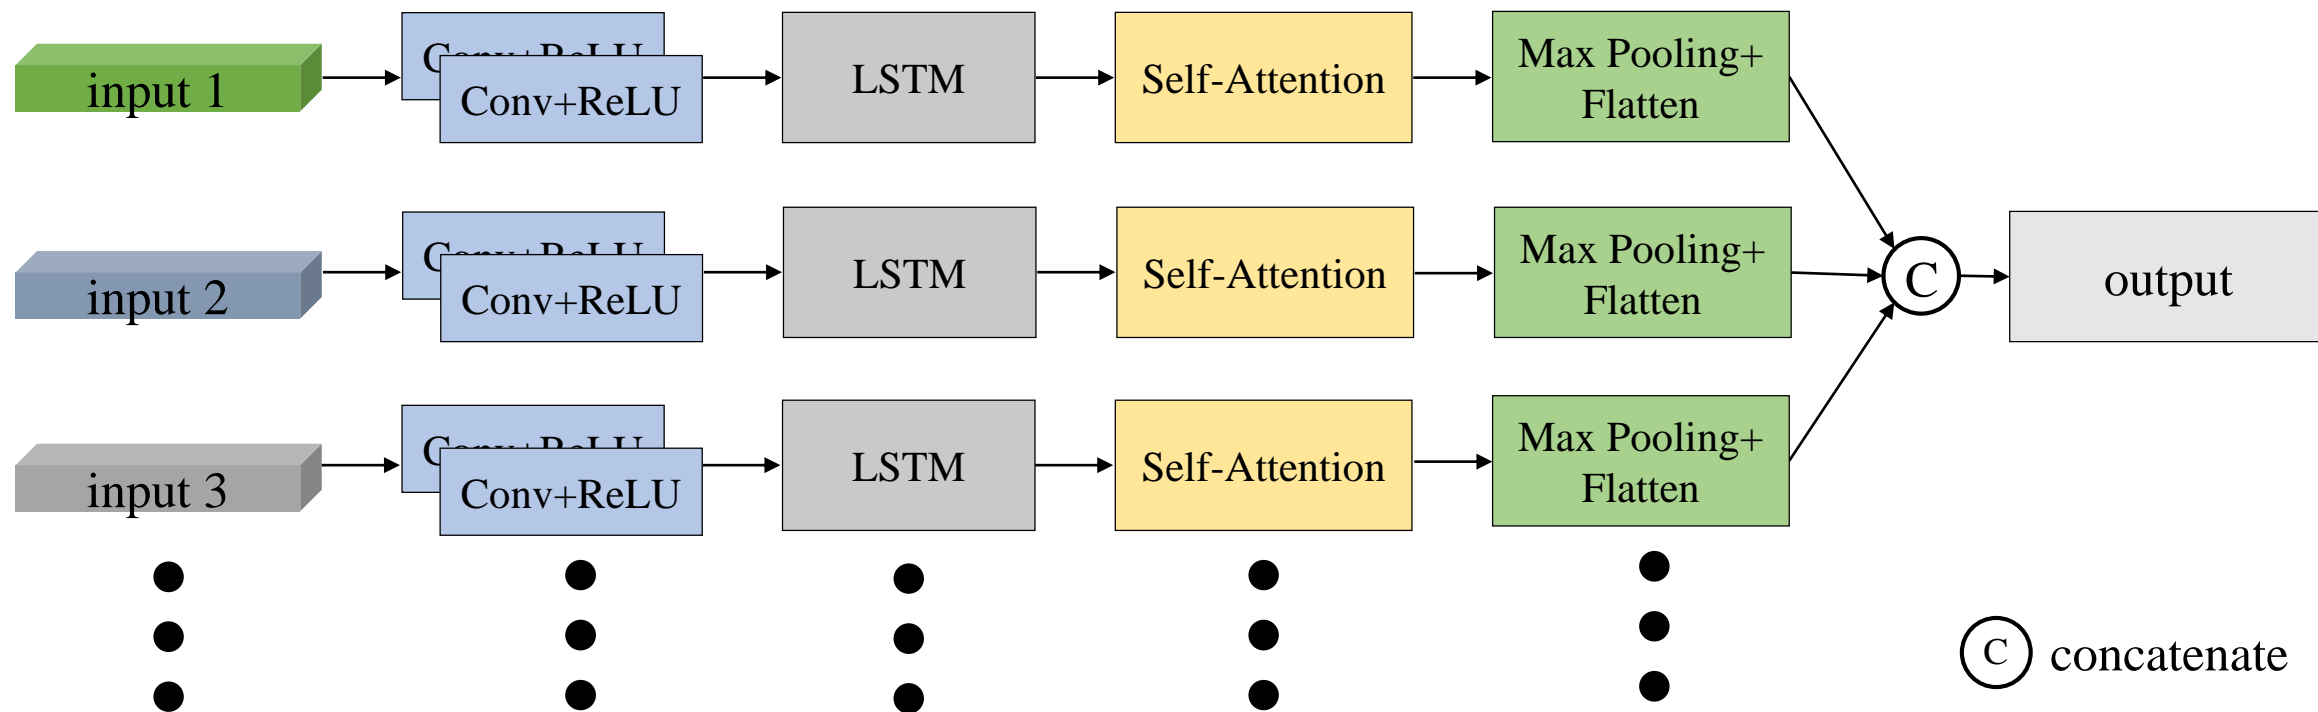
- LSTM主要用來處理時間序列的資料。它的特點是能夠記住很長時間的資訊，並且能夠選擇性地保留重要的記憶，忽略不重要的部分，這使得LSTM特別適合用來處理像語音、文字等需要記住過去狀況的任務。在模型訓練中，我們以三天的資料作為一個訓練單位，充分利用時間序列特性以提升模型效果。

### • 自注意力機制(Self-attention)[4]:

- Self-attention 是一種用來處理序列資料的技術，其特點是能夠讓模型在處理每個資料點時，自動關注序列中其他所有部分的重要性，這使得模型可以捕捉資料中各部分之間的關聯，而不僅限於鄰近的部分，Self-attention 機制讓模型能同時捕捉到短期和長期的依賴關係，並根據資料的不同部分給予不同的注意力。這種機制特別適合處理需要長距離依賴的任務，如語言理解、時序資料處理等。

# 模型訓練

- 模型建立



[5] Ayodeji, A., Wang, Z., Wang, W., Qin, W., Yang, C., Xu, S., & Liu, X, “Causal augmented ConvNet: A temporal memory dilated convolution model for long-sequence time series prediction,” ISA transactions, vol. 123, pp. 200-217, 2022.

# 可視化驗證

## 可視化區域:

- 數據點按**健康指數**分為**三個狀態**，以不同顏色表示：
  - 綠色：健康狀態（大於60%）
  - 橙色：警告狀態（30%-60%之間）
  - 紅色：故障狀態（小於30%）
- **輔助標線**：圖表上有**兩條水平線**標示重要的**健康指數門檻**：
  - 30%: 故障警戒值
  - 60%: 健康臨界值
- **互動功能**：將滑鼠移動至圖表上任意數據點，可即時查看該數據的詳細資訊，包括**時間**、**健康指數**與**狀態說明**。

## 操作區域

Rotating Machinery

Loda Data

Export As image

Clear data

Exit

## 可視化區域





# 成果說明

- 資料數量

- 資料數量共有788,063筆時序數據，將資料拆分為訓練資料以及測試資料

- 訓練資料: 選取前80% 的時序數據作為訓練資料

- 共631,890筆時序資料

- 時間範圍: 2019.10.22 00:00:00 至 2023.11.24 02:51:00，每3分鐘一筆數據

- 測試資料: 選取後20% 的時序數據作為測試資料

- 共156,173筆時序資料

- 時間範圍: 2023.11.24 02:54:00 至 2024.10.21 23:57:00，每3分鐘一筆數據

# 成果說明

## • 訓練結果

	7 sensors	8 sensors
輸入感測器選擇	滑油壓力A點、滑油壓力B點、滑油壓力C點、滑油壓力點、滑油溫度、泵浦出口壓力值、泵浦出口流量	滑油壓力A點、滑油壓力B點、滑油壓力C點、滑油壓力點、滑油溫度、泵浦出口壓力值、泵浦出口流量、 <u>重油進料比重</u>
精確率 (Precision)	$\frac{4083}{4083 + 43} = \mathbf{0.989}$	$\frac{4544}{4544 + 90} = 0.980$
召回率 (Recall)	$\frac{4083}{4083 + 38} = \mathbf{0.990}$	$\frac{4544}{4544 + 110} = 0.976$
F1 score	$2 \times \frac{0.989 \times 0.990}{0.989 + 0.990} = \mathbf{0.989}$	$2 \times \frac{0.980 \times 0.976}{0.980 + 0.976} = 0.978$

7sensors		實際值	
		故障事件	正常事件
預測值	故障事件	4083	43
	正常事件	38	152009

8 sensors		實際值	
		故障事件	正常事件
預測值	故障事件	4544	90
	正常事件	110	151429

剔除不可靠的感測器資訊能有效提升結果的準確性

## (4.2) 驗證(C2001與C4001)大林煉油廠

– C2001感測器資訊如下，正常事件: 735515筆，故障事件: 150805筆(包含維修紀錄17筆):

- C-2001密封氣加熱器接線(2023/11/10)
- C-2001機房空調箱皮帶斷(2022/11/30)
- C-2001壓縮機 PCV-2577 壓力不足(2022/11/7)
- C-2001壓縮機軸心吊桿搬運(2022/7/1)
- C-2001油霧風扇接線(2022/6/15)
- C-2001OMF 拆線(2022/6/10)
- C-2001OMF 檢修(2022/6/10)
- C-2001機房 FM200 Low batt(2021/1/27)
- C-2001/PDI2552 差壓偏高(2021/1/19)
- C-2001超速跳車(2020/6/14)
- 協助查修C-2001 LCP ACS問題(補單)(2020/6/11)
- 烷化MCC、C-2001、C-4001空調皮帶檢(2019/12/18)
- C-2001壓縮機房空調箱皮帶斷(2018/9/25)
- C-2001 LCP室空調皮帶斷，請更換。(2018/5/2)
- C-2001 LCP 冷卻風扇故障需更換(2017/5/16)
- C-2001 m-2034a濾芯更換(滑油)(2016/8/29)
- C-2001 LCP 檢修(補單)(2015/11/16)


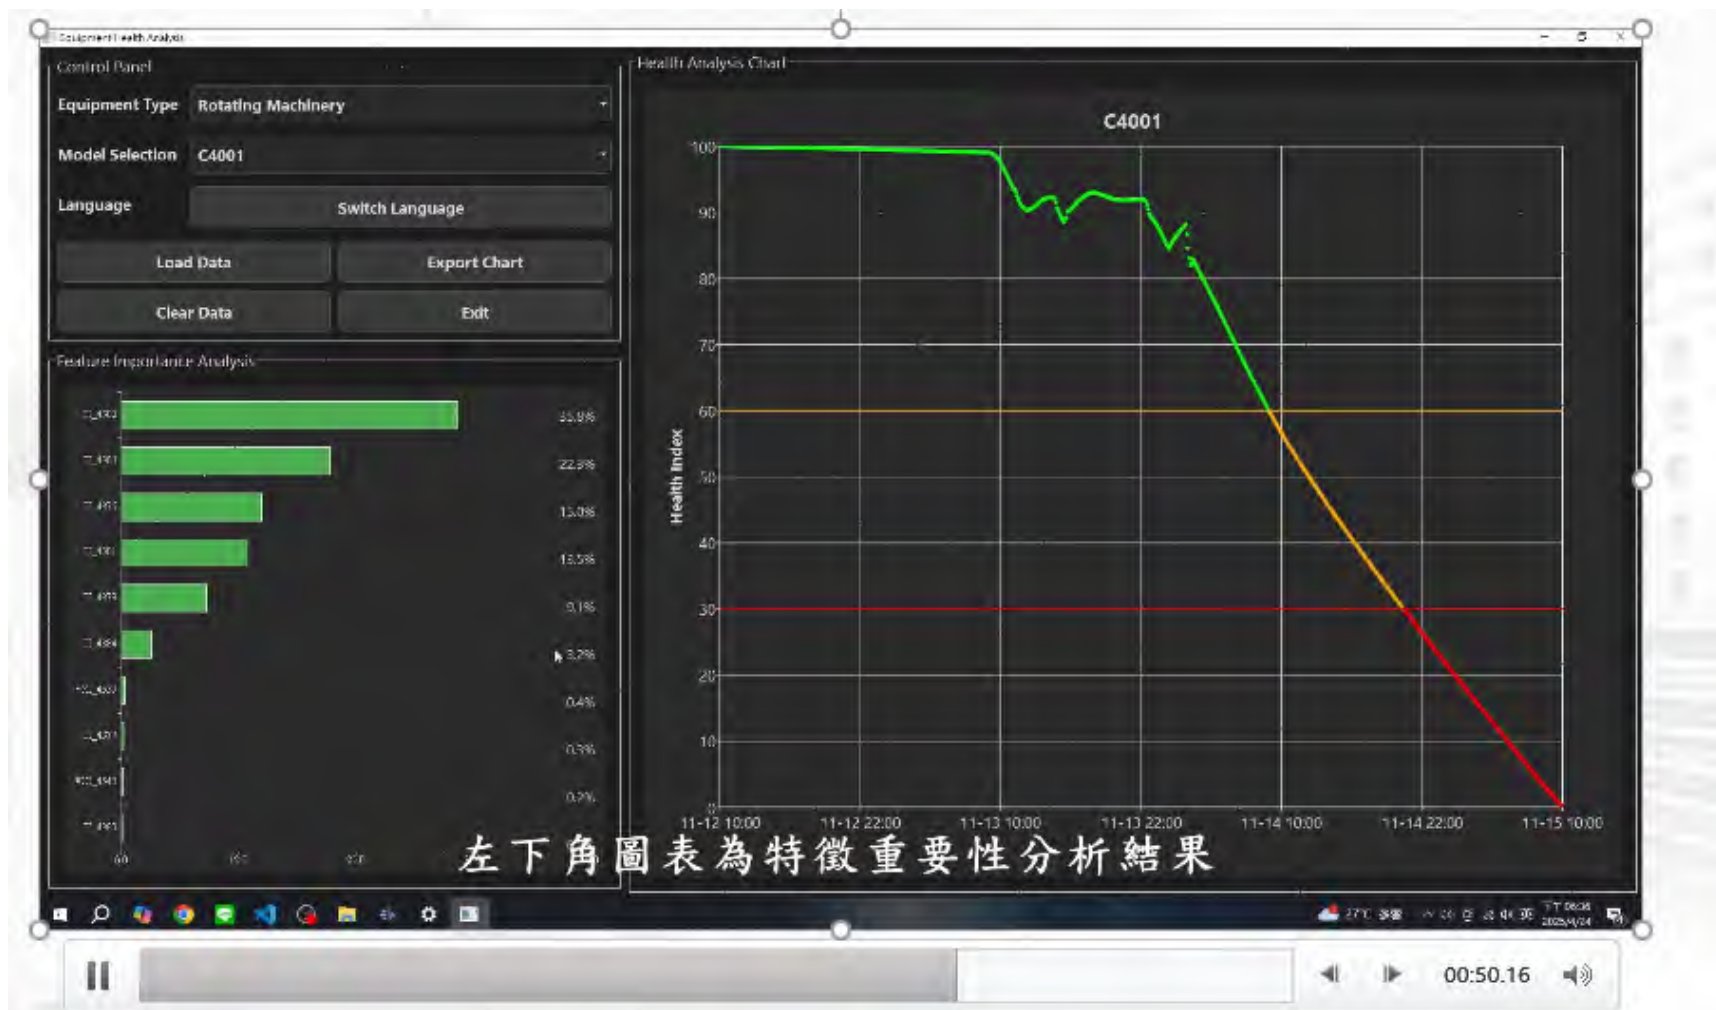
– C4001感測器資訊如下，正常事件: 871223筆，故障事件: 15097筆(包含維修紀錄5筆):

- C-4001振動點VI-4537/VI-4538(2024/3/15)
- C-4001進口端短管拆清(補單)(2021/5/19)
- C-4001/FT4306顯示異常(補單)(2021/1/27)
- 葉輪室內部累積許多硫酸鹽(2020/11/24)
- 烷化MCC、C-2001、C-4001空調皮帶檢查(2019/12/18)



# 成果說明

2天前預知  
設備即將故障，  
可以調整左側  
特徵(流量, 壓  
差, 溫度等), 使  
設備回復正常  
或延緩發生



C2001感測器資訊如下，正常事件: 735515筆，故障事件: 150805筆(包含維修紀錄17筆)

C4001感測器資訊如下，正常事件: 871223筆，故障事件: 15097筆(包含維修紀錄5筆)

# 擴大案件執行 台科大開口合約成果,驗證有效後,大量推動

## 可視化驗證結果C2001m

維修紀錄：2034a濾芯更換(滑油)(2016/8/29)

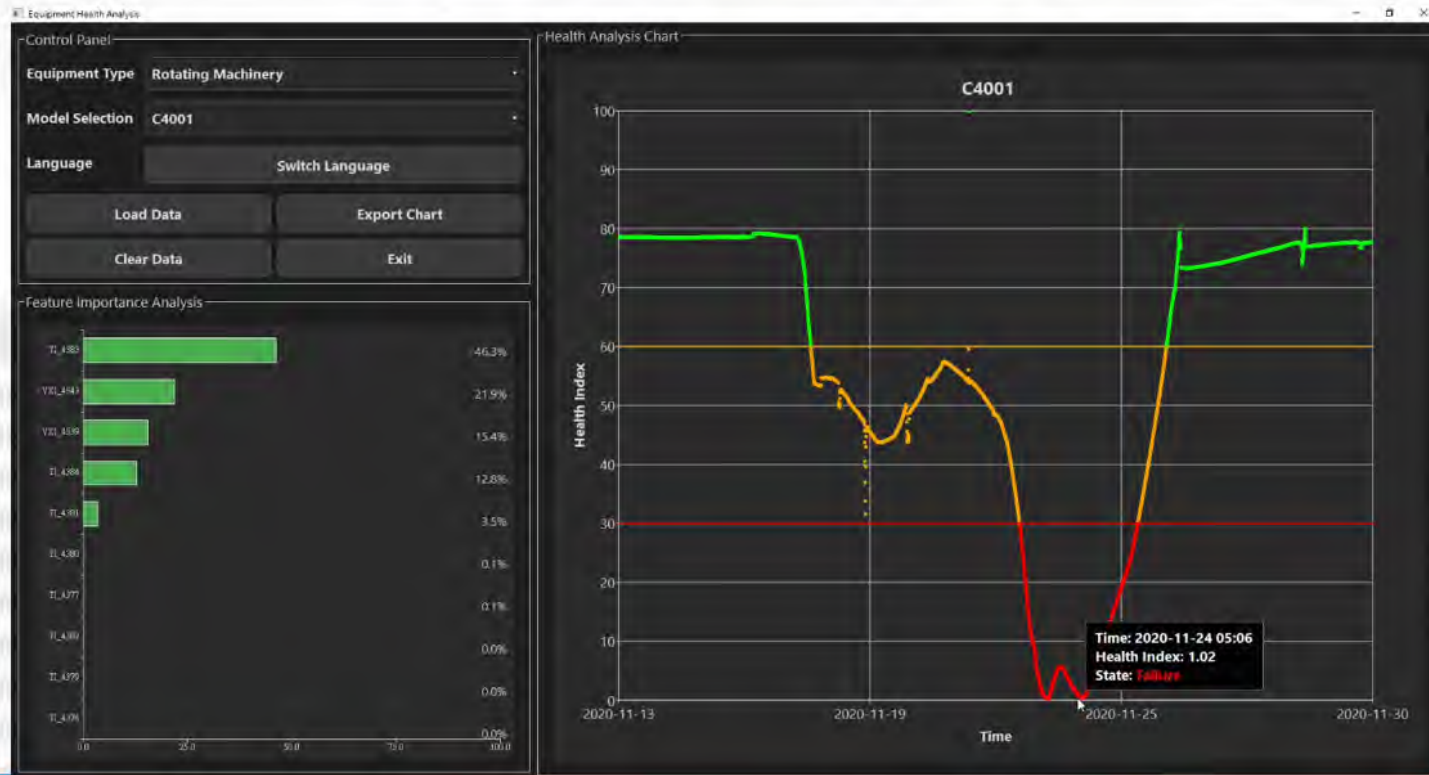
調整左側特徵,使設備回復正常或延緩發生



# 可視化驗證結果C4001

## 葉輪室內部累積許多硫酸鹽(2020/11/24)

調整左側特徵，  
使設備回復正常或延緩發生







## (應用範例五)

# AI診斷煉油廠設備複雜多樣態之故障預測(AI可用性驗證)

總工程師室儀控轉機中心 + 大林廠轉機課

# 設備故障預測之 AI 技術方塊圖

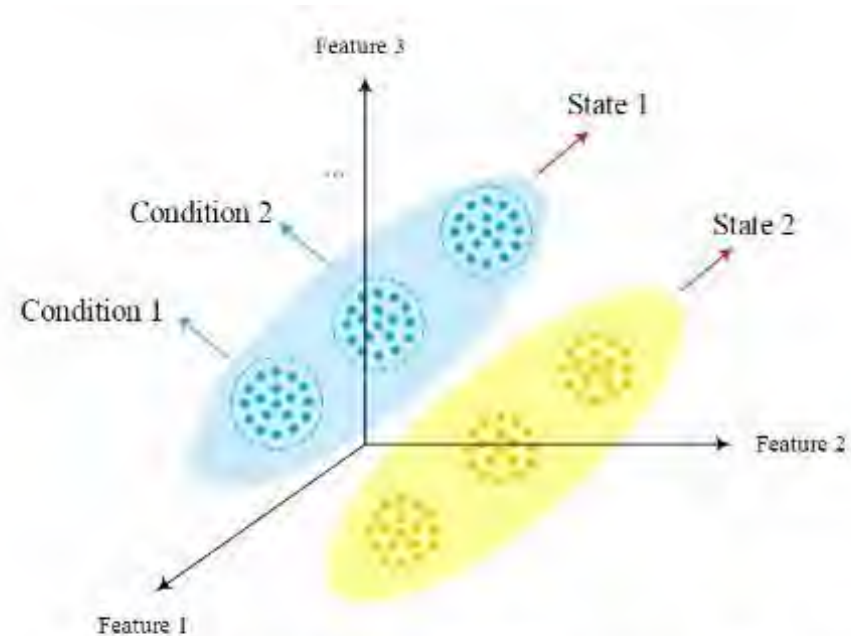
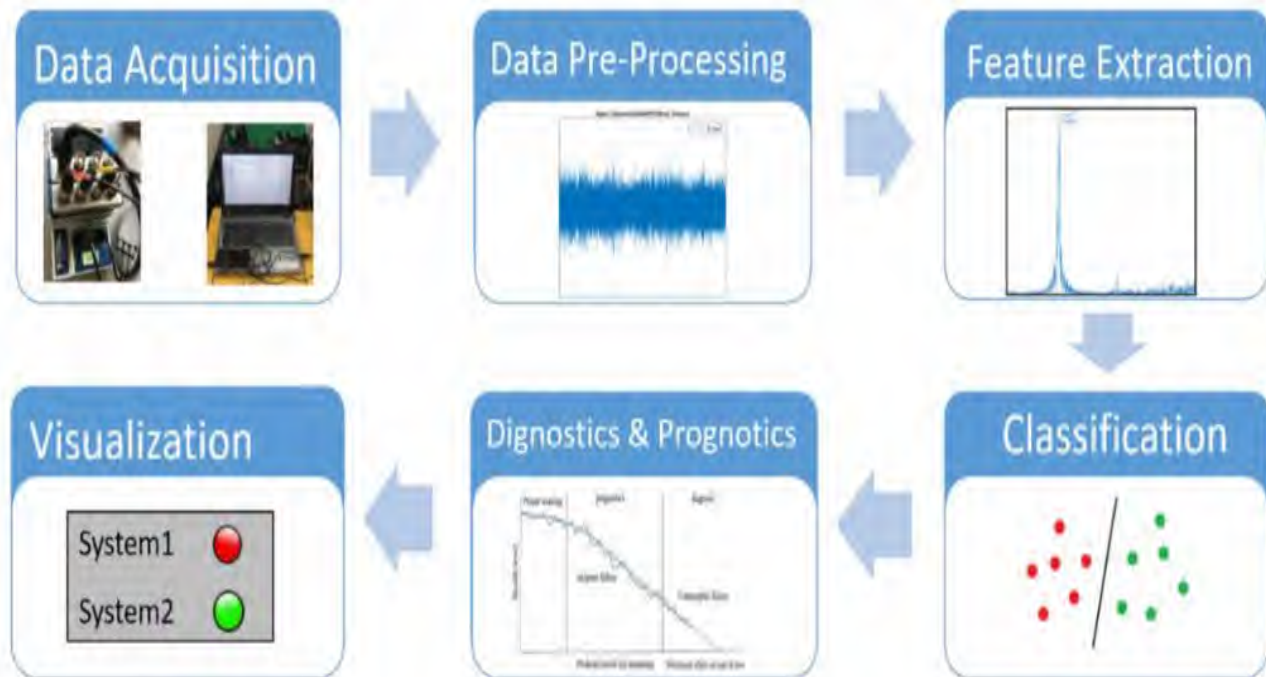


Fig. 1. Distribution of typical features under different operating conditions.

需求：可以分辨Health與Faulty1/Faulty2

# (A)資料收集系統

## 多樣態故障判別之測試方法:

- 馬達正常運轉下，約15分鐘，處在抽油狀態，檔案編號為**1 (狀態為正常)**。
- 底座鬆動，約15分鐘，過程中後段時間，油被抽光，變成抽水，收集到的檔案編號為**2 (狀態為底座鬆動-抽水)**。
- 再次收集震動數據(底座鬆動-抽水狀態)約15分鐘，收集到的檔案編號為**3 (狀態為鬆螺絲-抽水)**。
- 調整螺絲，進行偏心狀態下的震動數據收集，約15分鐘，收集到的檔案編號為**4 (狀態為偏心)**。



類比數位轉換器，數據取樣率為977 Hz  
學習 底座鬆動/偏心/正常等三種狀態



# (B)設備故障預測流程圖

流程

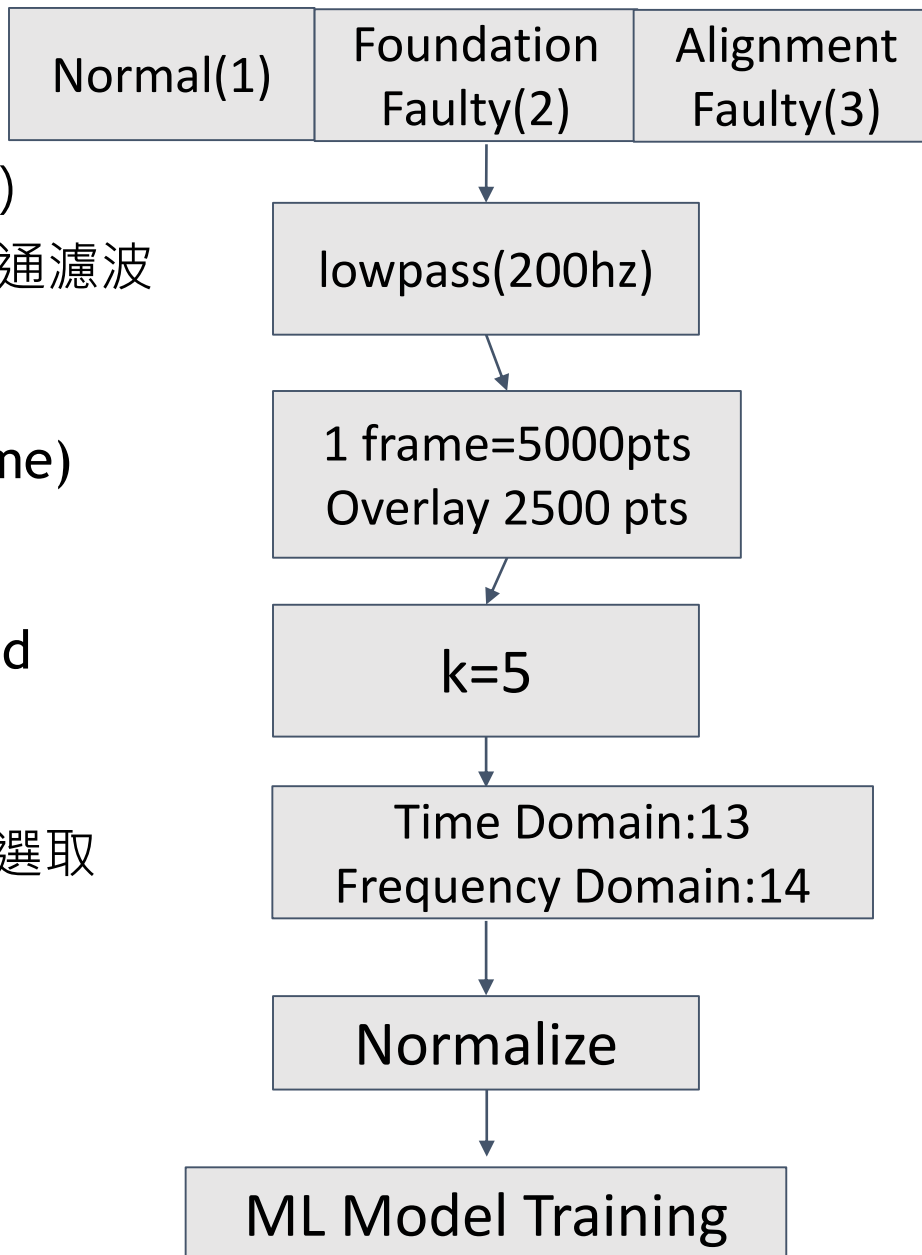
讀取資料  
(將啟動階段取樣點去除)

低通濾波

取樣點分幀(frame)

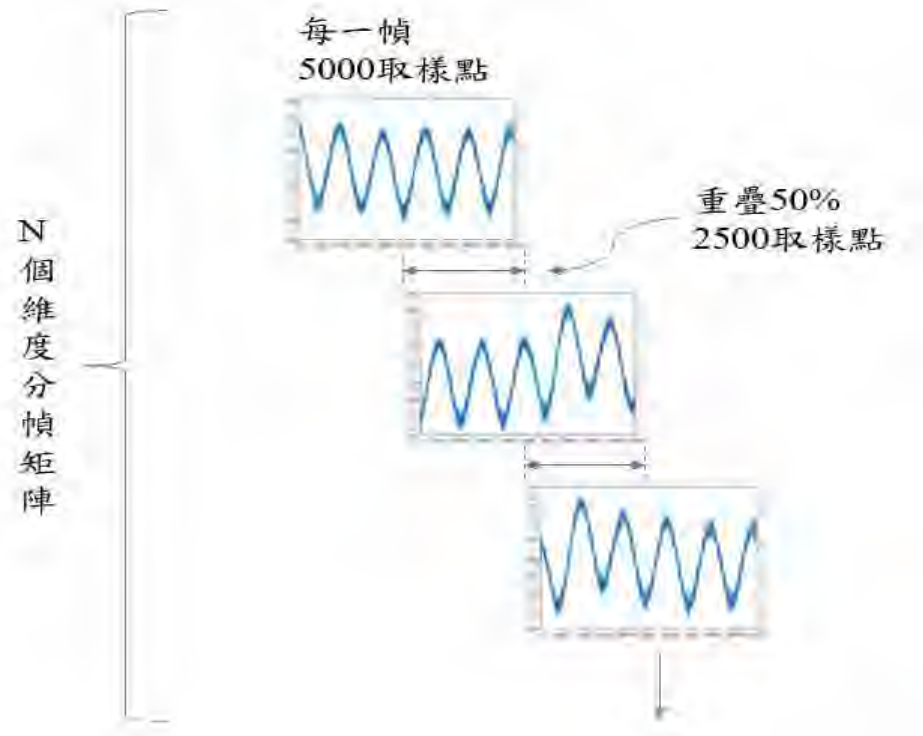
k-fold

特徵選取




## (C)資料前處理

- 濾波—去除200 Hz以上頻率訊號
- 分幀
  - 將訊號以5000取樣點為一幀，
  - 前後幀的重疊率為50%，前後幀有2500取樣點為重複



### 特徵擷取




震動訊號(正常、偏心、鬆螺絲)分幀示意圖

# (D)資料讀取與區塊切割


## 分幀

正常  
358個




底座鬆動  
抽油


底座鬆動  
546個



偏心  
386個



底座鬆動  
抽水



偏心  
抽水



## (D)資料讀取與區塊切割

### 標籤分為正常、底座鬆動、偏心

Excel 資料檔分配:

{(1)正常抽油}、{(2)底座鬆動抽油、(3)底座鬆動抽水}、{(4)偏心抽水}

標籤為:

正常(1)、鬆螺絲(2)、偏心(3)

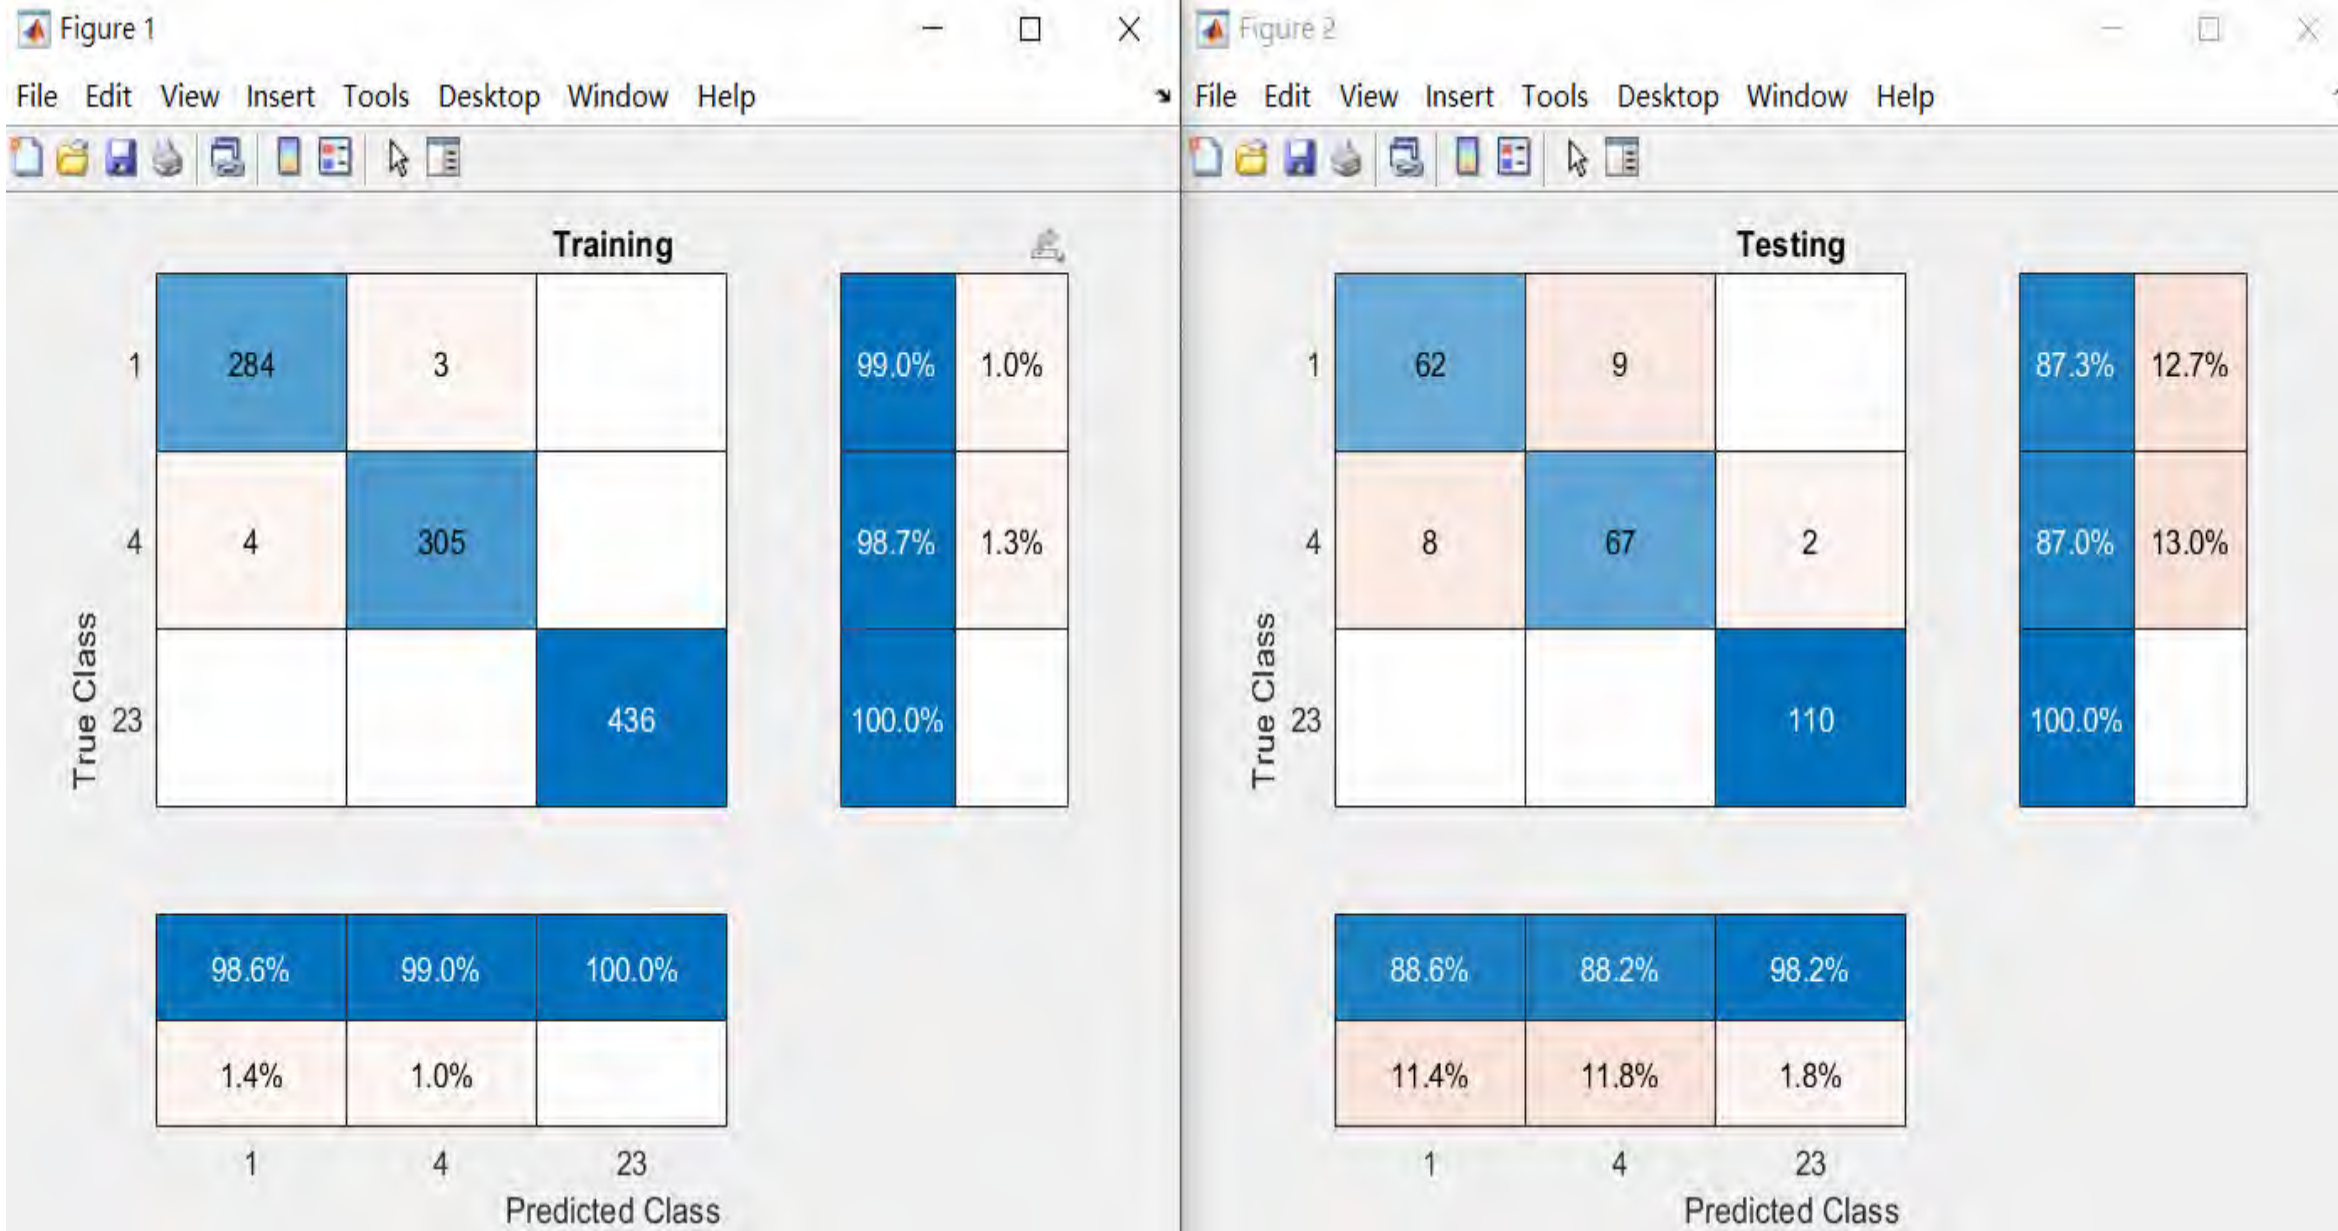
1. 使用matlab中support vector machines, SVM 之error-correcting output codes (ECOC) model分類函數 `fitcecoc`。
2. 使用KernalFunction中的gaussian參數。
3. 平均準確度：

--> train\_ave\_acc: 98.85

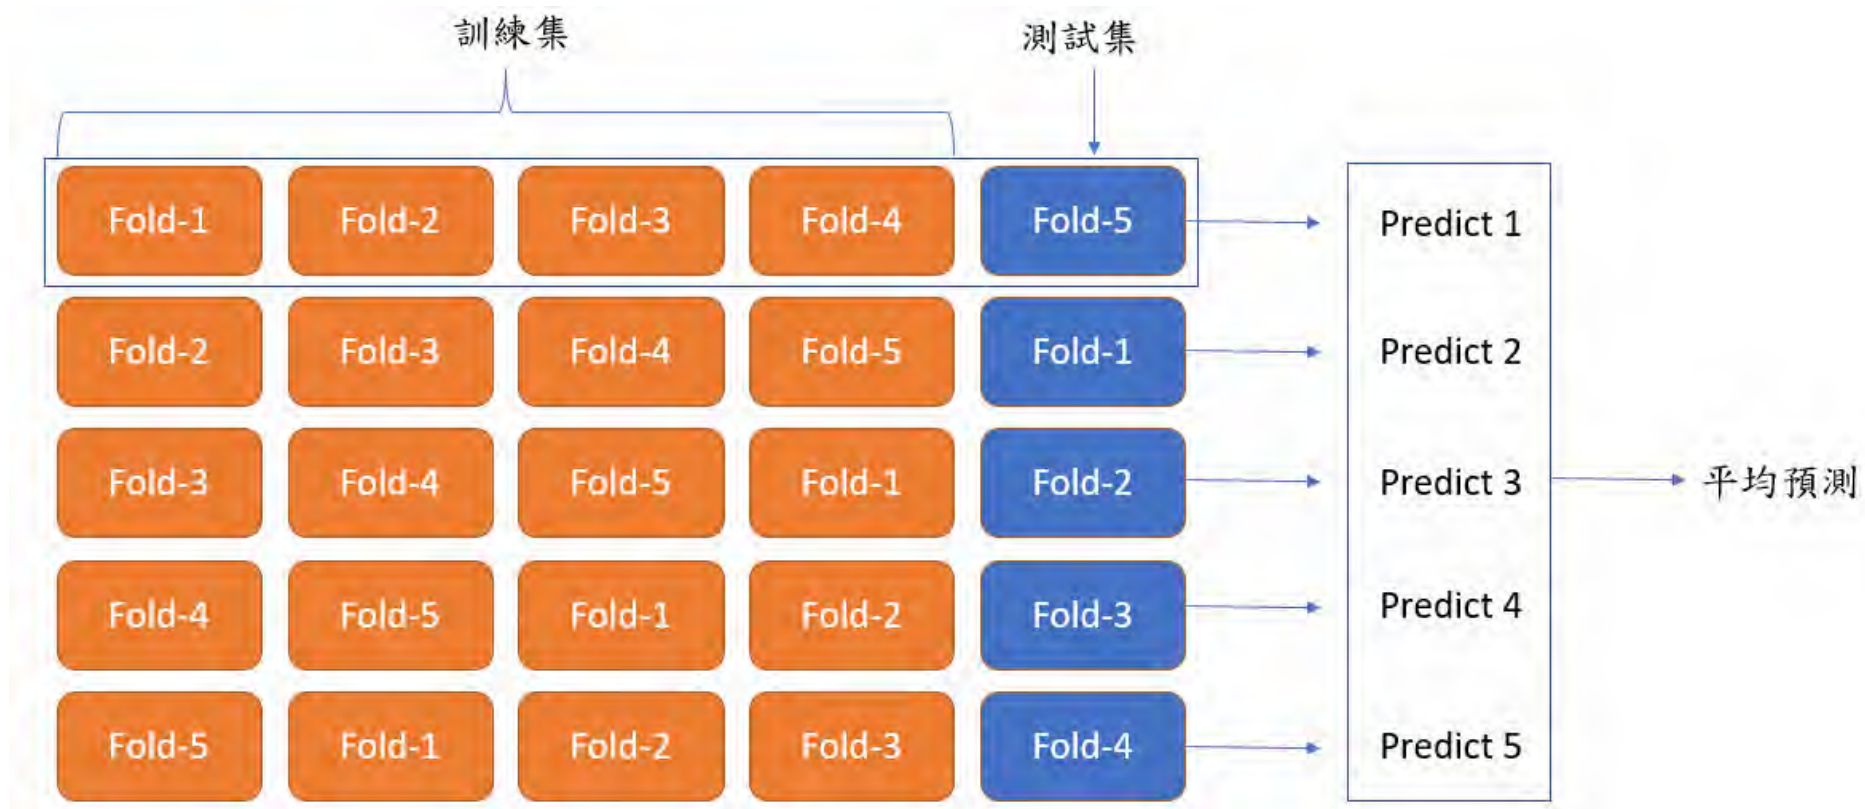
--> test\_ave\_acc: 94.49

label	
正常(1)	震動電流訊號-(1)標準正常訊號-抽油.csv
鬆螺絲(2)	震動電流訊號-(2)鬆螺絲訊號-抽油.csv
	震動電流訊號-(3)鬆螺絲訊號-抽水.csv
偏心(3)	震動電流訊號-(4)偏心訊號-抽水.csv
	震動電流訊號-(5)長距離-偏心訊號-抽水.csv
	震動電流訊號-(6)長距離-微偏心訊號-抽水.csv
	震動電流訊號-(7)長距離-微偏心+鬆螺絲訊號-抽水.csv

# (E)結果: FOLD1 之混淆矩陣



# 訓練加強







# (F)成果: 訓練階段(Training)

- **訓練階段**的整體準確度為99.7%，
- 狀態為正常的分類準確度為99.6%，
- 狀態為偏心的分類準確度為99.5%，
- 為底座鬆動的分類準確度為100%。

抽油水馬達資料集


資料集	正常(類別1)	鬆螺絲(類別3)	偏心(類別4)
訊號(幀)	358	546	386



20次5-fold訓練混淆矩陣

## (F) 成果: 測試階段(Test)

- 整體分類預測準確度為94.2
- 狀態為正常的分類預測準確度為90.3% ,
- 狀態為偏心的分類預測準確度為91.1% ,
- 狀態為底座鬆動的分類預測準確度為98.9%



20次5-fold測試混淆矩陣

# 設備之故障複雜多樣態區分之解決方案

## 成果—Real Time測試(正常狀態)




線上實測狀態類別1-正常狀態



# 設備之故障複雜多樣態區分之解決方案


## 成果—Real Time測試(馬達底座鬆動)



線上實測狀態類別23- (馬達底座鬆動)

# 設備之故障複雜多樣態區分之解決方案

## 成果—Real Time測試(偏心)

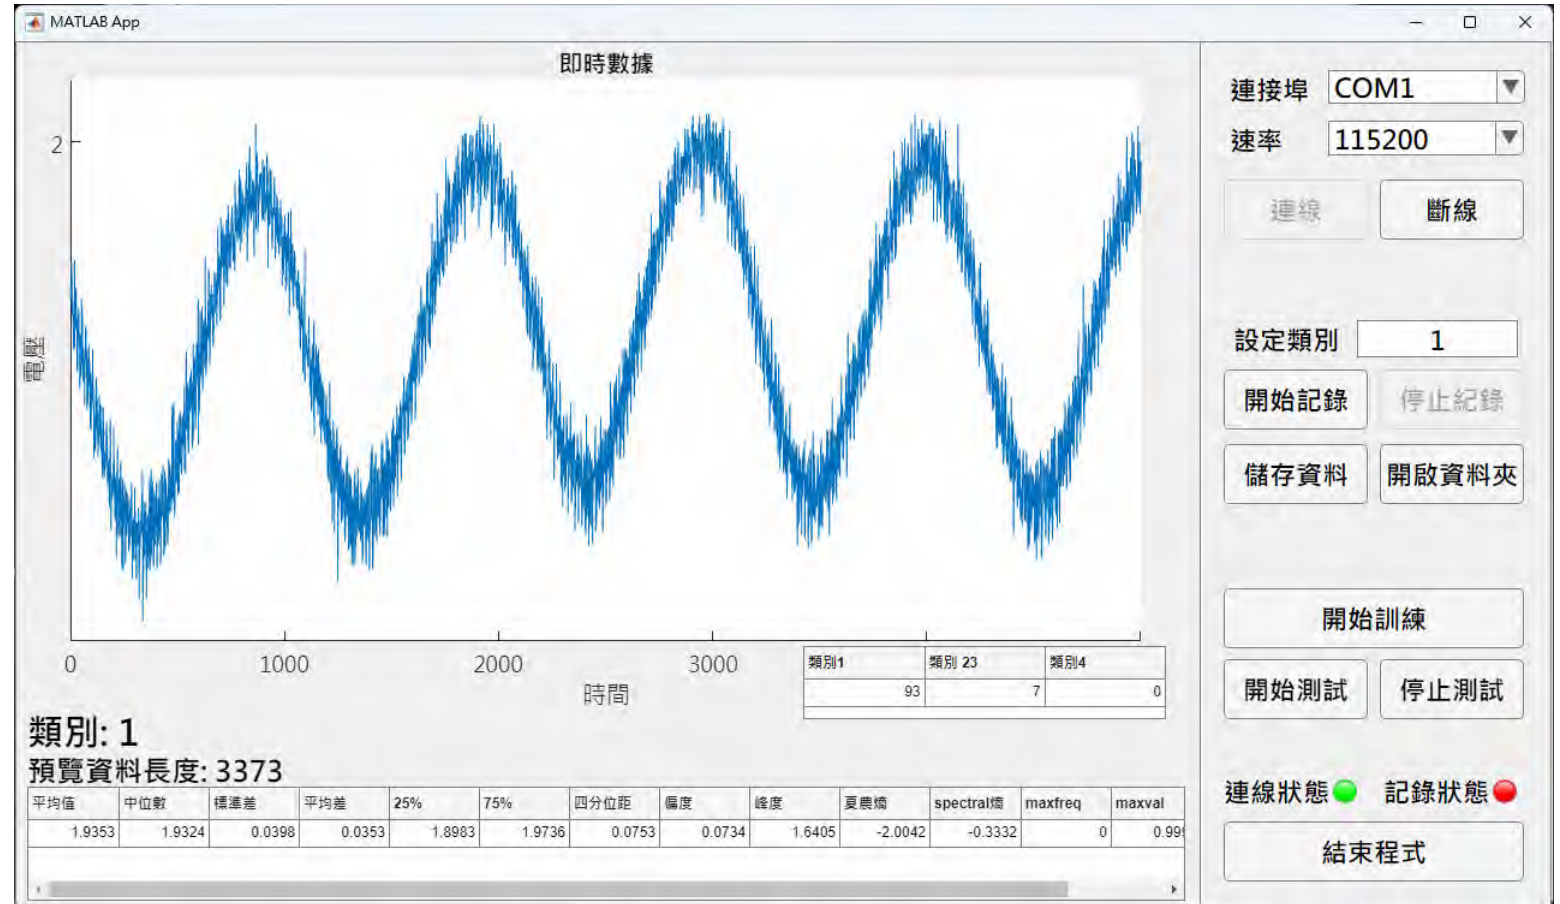


線上實測狀態類別4-偏心狀態

# 設備之故障複雜多樣態區分之解決方案

## 應用的實現:

- AI最大的難題是要有異常,方能進行訓練學習,但設備不故障,無法訓練
- 設備故障了,又無法線上學習
- 本專題實現線上訓練,多重故障的難題



線上訓練



# AI技術研討


預測型AI與應用(設備預知保養,異常偵測,節能與最佳化)  
(第二堂課)

5G AIoT 推動辦公室

王朝民

2026年03月24日





## (應用範例六)

# 關鍵儀控設備可用壽命預測AI

113年國家品質玉山獎最佳產品

113年國家品質玉山獎全國首獎

114年國家品質玉山獎最佳產品

# 本案特點

## (1)三階段:

1. 獨立式電源供應器壽命預測 (已完成)
2. 卡片式電源供應器壽命預測 (已完成)
3. DCS控制器 或模組 壽命預測 (建置中)

## (2) 關鍵儀控設備壽命預測的實現

(3)取樣頻率500K/s,每秒鐘讀入50萬筆

(4)暫態響應特性訓練,特性區間200ms,取樣500ms,完成判別時間5 秒之內完成





# 電源系統可用壽命預知AI

## 1. 計畫緣由:

因應112年7月台中廠電源供應器故障斷氣事件，中油公司承諾經濟部王部長使用AI預知電源系統的故障。

## 2. AI的建置:

天然氣事業部開立採購案，推辦篩選3家學術單位，建置AI系統。

## 3. 建置方法:

(1)理論模型：請三學術單位用穩態響應、暫態響應、ESR(電源內阻)進行運算。

(2)AI數據模型：

學術單位一(電機): 多層神經元類神經網路

學術單位二(航太): LR Modelling+PHM

學術單位三(機械): LSTM+Seq2sqe

## 4. 結果:

學術單位一(電機): 5秒測得，每秒運算50萬筆

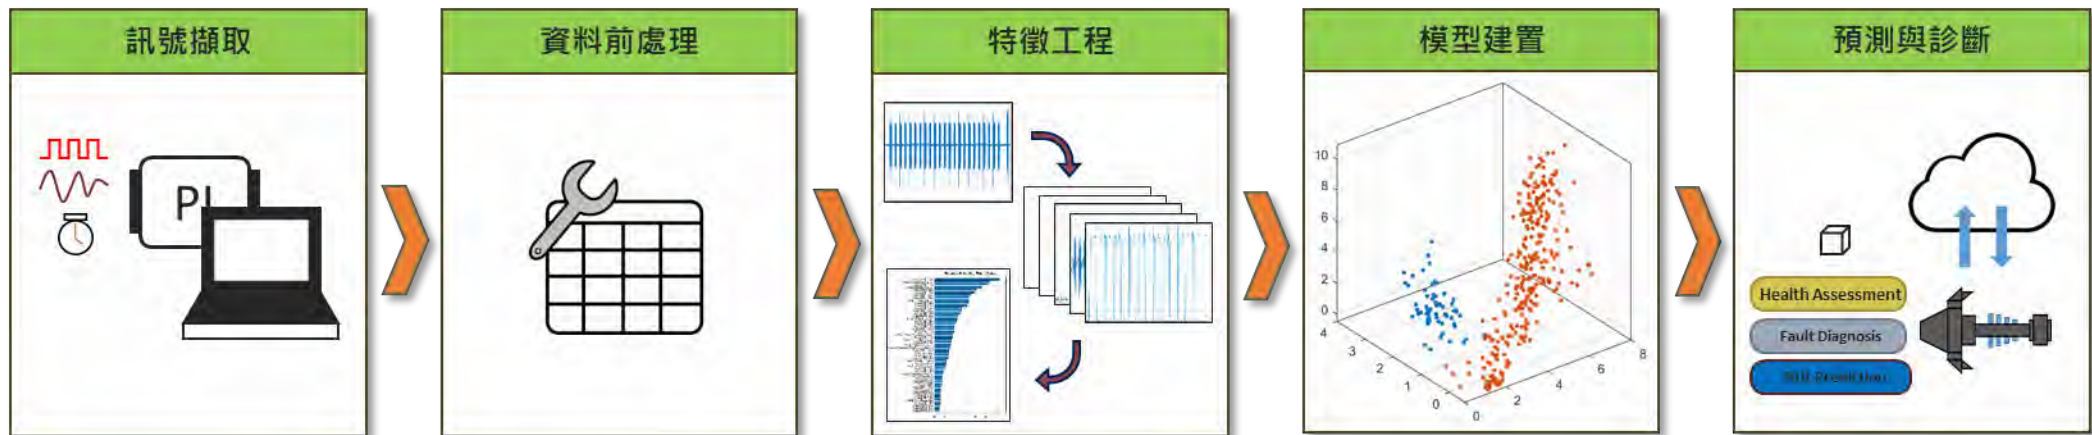
學術單位二(航太): 2分鐘(120秒)測得，穩態分

學術單位三(機械): 未簽約



# (4-1) 使用**健康指標**,開機後電流等變數(專案計畫一)

## 關鍵性電源供應器故障預測之 AI 技術方塊圖



研究方法

# 測試平台說明

以中油提供之 DCS 模板作為研究平台。該模板由二組 24V 電源供應器作為冗餘設計，為 DeltaV DCS 提供電源。

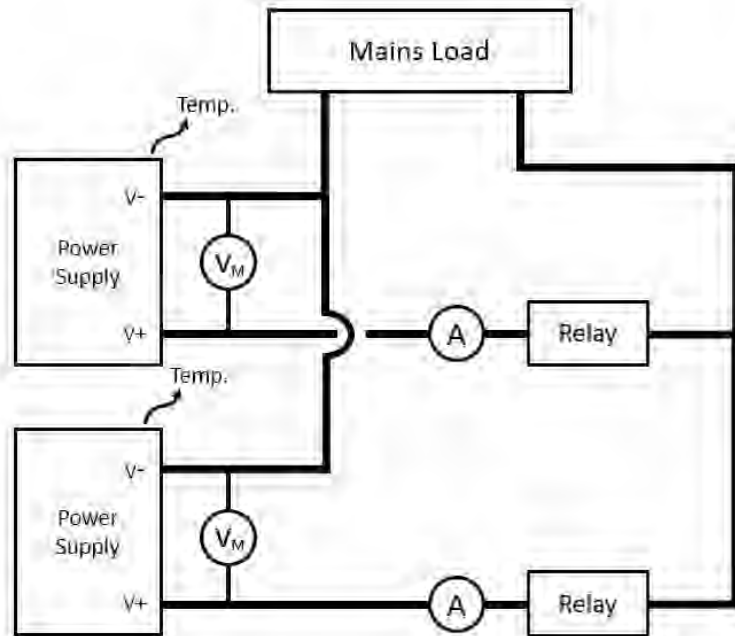


DeltaV DCS 訓練模板



## (A)資料收集



本案透過額外設置感測器，擷取電源供應器各項訊號。



訊號擷取對應感測器

訊號類型	感測器
輸出電流	霍爾感測器
輸出電壓	電壓訊號隔離器
機殼溫度	貼片式熱電偶


## (B)資料清洗(前處理)




去除異常與非穩定資料 (a)離群值 (b)啟動升溫

## (B)資料清洗(前處理)

輸出電壓	輸出電流
24V	40A



輸出電壓	輸出電流
24V	20A




不同額定電流的電源供應器輸出差異



## (C)訊號分析

- 右圖顯示全新電源供應器 (New) 與3個使用 12 年的電源供應器 (Old\_S1, Old\_S2, Old\_S3) 的溫度原始訊號。
  - 四個電源供應器的工作溫度都分布在相近的區間，溫差不超過3度。而 Old\_S2 的溫度較其他三者低溫，推測為該電源供應器的個體差異。
- 不使用溫度訊號建立模型。



各電源供應器溫度表現

# (D) 特徵提取


## 特徵提取

- 分析標的由 1 個全新電源供應器 (New) 與 3 個使用 12 年的電源供應器 (Old\_S1, Old\_S2, Old\_S3) 組成。
- 為標的電壓、電流與溫度提取右列 7 種時域特徵，總計 14 項特徵。

提取特徵列表

No.	特徵	公式
1	Standard deviation	$SD = \sqrt{\frac{\sum_{i=1}^n  x_i - \mu ^2}{n - 1}}$
2	Mean value	$\bar{M} = \frac{1}{n} \sum  x_i $
3	Max value	$x_M = \max(x)$
4	Min value	$x_m = \min(x)$
5	Peak to peak	$x_{ptp} = \max(x_i) - \min(x_i)$
6	Kurtosis	$x_{kurt} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right]^2}$
7	Skewness	$x_{skew} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2\right]^{\frac{3}{2}}}$

# (D) 特徵提取





特徵顯著性評分

No.	特徵
1	輸出電流平均值 ( Mean_C )
2	輸出電流最小值 (Min_C)
3	輸出電流最大值 (Max_C)
4	輸出電壓標準差 (Std_V)

特徵子集組成




# (E) 測試結果(定性) -





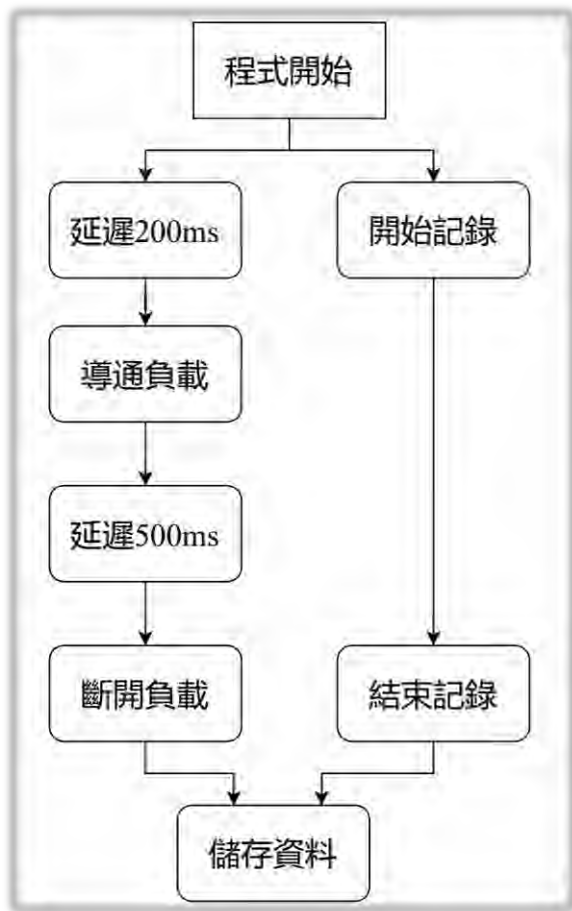
顯著特徵

# (E) 測試結果(定量) – 健康指標



## (4-2) 使用機械學習(專案計畫二)




示波器開始記錄200ms為電源供應器空載時漣波，之後控制固態繼電器導通，將其與水泥電阻連接，此時電源供應器為滿載狀態，滿載持續500ms後斷開負載直到1000ms記錄結束。






## (2.4-2) 使用機械學習(專案計畫二)

使用暫態和穩態特性進行機械學習。




空載穩態





空載暫態

## 使用暫態和穩態特性進行機械學習。

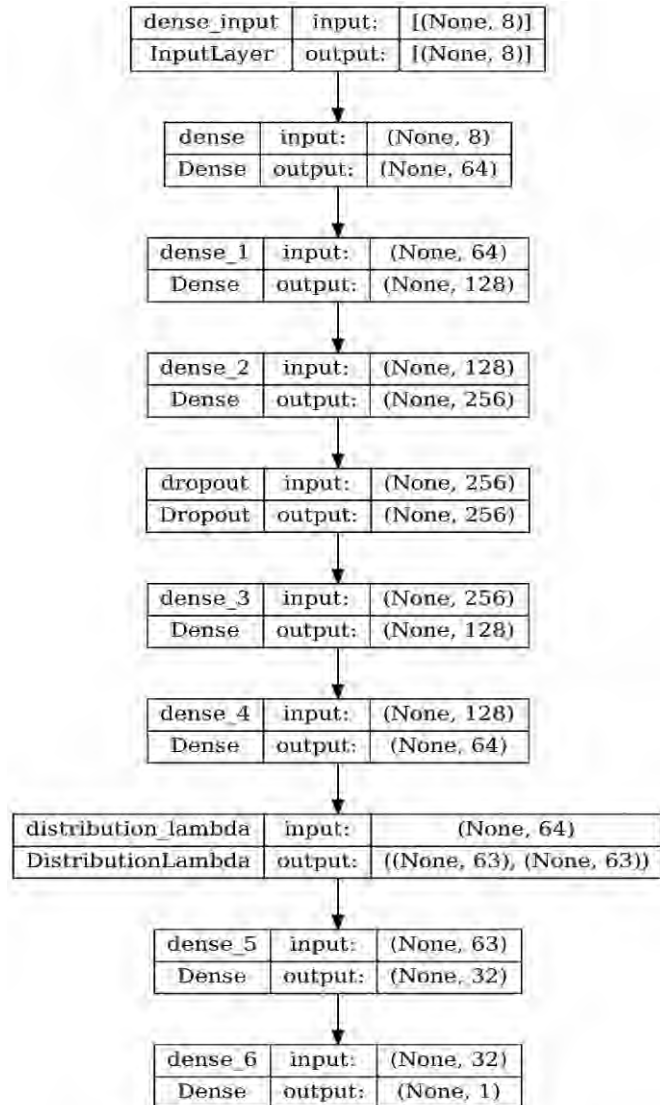


滿載穩態



通電和斷電瞬間的暫態

# 漣波資料分佈(穩態)

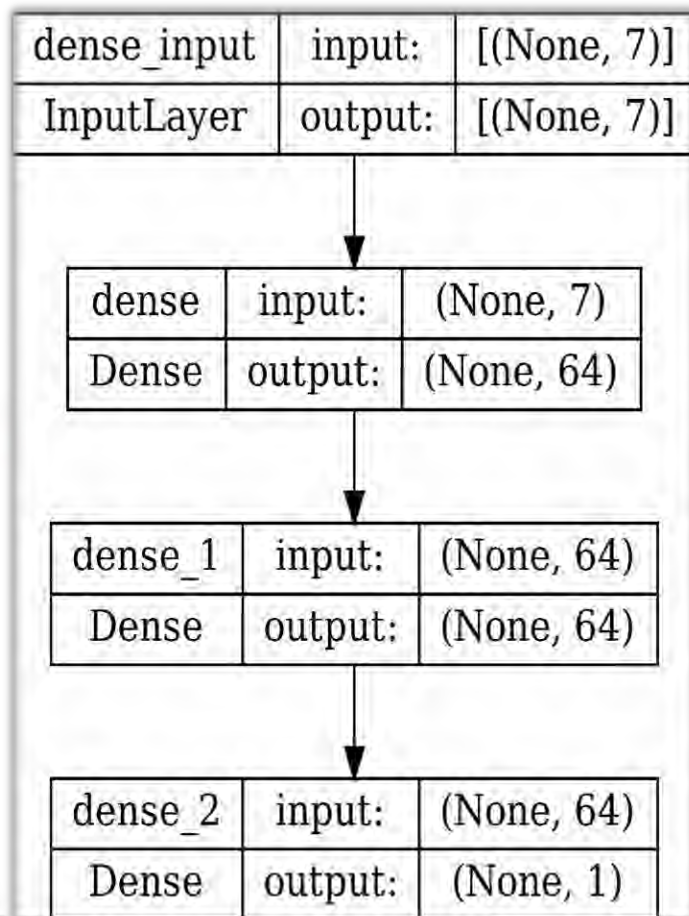



將穩態漣波資料加入回歸模型進行訓練。經過多次的模型參數調整和實驗，我們確定了最適合的模型架構。我們所選擇的模型包括1層輸入層、1層輸出層、8層隱藏層。其中輸入層的維度為8，對應著特徵的數量；輸出層為單一維度的數字，代表著我們想要預測的壽命結果。

在隱藏層方面，我們採用了7層的全連接層，這些層次能夠有效地處理特徵之間的複雜關係。此外，我們還添加了1層機率分佈層，以更好地處理數據的不確定性和變異性。





# 漣波資料分佈(暫態)





初步嘗試利用統計特徵來探測電源供應器的壽命可能性，通過對每筆樣本計算出**7種統計特徵**，包含平均值、標準差、最小值、第一四分位數、第二四分位數、第三四分位數、最大值，我們觀察到6號(綠色)電源供應器的電壓起伏較大，這可能意味著其壽命相對較低。

# 使用電源供應器暫態資料預測壽命-訓練過程



在訓練過程中，我們將epoch設定為1000，並使用RMSprop做為最佳化器。經過訓練，我們得到了以下結果：loss為0.55、平均絕對誤差（MAE）為0.5370、均方誤差（MSE）為0.5500，每次epoch的訓練時間為155毫秒，每次step的訓練時間為5毫秒

# 使用電源供應器暫態資料預測壽命-訓練結果



我們的回歸模型的預測結果整體上與正確答案相當接近，這表明我們的模型在大多數情況下能夠有效的捕捉到漣波資料的特徵並進行準確的預測。



## 關鍵性設備：電源供應器AI剩餘壽命預估(1/3)



大林廠RFCC電腦室，有數量極多的DeltaV DCS硬體

優點：避免維修不足及過度維修



檢測用基板，如上圖的電源供應器(兩組複聯)  
同時發生故障，會造成工場停爐重大損失

## 關鍵性設備：電源供應器AI剩餘壽命預估(2/3)

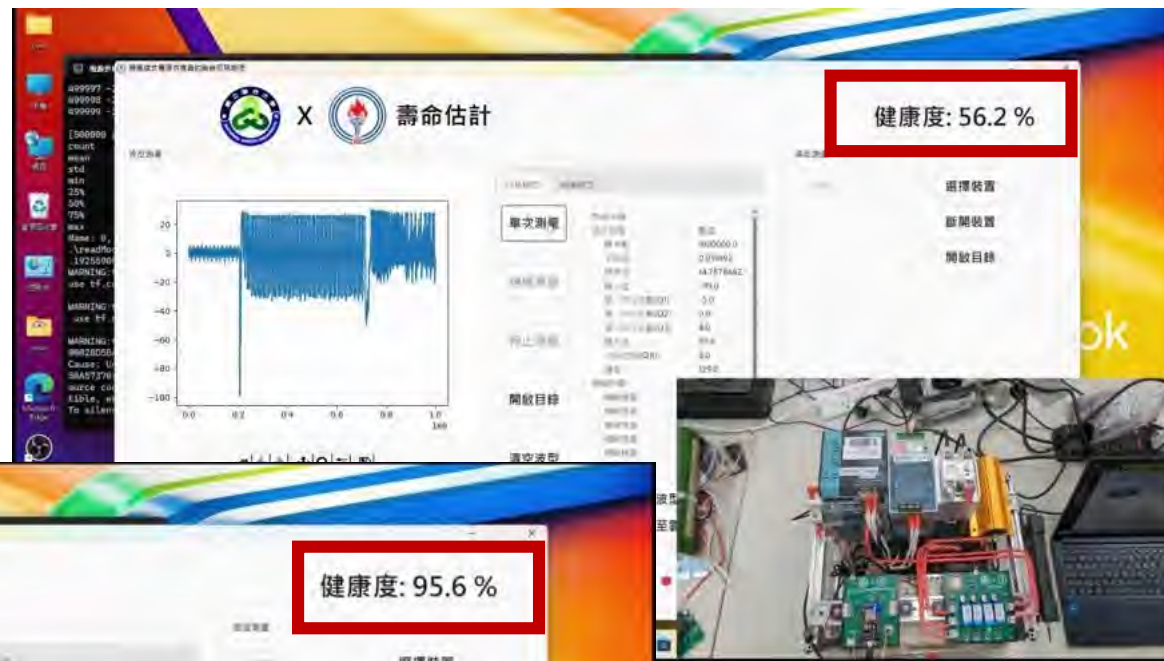
The screenshot displays a software application window titled "壽命估計" (Life Estimation). The interface includes a waveform graph on the left showing a signal fluctuating around zero with two sharp negative spikes. In the center, there is a table with columns for "項目名稱" (Item Name), "單位" (Unit), and "數值" (Value). The right side of the window features a "健康度: 10.4%" (Health: 10.4%) indicator, which is highlighted with a red box. Below the graph, there are control buttons for "單次測量" (Single Measurement), "開啟目錄" (Open Directory), and "清空波形" (Clear Waveform). At the bottom, there are status indicators for "模型已載入" (Model loaded), "已連線至雲端" (Connected to cloud), "伺服器主機未設定" (Server host not set), and "登入帳號未設定" (Login account not set). A red box highlights the "健康度: 10.4%" text.

預測出健康度後，會顯示在程式右上角

DeltaV DCS電源供應器狀況，會在幾秒內由AI檢測完成，



# 關鍵性設備：電源供應器AI剩餘壽命預估(3/3)





# 天然氣台中廠ABB DCS壽命預測(第一代)已落地使用

編號	電源供應器型號	規格	使用年份	量測健康度(%)	備註
1	SD833	24V 10A	使用7年	53.13%	
2	SD833	24V 10A	全新	93.89%	備品
3	SD833	24V 10A	全新	94.43%	備品
4	SD833	24V 10A	全新	94.25%	備品
5	SD833	24V 10A	全新	93.96%	備品
6	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
7	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
8	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
9	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
10	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
11	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
12	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
13	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
14	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢
15	SD822	24V 5A	使用15年	<20%	因健康度不佳，已於114/06報廢

- 114年陸續共計量測15台電源供應器。
- 其中10台因量測健康度<20%，為維持設備正常操作，已將其報廢不再使用。



## 2. 卡片式電源供應器壽命預測

電源供應器電壓與電流關係

編號	型號	3.3V 電流	3.4V 電流	5V 電流	5.1V 電流	12V 電流
1	KJ1501X1-BC1	2		2		4.5
2	KJ1501X1-BC1	2		2		4.5
3	KJ1501X1-BC1	2		2		4.5
4	KJ1501X1-BC1	2		2		4.5
5	KJ1501X1-BC2	2		2		4.5
6	KJ1501X1-BC2	2		2		4.5
7	KJ1501X1-BC2	2		2		4.5
8	KJ1501X1-BC3		2		2	8
9	KJ1501X1-BC3		2		2	8
10	KJ1501X1-BC3		2		2	8
11	KJ1501X1-BC3		2		2	8
12	KJ1501X1-BC3		2		2	8



## 2. 卡片式電源供應器壽命預測




圖 3 電源供應器內部電源接腳



(a) PCB 板 3D 模型



(b) 實體測量示意圖

圖 4 電源供應器量測板



## 2. 卡片式電源供應器壽命預測

將第一個運算放大器輸入訊號透過  $1\mu\text{F}$  電容做交流耦合，後連接一  $10\text{k}\Omega$  電阻做為輸入電阻；輸出端連接  $100\text{pF}$  電容濾波，並連接  $100\text{k}\Omega$  電阻做負回授到輸入負極。而第二個運算放大器仿照前者串聯，則可得到一放大 100 倍正向放大器。電路如圖 6 所示。

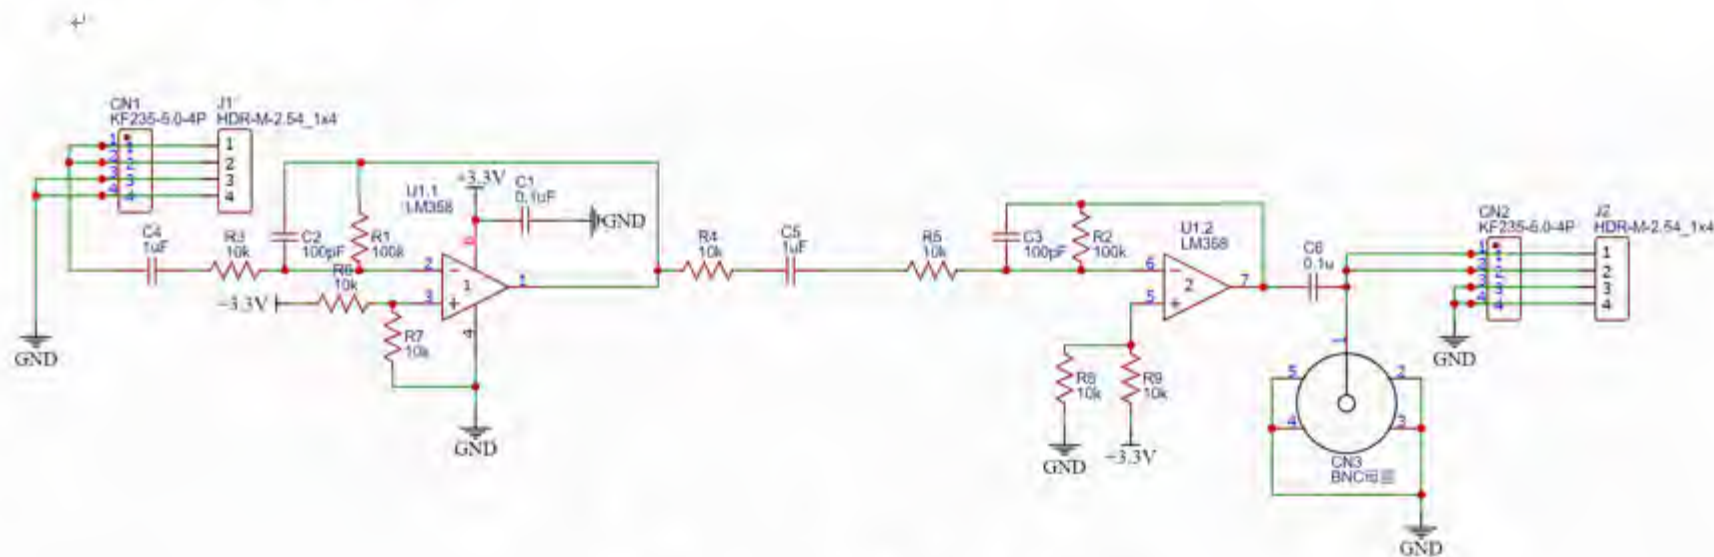


圖 6 整體運算大器電路


## 2. 卡片式電源供應器壽命預測

為了觀察各種狀態的波型變化，我們設計多執行續程式，該程式能夠同時控制固態繼電器與示波器，首先示波器開始記錄 200ms 為電源供應器空載時漣波，之後控制固態繼電器導通，將其與水泥電阻連接，此時電源供應器為滿載狀態，滿載持續 500 ms 後斷開負載直到 1000 ms 記錄結束。流程圖如圖 12 所示。




圖 12 暫態漣波記錄流程圖。


## 2. 卡片式電源供應器壽命預測



(a) BC1 波型



(b) BC2 波型



(c) BC3 波型

圖 13 不同型號單次取樣波型



## 2. 卡片式電源供應器壽命預測




圖 15 通電時暫態。




圖 16 滿載時穩態。




圖 17 斷電時暫態。

## 2. 卡片式電源供應器壽命預測

表 3 電源供應器壽命對照表

編號	型號	日期	設定壽命
1	KJ1501X1-BC1	2002-01-25	0
2	KJ1501X1-BC1	2002-01-25	0
3	KJ1501X1-BC1	2002-03-04	0.58
4	KJ1501X1-BC1	2002-05-01	1.47
5	KJ1501X1-BC2	2004-01-29	11.24
6	KJ1501X1-BC2	2004-02-17	11.53
7	KJ1501X1-BC2	2008-07-07	36.08
8	KJ1501X1-BC3	2009-10-07	43.08
9	KJ1501X1-BC3	2011-07-13	52.94
10	KJ1501X1-BC3	2013-03-09	62.21
11	KJ1501X1-BC3	2013-03-12	62.25
12	KJ1501X1-BC3(全新)	2019-12-10	100

## 2. 卡片式電源供應器壽命預測




圖 30 經過孤立森林演算法後的標準差



## 2. 卡片式電源供應器壽命預測

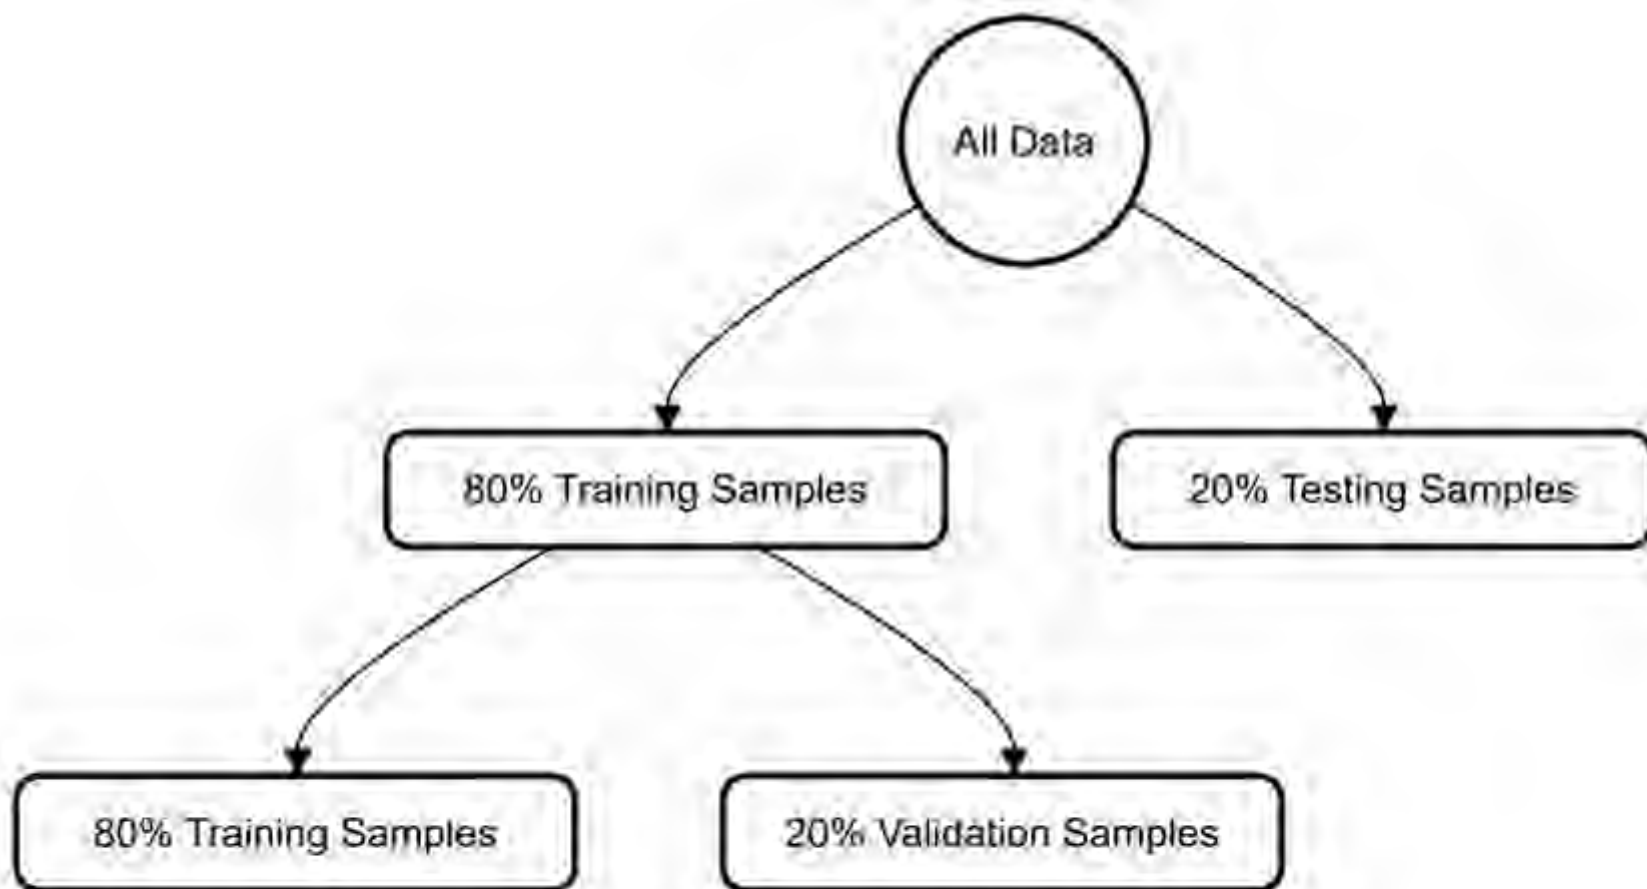


圖 36 資料分割示意圖。

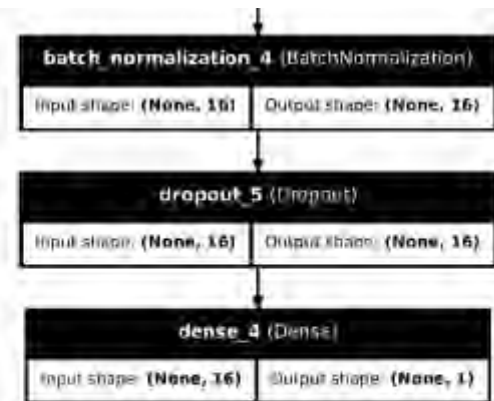
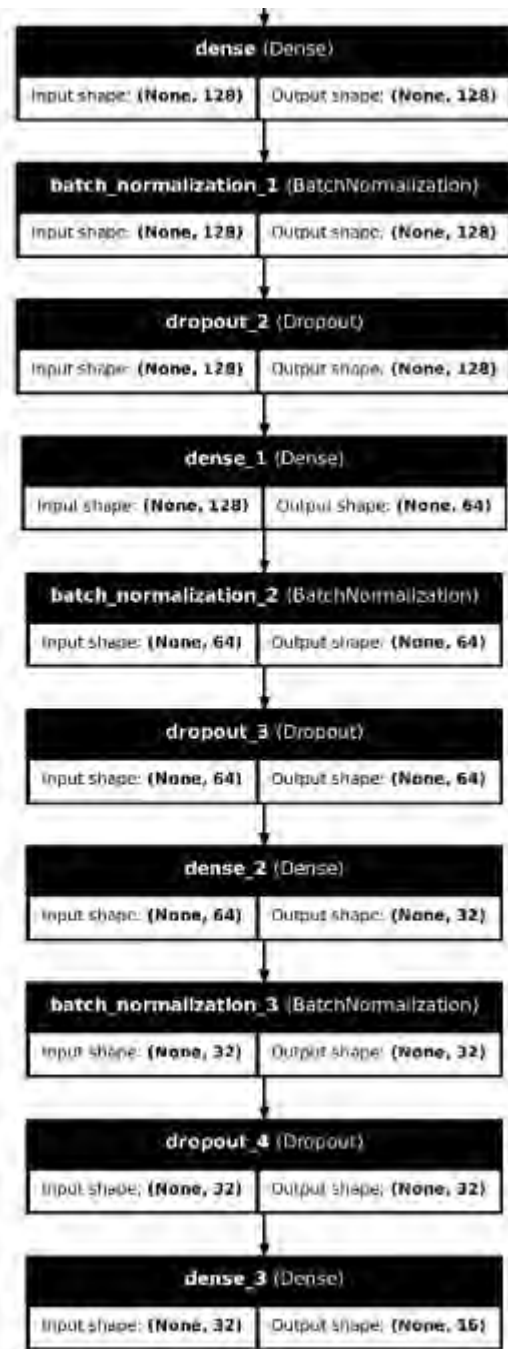
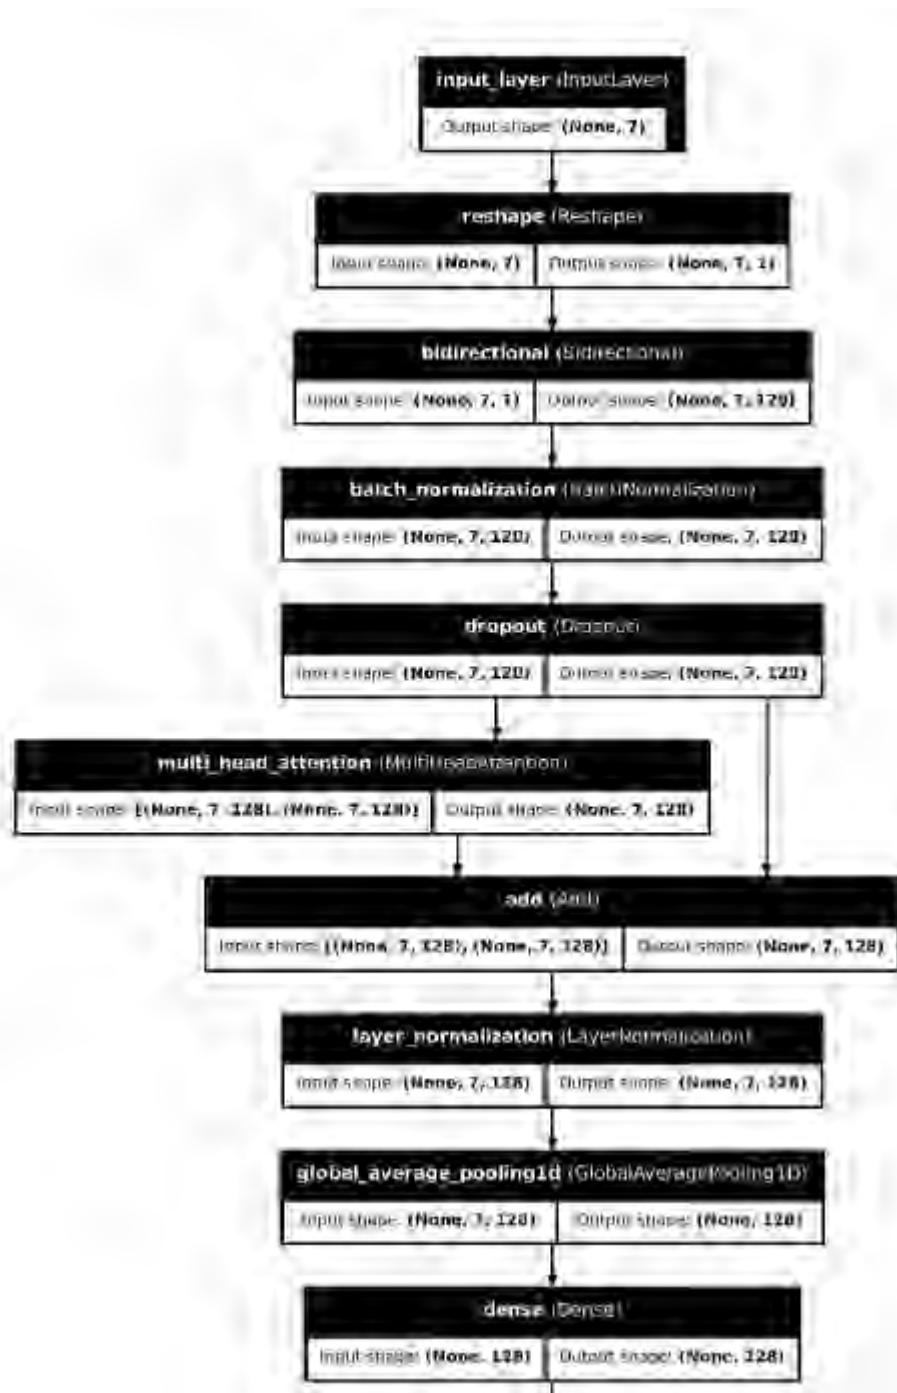


圖 37 模型架構

## 2. 卡片式電源供應器壽命預測




圖 38 訓練過程 Mean Absolute Error



## 2. 卡片式電源供應器壽命預測




圖 40 預測結果分布圖

## 1.1、快速AI壽命預測系統-應用於工控電腦DCS電子模組





## 1.2、公司各單位，有數量極多的DCS模組硬體



公司各單位，有數量極多的DCS模組硬體



將卡片拔出,插入測試機板即可得知卡片的可用壽命




## 1.3、拆線式與卡片抽取式



上圖為第一代(2024年),適用於外接式電源,檢測時須拆線

上圖為第二代(2025年),適用於模組,檢測時無須拆線



(應用範例七)

## 使用PI系統進行設備之故障預測

RFCC C8002 葉片裂痕預測  
RFCC C1201 觸媒粉阻塞預測

總工程師室儀控轉機中心 + 煉製研究所

# 目的

- 以 PI 系統資料庫結合預測與健康管理 (Prognostics and Health Management, PHM) 技術**建立 AI 預兆診斷與保養系統**。
- 以 PI 系統資料庫之相關訊號**搭配工場之維修保養、零件更換等紀錄**作為建置 AI 智慧預兆診斷與保養系統之資料來源。
- 結合 PI 系統資料庫與 PHM 技術建置健康評估與故障診斷模型根據**維修工單紀錄**可針對設備健康狀態**提出警示與建議**。
- 以**壓縮機、膨脹式渦輪機與軸承溫度異常**為研究標的。



# 研究方法與步驟

以PHM為開發基礎，藉由PI系統擷取設備數據，依序對資料進行前處理、**特徵提取、特徵降維與模型建置**，最後使用模型進行預測與診斷。

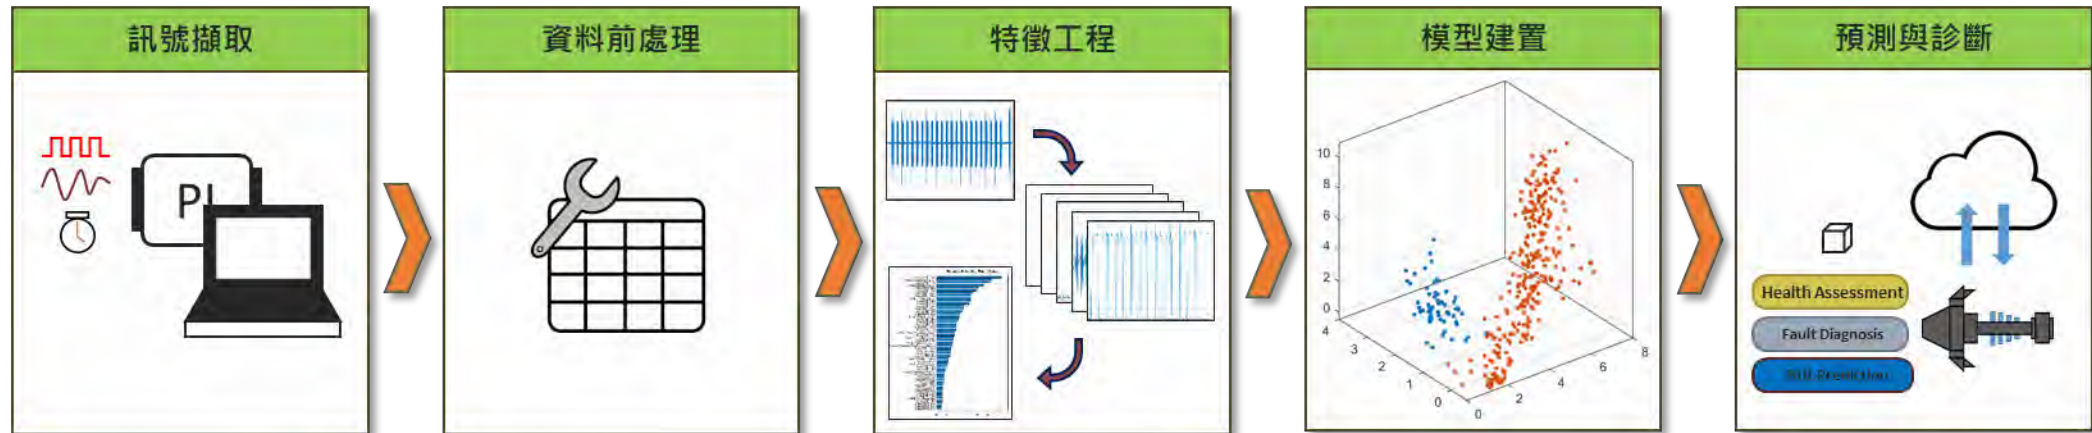


圖1 研究方法

## (7.1)大林廠GHDS 葉輪裂開預測

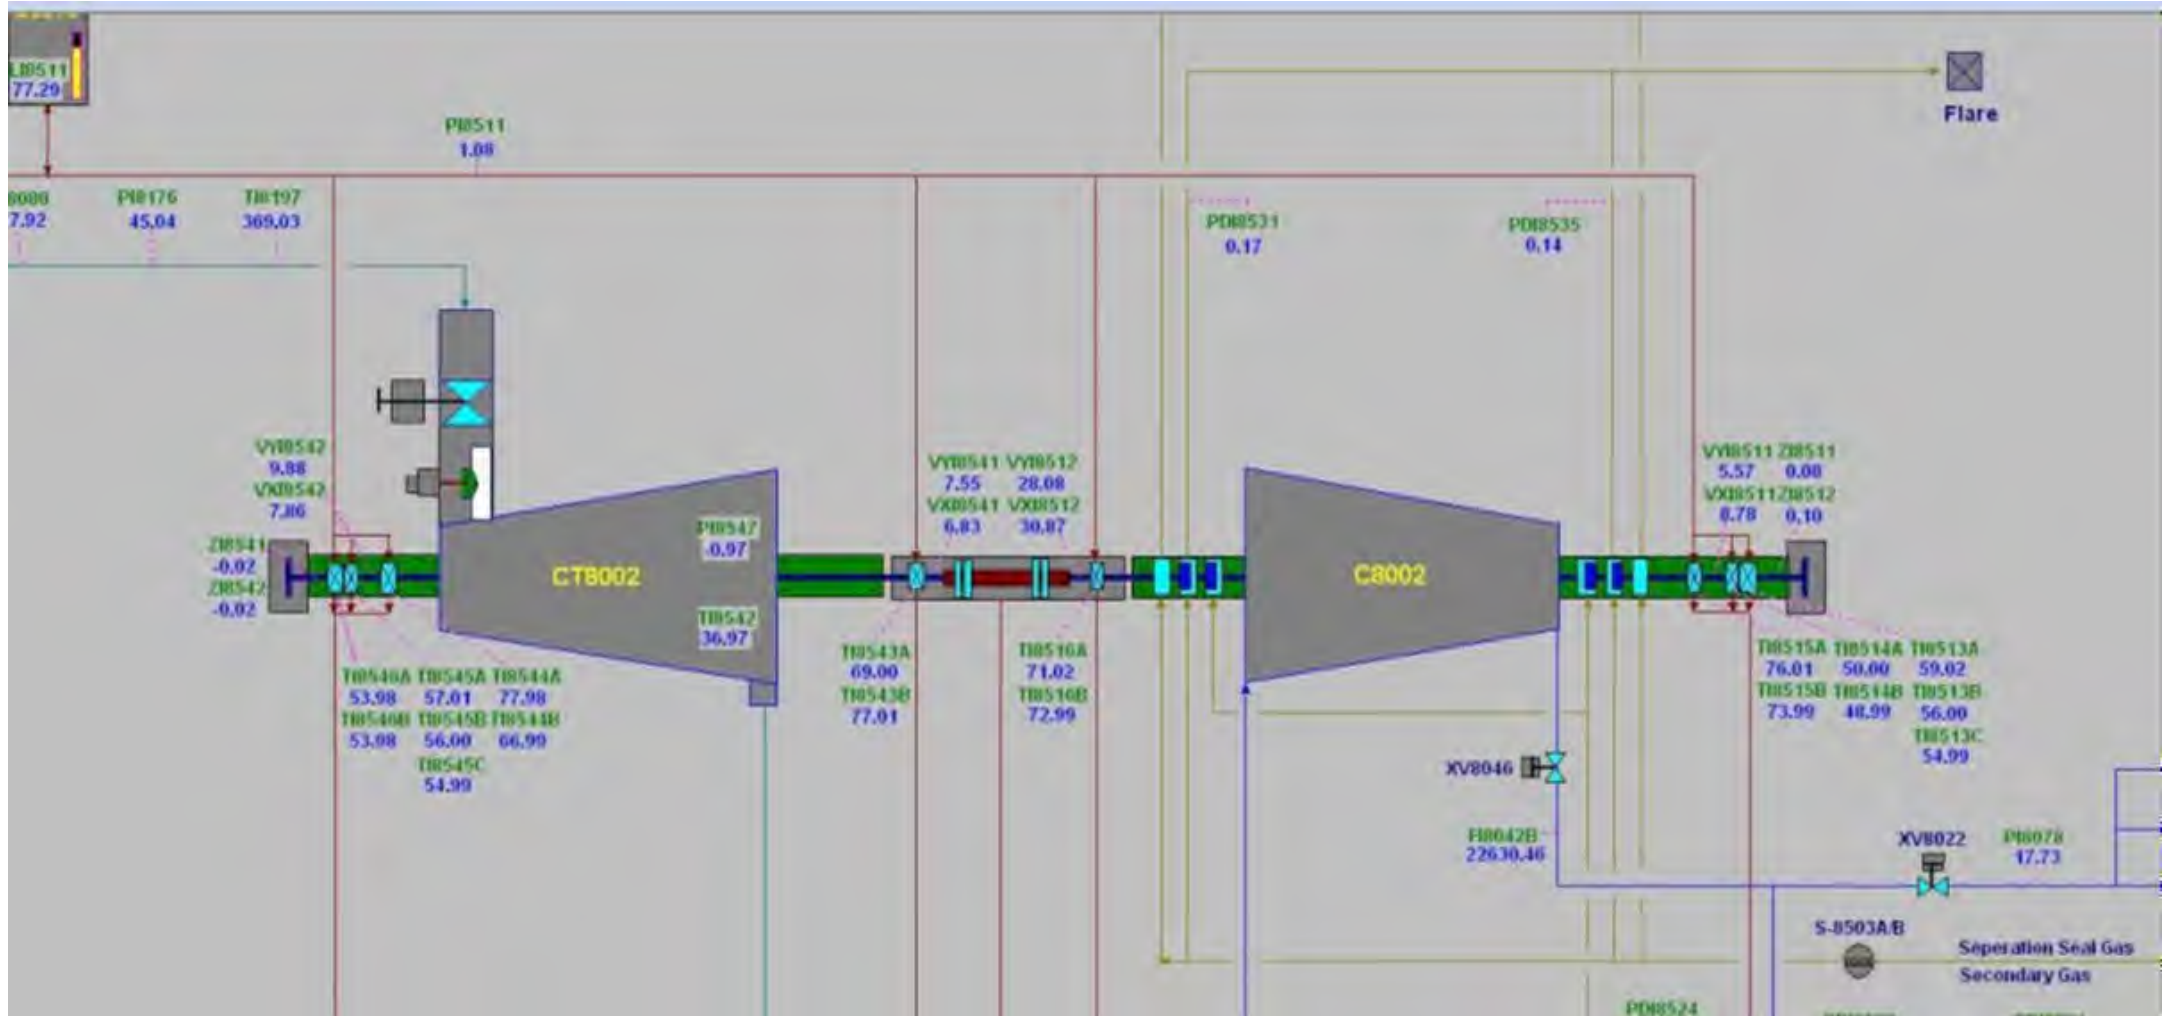
### 轉動機械故障AI預測 大林廠GHDS壓縮機C8002



轉子葉輪斷裂(2019)

- 2015年大修與2019年大修，GHDS C-8002拆下時都發現轉子葉輪裂開。
- 使用2015和2019的PI歷史資料，經過特徵提取與迴歸AI運算，可以得到目前葉輪的狀況

# C8002流程






# GHDS 工場蒐集PI訊號編號

軸承溫度	流體溫度	管線壓力	壓差	流量
TI8513 A/B/C	TI8542 A	PI8077	PDI8521 A	FI8042 B
TI8514 A/B	TI8562 A	PI8078	PDI8523 A	FI8080
TI8515 A/B		PI8176	PDI8524 A	FI8086
TI8516 A/B		PI8511 A	PDI8531 A	
TI8543 A/B		PI8547 A	PDI8535 A	
TI8544 A/B				
TI8545 A/B/C				
TI8546 A/B				

分析的PI訊號編號

# 數據標記

- 2015/12/16 – 2016/03/26:  
標記為正常狀態數據
- 2015/02/14 – 2015/08/26:  
標記為異常數據1
- 2018/08/13 – 2019/09/05:  
標記為異常數據2



訓練資料標記

# 特徵提取與篩選

對蒐集的訊號提取時域特徵，最終特徵矩陣由175個向量組成


特徵	公式	說明
標準差 Standard deviation	$SD = \sqrt{\frac{\sum_{i=1}^n  x_i - \mu ^2}{n - 1}}$	描述機率分佈相對於其均值的分散程度
均方根 Root mean square	$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$	表示整體訊號能量
峰對峰值 Peak to peak	$x_{ptp} = 2x_p$	波形的最大正振幅和最大負振幅之間的差值
峰度 Kurtosis	$x_{kurt} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left[ \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^2}$	描述機率分佈峰態，用於測量訊號的脈衝性
偏度 Skewness	$x_{skew} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[ \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{\frac{3}{2}}}$	描述機率分佈的不對稱性

提取特徵列表




# 費雪判別分析

- (a)表示藉由費雪判別分析計算出來的影響力評價。
- (b)表示以肘部法則決定的最佳特徵子集向量總數。



(a)



(b)

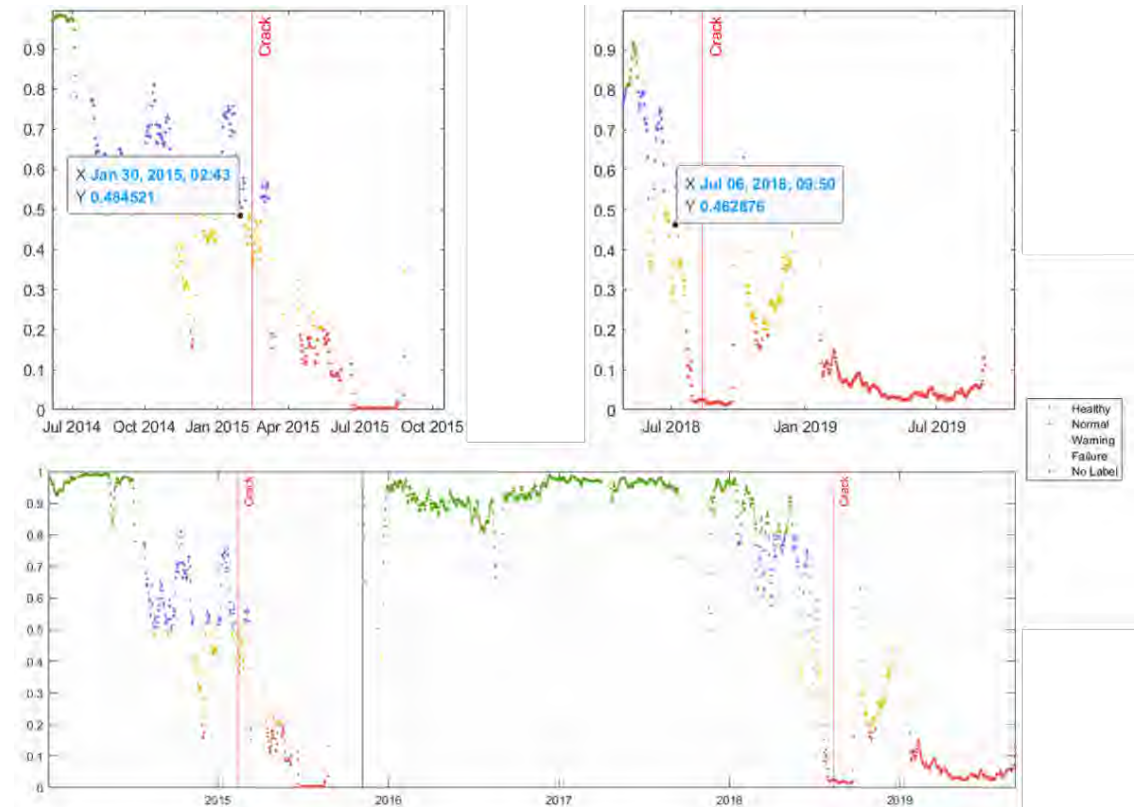
特徵評價 (a)累積95%影響力特徵 (b)決定最佳特徵數量

# 模型性能評估方法

- 調整後R平方(Adjusted R squared) :  
預測變數可以解釋依變數變異的百分比。
- 10折交叉驗證(10-Fold Cross-Validation) :  
將數據拆分為 10 組，每次取一組數據作為測試資料，平均 10 次驗證結果作評估。
- 混淆矩陣(Confusion matrix) :  
用於計算 accuracy 等衡量指標，評估模型優劣。
- 精確率-召回率曲線(Precision-Recall curve) :  
計算不同閾值的精確度和召回率之間的評估結果，曲線下面積(Area Under Curve) 越大表示不論閾值為何，Recall 與 Precision 的平均效果越好。

# 性能衰退評估模組

- 利用正常與二次轉子葉輪異常狀態數據訓練模型
- 用於預測設備性能衰退




性能衰退評估模組預測響應



# 性能衰退評估模組


模型評估結果顯示訓練之模型有效預測  
設備性能衰退



性能衰退評估模組混淆矩陣

Adjusted R <sup>2</sup>	10-fold cv	Confusion matrix	AUC-PR
0.942	98.5%	94.7%	0.987


性能衰退評估模組評估結果



性能衰退評估模組PR曲線

# (7.1)大林廠GHDS C8002葉輪裂開預測

## 轉動機械故障AI預測



訓練資料標記

- 所有AI運算選擇的製程參數都**不用震動訊號**來做。

- 在葉片裂開時期，左側時域訊號看似正常，下圖健康指標已經顯示狀況危急。



性能衰退評估模組預測響應

## (7.2)大林廠RFCC C-1201膨脹機高振動跳車


### 膨脹式渦輪機停機歷程紀錄

時間	說明
2020/01/28 – 2020/02/03	停爐，其他設備檢修
2021/01/19 – 2021/02/04	停爐，其他設備檢修
2021/09/27 – 2021/11/07	大修，膨脹式渦輪機檢修、葉輪液滲檢測
2022/01/17	高振動跳俥
2022/03/03	全台停電
2022/03/13 – 2022/03/29	停爐，其他設備維修
2022/06/06	高振動跳俥
2022/10/06	停爐



# 資料前處理


去除停機數據，僅以高負載作為有效訊號進行分析。



膨脹式渦輪機降載數據標示

# 費雪判別分析

- (a)表示藉由費雪判別分析計算出來的影響力評價。
- (b)表示以肘部法則決定的最佳特徵子集向量總數。



(a)

(b)

特徵評價 (a)費雪判別分析得分 (b)決定最佳特徵數量

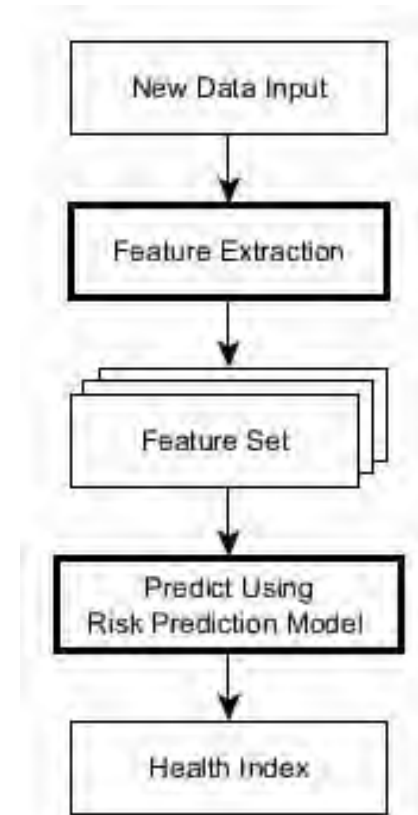
# 跳俾預兆診斷模型

➤ 基於邏輯迴歸(Logistic regression)

➤ 用於渦輪機高振動跳俾發生風險

ID	特徵
1	PI1384_Mean
2	TI1352C_Mean
3	TI1352A_Mean
4	PI1351_Mean
5	PI1352_Mean
6	PI1354_Mean
7	PI1353_Mean
8	PI1122_Entropy
9	TI1353C_Mean

B工場最佳特徵子集組成




預兆診斷模型運作模式



# 跳俾預兆診斷模型

- 模型在跳俾前1個月偵測到高度發生機率存在，能作為風險解除與否的判斷依據
- 以模型預測2022年4月到6月健康狀態，可見3月停爐期間採取的措施並未令設備狀態復歸




預兆診斷模型預測響應

# 模型性能評估結果



預兆診斷模型混淆矩陣



預兆診斷模型ROC曲線

預兆診斷模型評估結果

Adjusted $R^2$	10-fold cv	Confusion matrix	AUC-ROC
0.999	100%	100%	1

# (7.2)大林廠RFCC C-1201膨脹機高振動跳車

## 注意:

(1)使用2022/01/17的事件來訓練

(2)所有AI運算選擇的製程參數都**不用震動訊號**來做

(3)2022/06/06高震動跳車前1個多月,由壓力,溫度等參數經AI計算,預知健康指標低落,隨時會

跳車

表 11 膨脹機預兆診斷模型的因子集組成

ID	特徵
1	PI1384_Mean
2	TI1352C_Mean
3	TI1352A_Mean
4	PI1351_Mean
5	PI1352_Mean
6	PI1354_Mean
7	PI1353_Mean
8	PI1122_Entropy
9	TI1353C_Mean





圖 27 預兆診斷模型預測響應





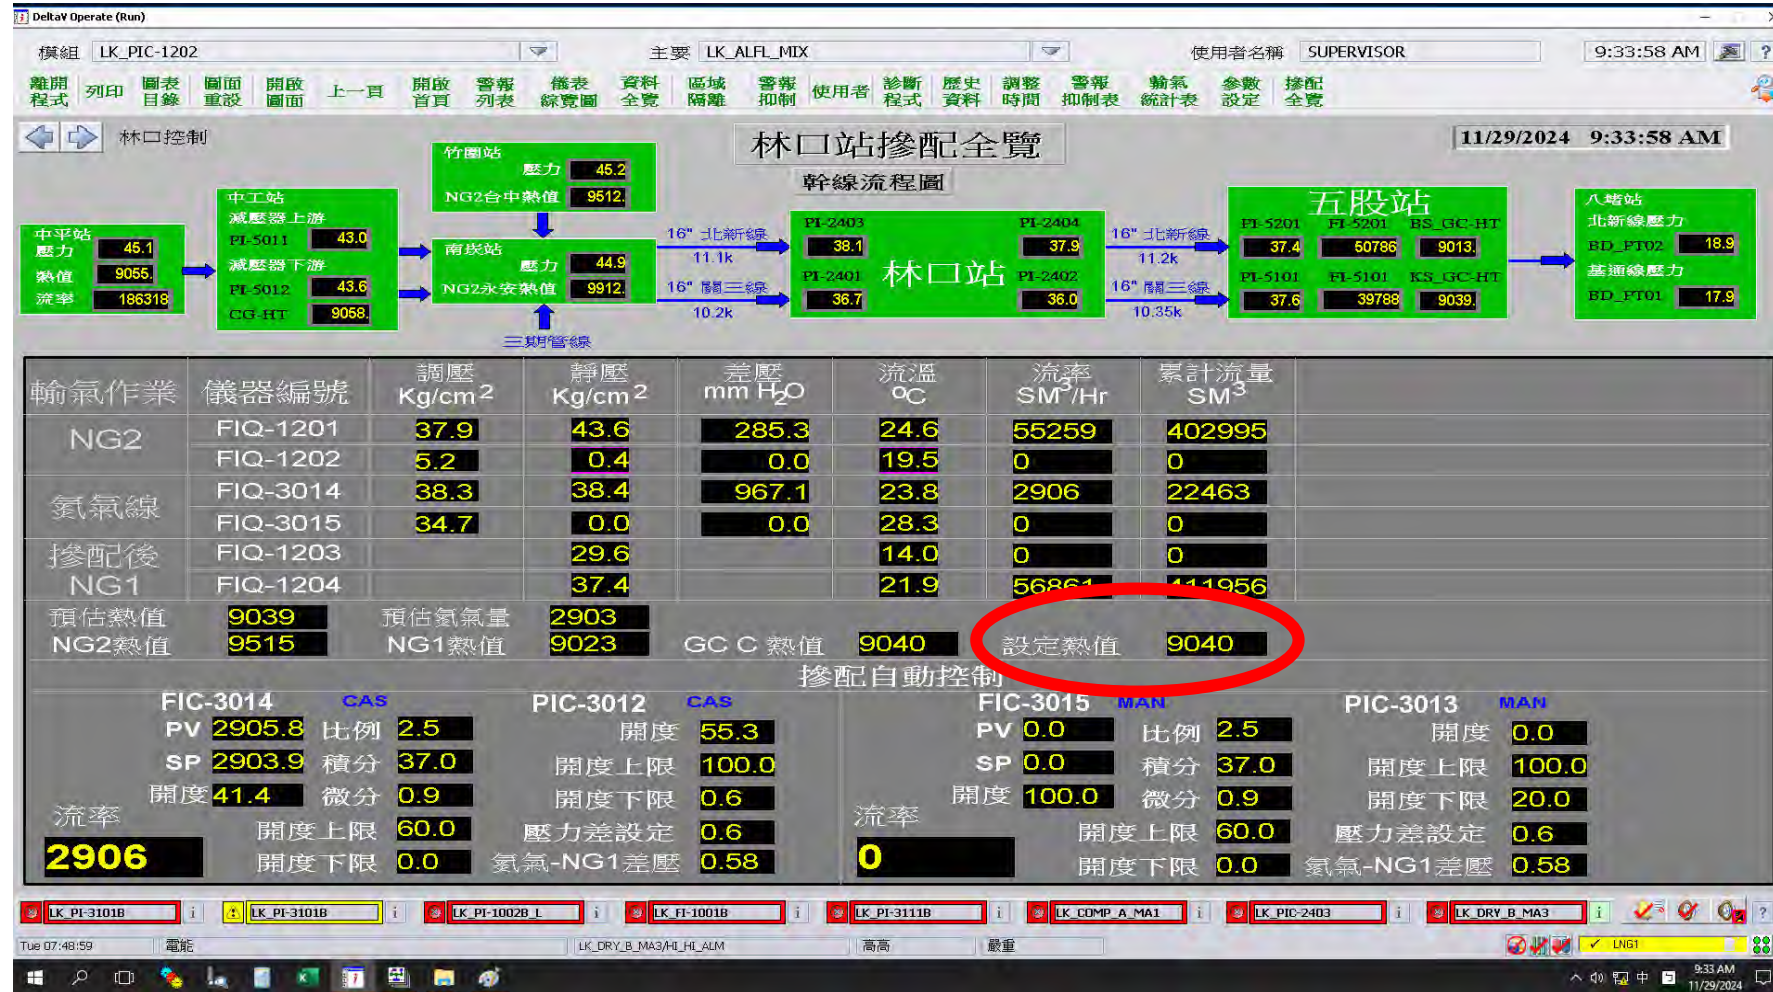
(應用範例八)

## 天然氣熱值摻配最佳化AI

林口配氣中心  
苗栗配氣中心

總工程師室儀控轉機中心 + 天然氣事業部

# 天然氣事業部LNG熱值摻配最佳化AI



1. 熱值規範8800-9200 Kcal ,目前藉由EXCEL計算及經驗調節。

2. 產出熱值由上圖之”設定熱值”設定,越接近8800Kcal越好,但用戶和天氣等因素會拉低熱值。




# AI模型實際試作

(預測房價/千美元)

```
   crim    zn    indus  chas    nox    ...    tax    ptratio    b    lstat    medv
0  0.00632  18.0    2.31    0  0.538    ...  296    15.3  396.90  4.98  24.0
1  0.02731    0.0    7.07    0  0.469    ...  242    17.8  396.96  9.14  21.6
2  0.02729    0.0    7.07    0  0.469    ...  242    17.8  392.83  4.83  34.7
3  0.03237    0.0    2.18    0  0.458    ...  222    18.7  394.63  2.94  33.4
4  0.06905    0.0    2.18    0  0.458    ...  222    18.7  396.90  5.33  36.2
```

```
[5 rows x 14 columns]
(506, 14)
Process finished with exit code 5
```



```
32/102 [=====]
102/102 [=====]
MSE_test: 8.17044911665075
MAE_test: 2.1490171773760927
Process finished with exit code 0
```

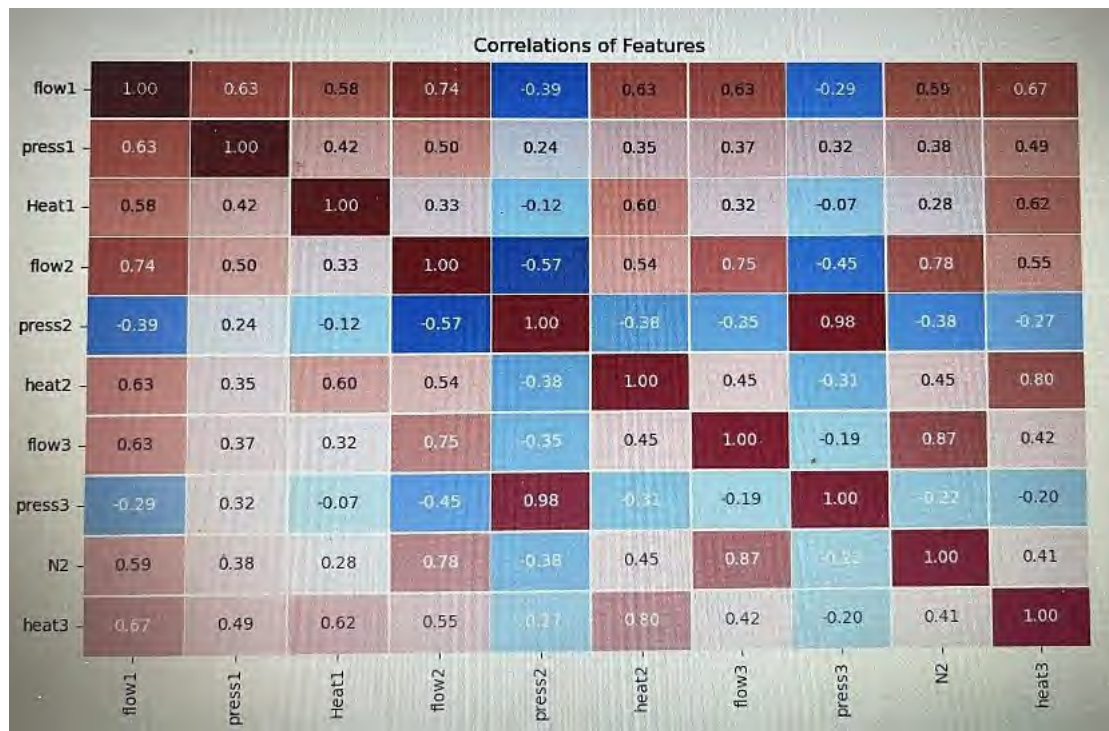
(預測的平均誤差2149美元)

- crim: 人均犯罪率。(輸入)
- zn: 占地面积超过 25000 平方英尺 (英制面积单位, 1 平方英尺  $\approx 0.092903$  平方) 的住宅用地比例。(輸入)
- indus: 每个城镇非零售业务的土地比例。(輸入)
- chas: 是否邻近查尔斯河 (1 是邻近、0 是没有)。(輸入)
- nox: 一氧化氮浓度 (千万分之一)。(輸入)
- rm: 住宅的平均房间数。(輸入)
- age: 1940 年以前建造的自住单位比例。(輸入)
- dis: 到 5 个波士顿就业中心的加权距离。(輸入)
- rad: 到达高速公路的方便性指数。(輸入)
- tax: 每万元的全价值的房屋税。(輸入)
- ptratio: 城镇的师生比。(輸入)
- b: 公式  $1000*(Bk-0.63)**2$  的值, Bk 是城镇的黑人比例。(輸入)
- lstat: 低收入人口的比例。(輸入)
- medv: 自住房屋的中位数价格 (单位是千元美金)。(預測的輸出)

1. 由類似的案例,試作預測波士頓地區房價,共506筆資料,每筆資料14個輸入,使用最簡易的演算法,2層隱藏層。
2. 經實際執行,房價30,000美元,誤差2149元,誤差值7.16%。
3. 波士頓地區房價輸入特徵的相關性(Corr)不高,LNG 熱值摻配的相關性極高,加上各種優化技術,可以非常精準預測,目標值誤差1% 以內。



# 推辦提供10個最常見AI模型,可協助各單位進行數值預測 (使用中林配氣站資料)











中平站與五股站及林口站NG1的熱值與流量相關性非常高,因此非常容易進行AI預測。

```
(1)Linear Regression - Mean Squared Error: 783.5977175265222
(1)Linear Regression - Mean Absolute Error: 18.720121650447396
9106
(2)Decision Tree - Mean Squared Error: 280.4459550343064
(2)Decision Tree - Mean Absolute Error: 6.419785570283331
C:\Users\User\Anaconda3\lib\site-packages\sklearn\ensemble\weight
from numpy.core.umath_tests import inner1d
(3)Random Forest - Mean Squared Error: 144.2286600040535
(3)Random Forest - Mean Absolute Error: 5.490367567195236
(4)SVM - Mean Squared Error: 819.5852784007005
(4)SVM - Mean Absolute Error: 18.189256274845388
(5)KNN - Mean Squared Error: 116.94933076740638
(5)KNN - Mean Absolute Error: 4.521941023676701
(6)Gradient Boosting - Mean Squared Error: 545.4508090779159
(6)Gradient Boosting - Mean Absolute Error: 14.999665617669926
(7)Neural Network - Mean Squared Error: 1386.9073806818067
(7)Neural Network - Mean Absolute Error: 18.036152810511936
(8)Bayesian Ridge - Mean Squared Error: 783.5754647765156
(8)Bayesian Ridge - Mean Absolute Error: 18.720248169911784
(9)XGBoost - Mean Squared Error: 247.93276398404973
(9)XGBoost - Mean Absolute Error: 10.18911252000742
(10)LightGBM - Mean Squared Error: 339.8311191642889
(10)LightGBM - Mean Absolute Error: 11.796993438484796
```

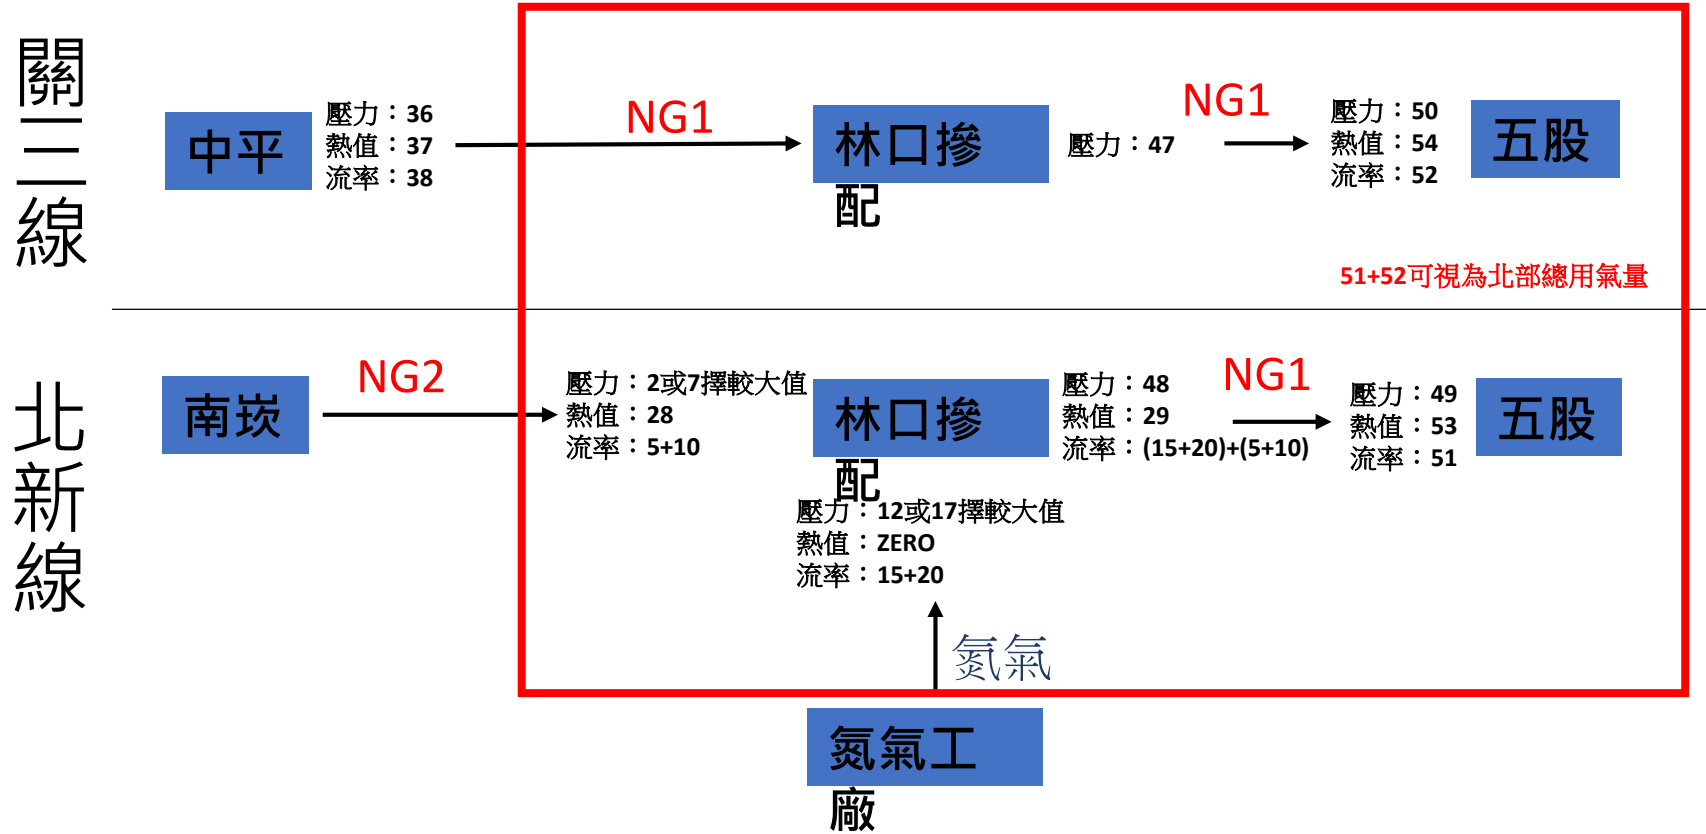
用5.5個月的資料,每5分鐘一筆,36364筆訓練,9106筆用來測試,MAE非常低,準確度都在98%以上。



# 推辦提供10個最常見AI模型,可協助各單位進行數值預測 (使用中林配氣站資料) 以下為各種演算法預測和實際值的差異



# 進階應用



- 以紅色框部分資料為模型建置



# 情境說明(單一點)

## □ 14 個歷史資料特徵值


- 五股的壓熱流: 50, 54, 52, 49, 53, 51
- 林口的壓熱流:, 47, 48, 29, 28, (15+20), (5+10), ((15+20)+(5+10))
- 溫度(23,26) 選小的, 再挑(22,25)

## □ 6個預測資料特徵值


- 五股  $t+p$  使用量(即流熱壓): 50, 54, 52, 49, 53, 51
- 3個建議值
- 林口  $t+1$  建議值: 28, (5+10), (15+20)

現在時間  $t$

輸入/向量序列( $s=60$ , 1 HR前)



輸出/向量( $p=30$ , 30 min後, 與建議值)



時間軸



# 訓練設定與資料

- 訓練設定


- 模型架構：LSTM ( 32 units, ReLU ) + Dropout(0.5) + FC
- 輸入特徵：14 項，timestep = 60
- 輸出維度：9 項
- Loss 函數：MSE；優化器：Adam

- 輸入資料

- 全部資料 5 個月，共150天，每一分鐘一筆資料
- Case 1: 每個月的前面 24 天為訓練資料，最後 6 天為測試資料。(大約)
- Case 2: 前4個月為訓練資料，最後 1 個月為測試資料。

# 30分鐘後北新線五股壓力(欄位 4)


- 平均絕對差異：0.92
- 相對誤差：2.72%
- 表現穩定。





# 1分鐘後北新線NG2熱值建議(欄位 7)

- 平均絕對差異：13.52
- 相對誤差：0.14%  
表現穩定。



# 系統畫面示意圖


- 五股關三線
- 林口關三線
- 五股北新線
- 林口北新線
- 林口 N2
- 林口 NG2

- 五股關三線
- 10分鐘趨勢
- 五股北新線
- 30分鐘趨勢
- 林口建議值
- 60分鐘趨勢

五股關三線壓力歷史



五股關三線熱值歷史



五股關三線流速歷史



五股關三線壓力趨勢預測



五股關三線熱值趨勢預測



五股關三線流速趨勢預測







(應用範例九)

## 碳封存

總工程師室儀控轉機中心 + 探採研究所



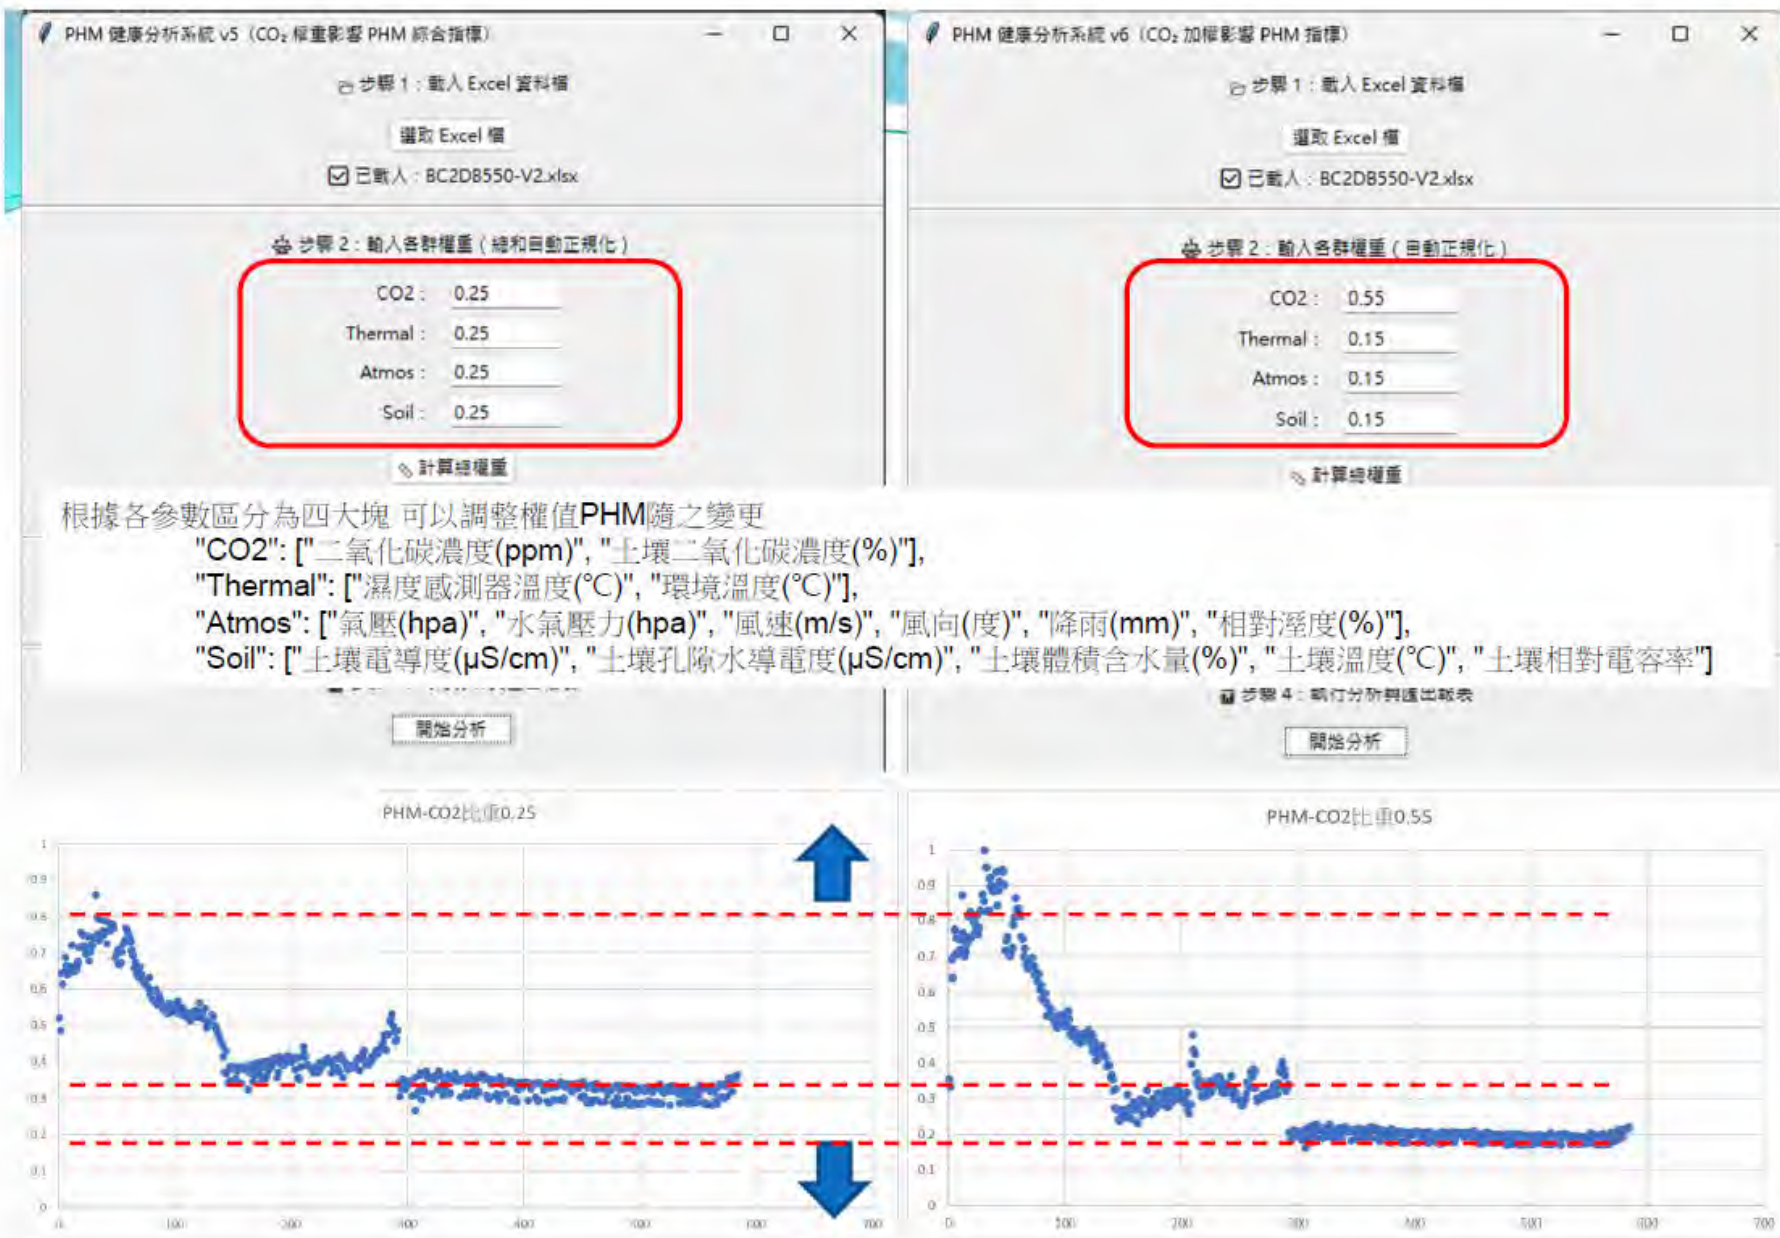
# 碳封存CO2預測AI



環境大氣


土壤氣

# 碳封存CO2預測AI






# 特徵提取



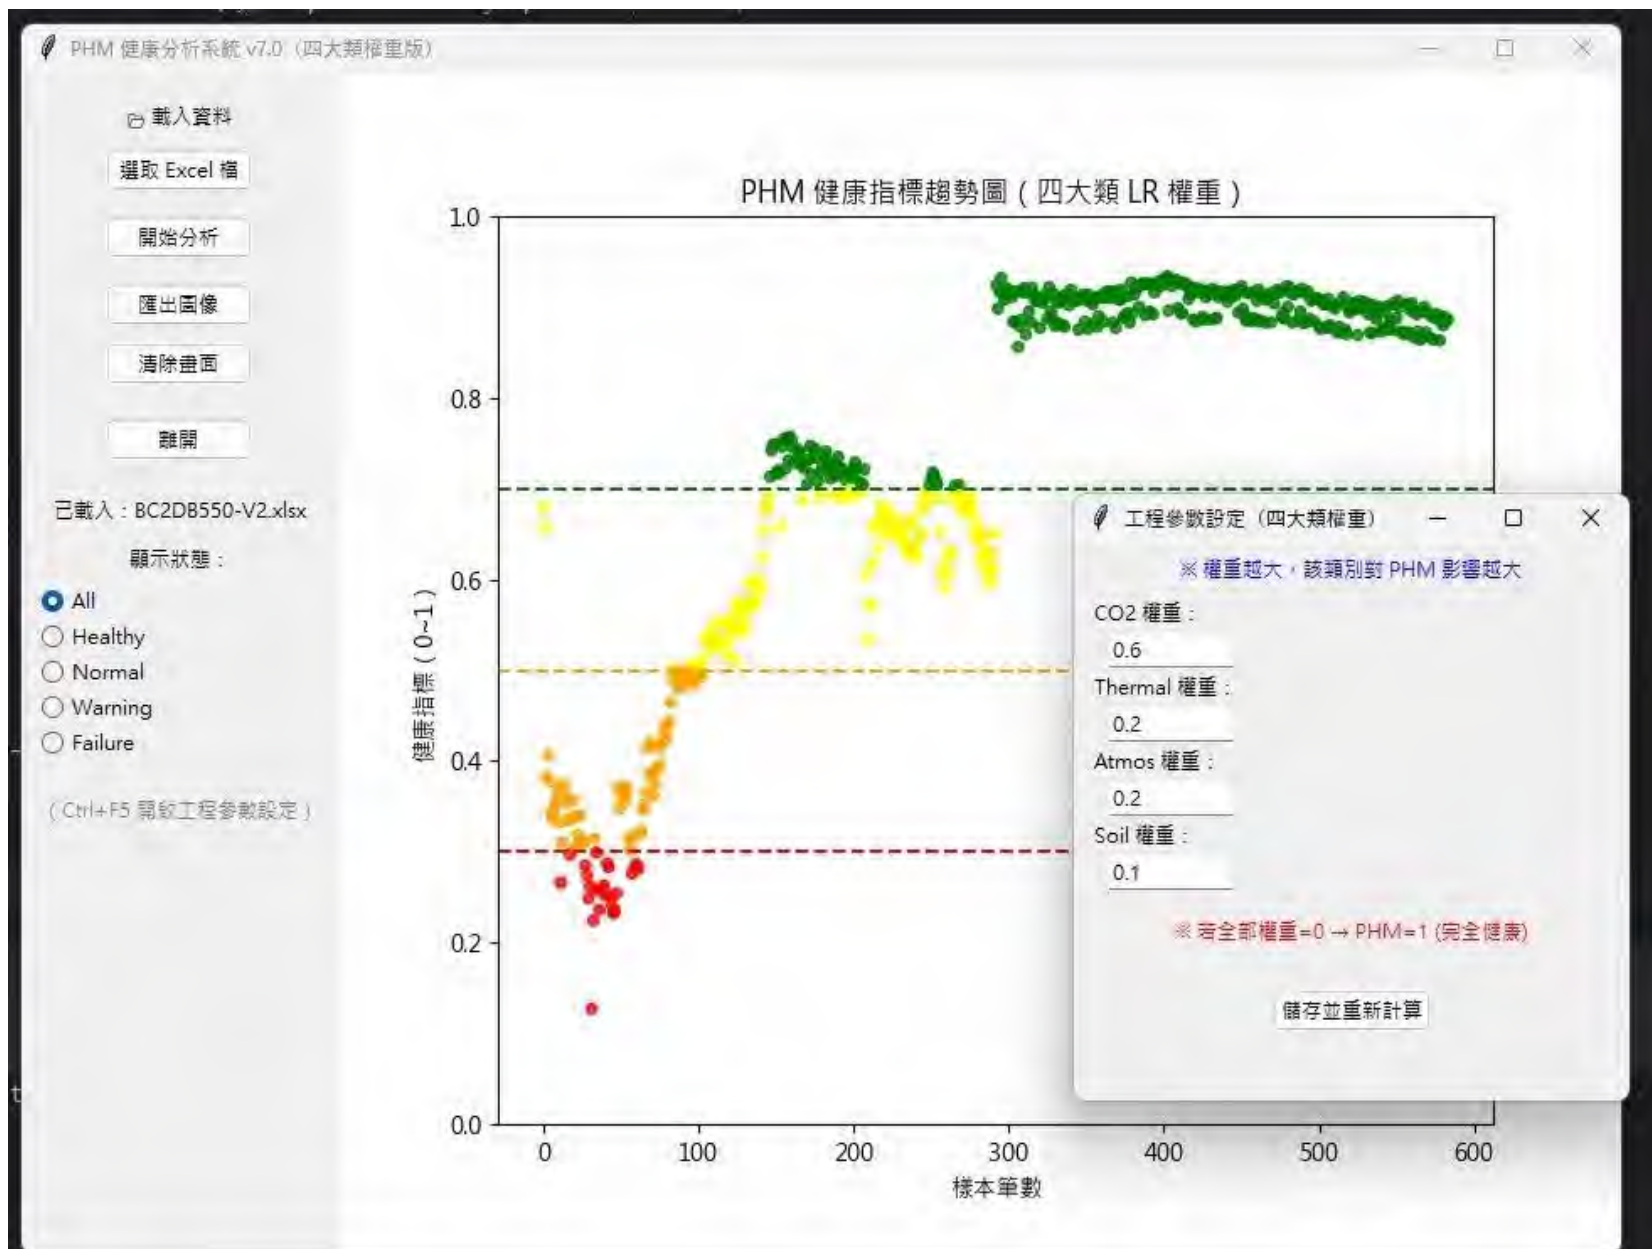


# 碳封存CO2預測AI(Correlation)


□ 特徵間線性相關係數 (%)



# 碳封存CO2預測AI(CO2)




# 碳封存CO2預測AI (Soil)






# 碳封存CO2預測AI(Thermo)



# 碳封存CO2預測AI(Atoms)





**(應用範例-其他)**

## 聲音訊號的壓縮機故障診斷

總工程師室儀控轉機中心





# 其他應用(聲音辨識與ECG 疾病辨識)

## Sequence Classification Using CNN-LSTM Network

This example shows how to create a 2-D CNN-LSTM network for speech classification tasks by combining a 2-D convolutional neural network (CNN) with a long short-term memory (LSTM) layer.

A CNN processes sequence data by applying sliding convolutional filters to the input. A CNN can learn features from both spatial and time dimensions. An LSTM network processes sequence data by looping over time steps and learning long-term dependencies between time steps. A CNN-LSTM network use convolutional and LSTM layers to learn from the training data.

To train a CNN-LSTM network with audio data, you extract auditory-based spectrograms from the raw audio data and then train the network using the spectrograms. This diagram illustrates the network application.

