

行政院原子能委員會核能研究所

委託研究計畫

期末報告

變壓器智慧診斷之專家系統技術研究

Research of an Expert System of Transformer for Diagnosis Using  
Artificial Intelligence

計畫編號：111A016

受委託機關(構)：國立臺灣科技大學電機工程系

計畫主持人：郭政謙

核研所聯絡人員：沈勁鈺

111 年 11 月 30 日

## 目 錄

摘要 .....	1
Abstract .....	2
一、 計畫緣起與目的 .....	3
1.1 計畫背景 .....	3
1.2 計畫目的及重要性 .....	3
1.3 國內外有關本計畫之執行情況 .....	4
二、 研究方法 .....	5
2.1 採用之方法與原因 .....	5
2.2 設備儀器之使用介紹 .....	12
2.3 電力變壓器實裝擷取局部放電預警監測 .....	16
2.4 局部放電警報功能 .....	17
2.5 故障診斷系統之功能規劃 .....	21
2.6 故障診斷系統之軟體功能規劃 .....	22
2.7 局部放電 PRPD 圖之資料蒐集與彙整 .....	22
2.8 變壓器局部放電人工智慧故障診斷系統實作與分析 ...	29
2.9 變壓器局部放電人工智慧自動辨識 PRPD 圖之訓練 ...	38
2.10 變壓器局部放電人工智慧自動辨識 PRPD 圖之整合測試 ...	42
三、 結論與討論 .....	48
3.1 結論 .....	48
3.2 後續應用及發展 .....	48

## 摘要

高壓設備一旦故障即損失極大的經濟效益，所以預防更勝於治療，高壓絕緣劣化檢測的有效方法之一就是觀察設備局部放電的現象，且為最初期的特徵，即早發現設備問題就可以提前做預防，而趨勢性觀察更優於週期性的檢查，長時間的觀察有效降低誤判的機率。

本計畫擬運用局部放電量測後所產生的 PRPD 圖及其數據進行人工智慧深度學習辨識。為了能使診斷系統提升診斷效率與準確性，需對量測數據進行特徵分群演算法，使得對於故障數據敏感性高的模型快速對檢測數據進行故障辨識，本計畫擬採用 t-隨機鄰近嵌入法(t-distributed stochastic neighbor embedding, t-SNE)與一維卷積神經網路(One-Dimensional Convolutional Neural Network, 1-D CNN)來快速對油浸式變壓器進行故障分析與識別。t-SNE 被廣泛運用於降維與資料視覺化，在高維度數據使用高斯分布的機率密度函數近似，而低維度數據則使用 t 分佈方式近似，在使用 KL 距離密度計算相似度，最後利用梯度下降求出最佳解，相較於主成分分析更容易處理特徵之間的非線性關係避免欠擬合(underfitting)的情產生。透過此方法可以將系統實際運行數據非監督式分群，了解此油浸式變壓器於多次的局部放電量測中之 PRPD 圖形狀況有哪幾種，再進行資料篩選後，作為深度學習的訓練資料樣本集。

## Abstract

If high-voltage equipment fails, great economic benefits will be lost. So prevention is better than cure. One of the effective methods of high-voltage insulation degradation detection is to monitor partial discharge of the equipment, that is initial characteristic. Early detection of equipment problems can prevent them in advance, and trend observation is better than periodic inspection. Long-term monitoring effectively reduces the probability of misjudgment.

This project intends to use the PRPD map and its data generated after partial discharge measurement for artificial intelligence deep learning identification. In order to improve the diagnostic efficiency and accuracy of the diagnostic system, it is necessary to perform a feature clustering algorithm on the measurement data, so that the model with high sensitivity to the fault data can quickly identify the fault of the test data. This project plans to use t-random adjacent embedding. The method of t-distributed stochastic neighbor embedding (t-SNE) and one-dimensional convolutional neural network (One-Dimensional Convolutional Neural Network, 1-D CNN) can be used to quickly analyze and identify oil-immersed transformers. t-SNE is widely used in dimensionality reduction and data visualization. The probability density function of Gaussian distribution is used to approximate high-dimensional data, while the t-distribution method is used to approximate low-dimensional data. KL distance density is used to calculate similarity, and finally gradient is used. Compared with principal component analysis, it is easier to deal with the nonlinear relationship between features and avoid underfitting. Through this method, the actual operation data of the system can be unsupervised and grouped to understand the PRPD pattern status of the oil-immersed transformer in multiple partial discharge measurements. After data screening, it can be used as training data for deep learning. sample set.

## 一、計畫緣起與目的

### 1.1 計畫背景

高壓設備發生短路事故大多是絕緣劣化的原因，而絕緣劣化通常是經由電應力、熱應力或機械應力造成的老化現象，這些老化現象會再因為局部放電的關係加速劣化導致嚴重的事故發生，為避免造成重大事故，結合深度學習辨識達到即時偵測告警異常。

### 1.2 計畫目的及重要性

高壓設備部分放電訊號，除了有低頻成分也有高頻成分，但低頻信號所受到的環境干擾較高頻信號多，故本計畫以高頻成分信號進行局部放電分析。藉由安裝 HFCT 和 UHF 感測器，並進行全時長期線上量測，則可達到趨勢性的定量檢測，並記錄放電次數、放電最大值、放電平均值及畫出 PRPD 圖做放電檢測判斷。

本系統的檢測改善了過去許多檢測方式的缺點，像是過去使用直流耐壓或電力因數的絕緣品質測試都只能測出高壓設備整體的劣化情形，但本系統透過檢測到的局部放電信號，利用 PRPD 圖的分析診斷出高壓設備的瑕疵放電，而且舊有的檢查方法需要透過斷電才能進行檢查，設備停電的時間將會帶來經濟成本損失，因此本計畫運用高頻電磁波間接量測法，不需要再擔心靠近高壓設備的風險，高壓設備也不需要停電就能做即時傳輸資訊的監控。

### 1.3 國內外有關本計畫之執行情況

關於高壓設備局部放電的研究國內外皆有各種報告、論文可以參考，PRPD 圖的分析一直都是此類項目很重要的判斷依據，因此在參考的報告中有提供利用試片盤模擬的放電測試[1]，模擬了電暈放電、外部放電及內部放電，此報告中相關的放電頻段、放電數值、PRPD 圖都成為本系統相關數據的依據。

有關局部放電的雜訊處理也參考了相關的各項研究，時頻分析法利用放電訊號的時間長短可以有效地分析出雜訊和實際局部放電值[2]，另外也有參考人工智能分類 PRPD 圖的報告、論文，使用卷積神經網路(CNN)做圖像分析的學習[3]。

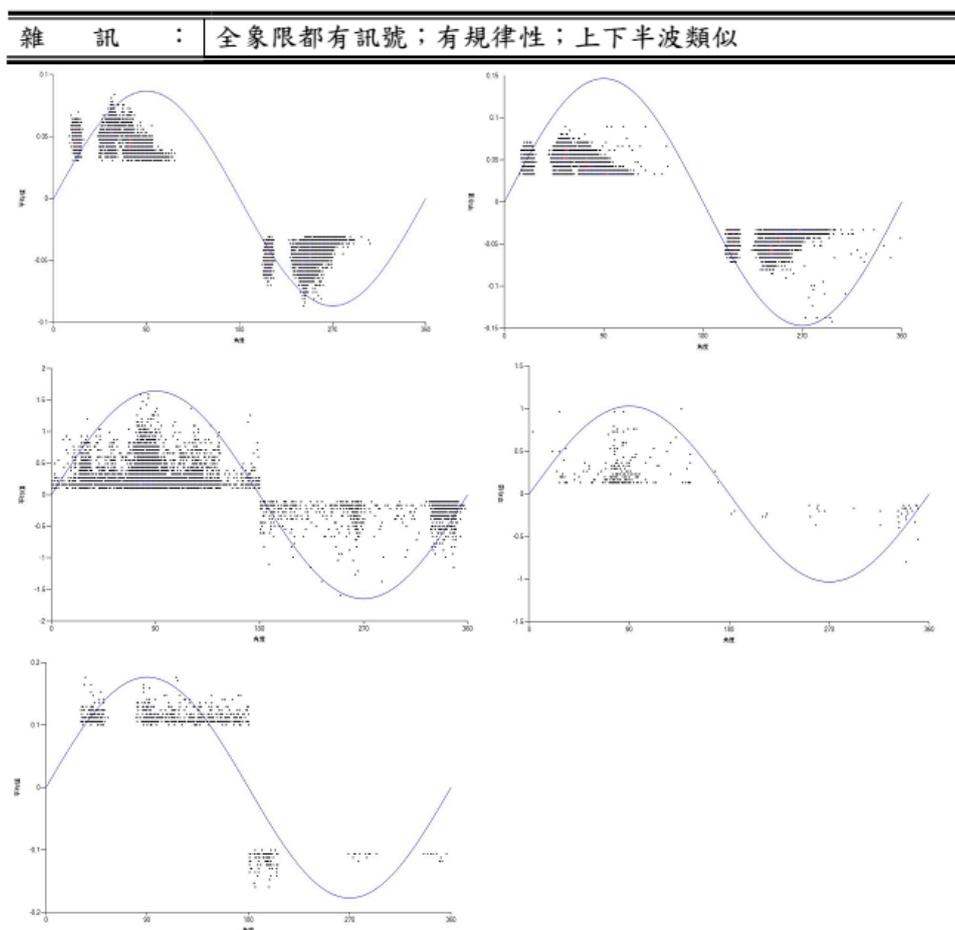
## 二、 研究方法

### 2.1 採用之方法與原因

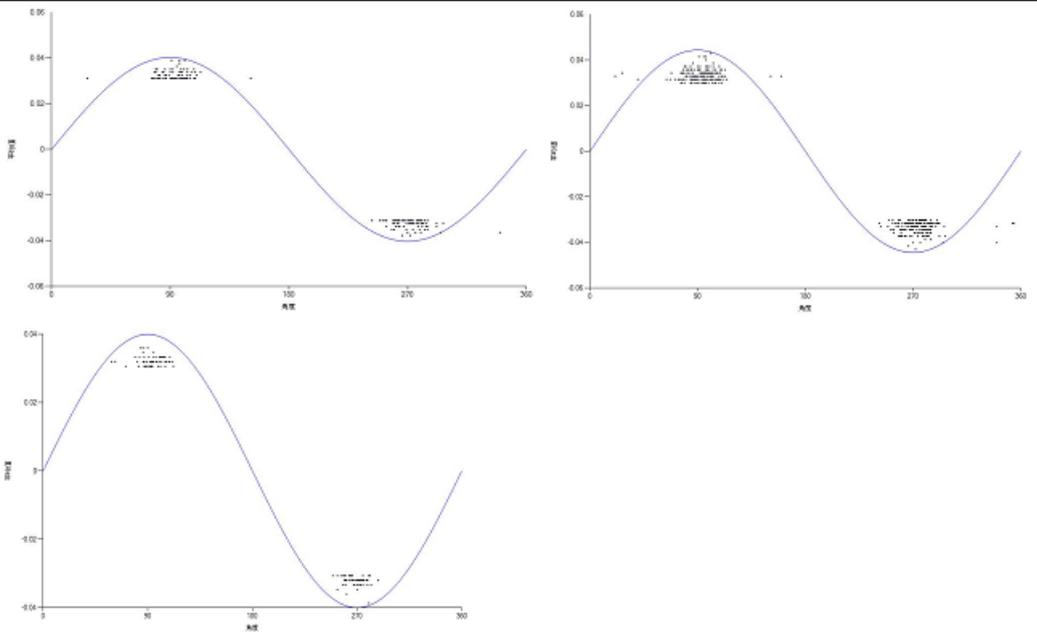
油浸式變壓器在投入使用以後，由於長期的運轉在高電壓、高電流及高溫度的情況下，導致了設備內各元件逐漸地發生各種老化現象，並隨著時間，元件的絕緣等級會隨之下降，且直接影響相關電力設備的運轉能力，亦可能導致設備發生非預期的突發性事故，造成停電困擾。目前商用環境下多半使用局部放電量測技術，以期提早發現高壓設備的瑕疵，惟局部放電的量測後的圖譜故障型態判別，非常受限於經驗豐富的專家或學者，因此若能利用人工智慧技術來輔以進行故障類型的評估，將能更大量的提高局部放電量測系統的建置，並獲致故障預知的效果，減少因高壓設備於未知下的傷害及其所造成的損失。基於此，本計畫擬針對油浸式變壓器進行線上之局部放電量測，並將之轉為可用來評估變壓器故障類型的 PRPD 圖，輔以人工智慧深度學習的技術，確保電力設備可靠的運行，降低維護費用，並提高安全性與穩定供電，避免未知的故障所引起的用電中斷現象。

本計畫擬運用局部放電量測後所產生的 PRPD 圖及其數據(如圖一所示)進行人工智慧深度學習辨識。為了能使診斷系統提升診斷效率與準確性，需對量測數據進行特徵分群演算法，使得對於故障數據敏感性高的模型快速對檢測數據進行故障辨識，本計畫擬採用 t-隨機鄰近嵌入法(t-distributed stochastic neighbor embedding, t-SNE)與一

維卷積神經網路(One-Dimensional Convolutional Neural Network, 1-D CNN)來快速對油浸式變壓器進行故障分析與識別。t-SNE 被廣泛運用於降維與資料視覺化，在高維度數據使用高斯分布的機率密度函數近似，而低維度數據則使用 t 分佈方式近似，在使用 KL 距離密度計算相似度，最後利用梯度下降求出最佳解，相較於主成分分析更容易處理特徵之間的非線性關係避免欠擬合(underfitting)的情產生。透過此方法可以將系統實際運行數據(圖 1)非監督式分群，了解此油浸式變壓器於多次的局部放電量測中之 PRPD 圖形狀況有哪幾種(圖 2)，再進行資料篩選後，作為深度學習的訓練資料樣本集。



**電 暈：** 發生於間隔 180 度的象限，且放電大小接近一致。



**內部放電：** 大致發生於間隔 180 度的象限，上下半波放電大小不會一致，電壓越大，放電有越嚴重的趨勢。

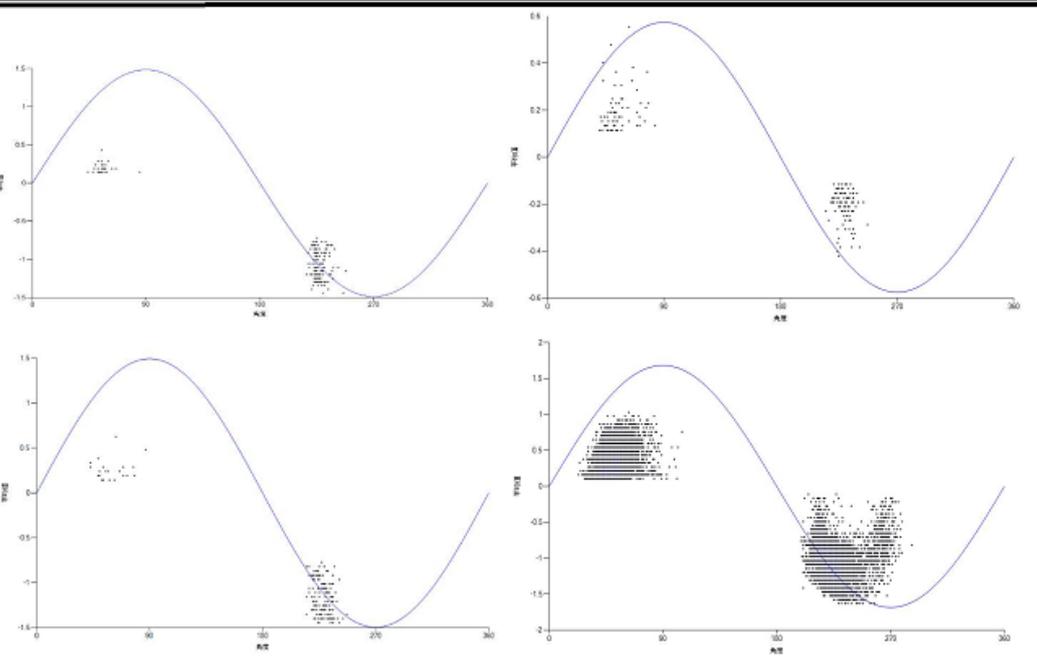


圖 1 局部放電 PRPD 典型圖譜

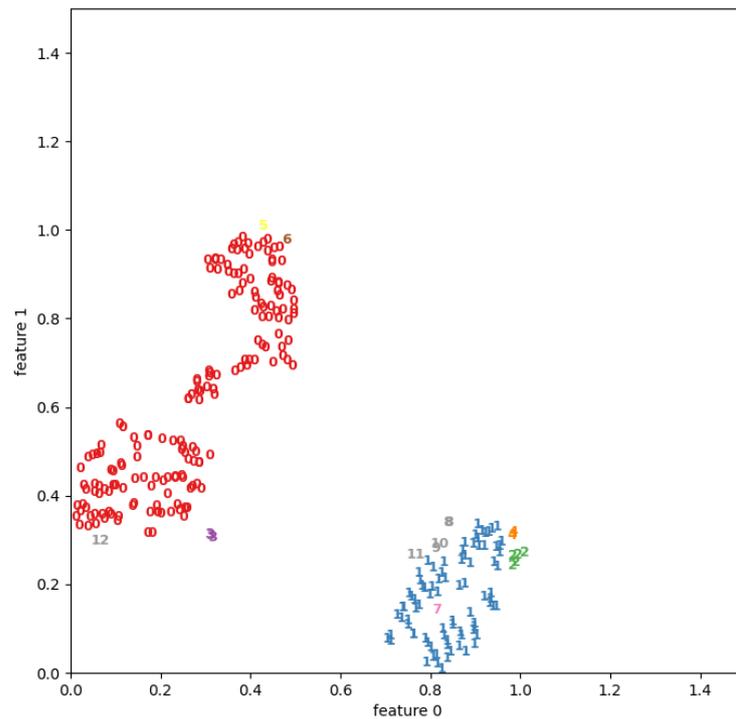


圖 2 t-SNE 數據特性分群

深度學習相較於機器學習能夠從原始數據執行自動特徵提取，深度學習是機器學習的分支，亦是人工智慧中成長最快的領域，深度學習模擬人類神經網絡的運作方式，常見的深度學習架構，如多層感知器(Multilayer Perceptron)、深度神經網路 DNN(Deep Neural Network)、卷積神經網路 CNN(Convolutional Neural Network)、遞迴神經網路 RNN(Recurrent Neural Network)。深度學習因富含多層的學習器，逐層學習並把學習到的知識傳遞給下一層，以便下層能夠得到更高級別的表述形式，所以特別能應用於視覺辨識、語音識別、自然語言處理、生物醫學等領域，取得非常好的效果，最終目標是期望可以得到與人類類似的結論。

本計畫擬用的深度學習網路為 1D CNN，其可以很好的應用於資料的時間序列分析與分析具有固定周期的訊號資料，將利用 t-SNE 預分類與原始資料預處理的訓練資料作為輸入，透過前端卷積層 (Convolution Layer) 對原始數據進行卷積運算萃取出數據中的特徵，接著使用池化層 (Pooling Layer) 壓縮圖片大小減少數據量卻有可以保留重要特徵以及雜訊功能，最後全連接層 (Fully Connected Layer) 將特徵導入基本神經網路中進行訓練建立良好的油浸式變壓器局部放電故障檢測系統(如圖 3 所示)。

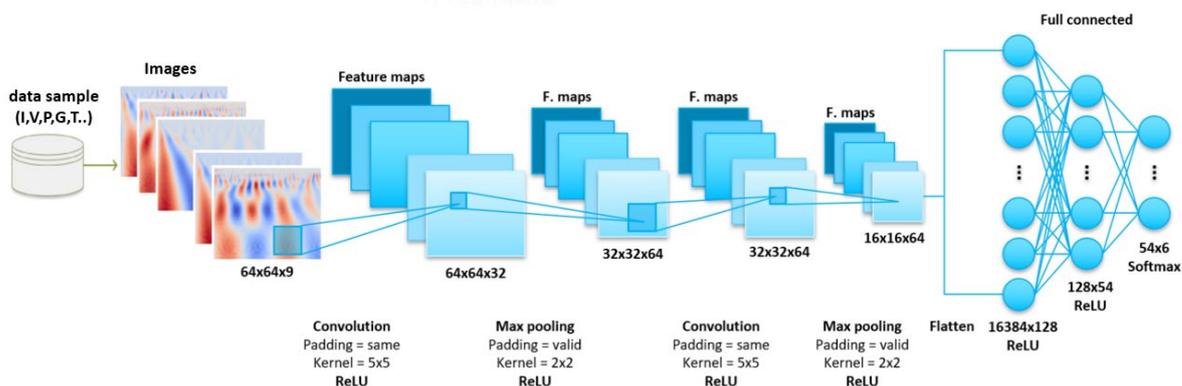


圖 3 1D CNN 深度學習網路架構圖

綜合上述，本計畫之主要目的，在開發一套電力變壓器之智慧診斷專家系統，提供智慧型的電力變壓器狀態立即顯示及故障預先警示系統，有效防止絕緣劣化或重要設備元件無預警故障的發生，確保其變壓器可靠的運行，降低維護費用，並提高安全性與穩定供電。透過各感測器所擷取之放電訊號進行卷積神經網路分析判讀，利用綜合檢測方式之優勢進而彌補其各不擅長之量測元件，進而增加判斷

故障程度與類型之功能。

計畫架構主要分為兩大部分，一為長期放置於電力變壓器之運轉監測單元，其透過資料擷取器收集電場感測器、高頻電流感測器、超高頻局部放電感測器，即時線上擷取電力變壓器內各元件局部放電訊號。並利用 TCP/IP 網路傳輸方式，傳回位元於中央伺服器進行訊號處理與分析。

本系統第二部分為電力變壓器狀態檢測及預警主系統，本部份將使用一台伺服器級電腦，搭配綜合局部放電法對電力變壓器內之高壓元件進行訊號量測，評估各高壓元件是否有異常局放現象，藉由圖控式人機介面的資料擷取與故障型態分析，並透過驗證程式以確認理論之可行性，完整開發電力變壓器之智慧專家系統，以提供狀態監視及預防性事故檢測所需。同時因此伺服器電腦具備大量儲存空間及網路介面，故可以輕易的將歷史資料儲存，透過捲積神經網路演算法分析目前與歷史數據，結合設備絕緣老化過程之特徵萃取，作為老化或絕緣劣化的輔助參考指標，評斷電力變壓器是否有老化、絕緣劣化或異常現象。亦可透過網路將資料傳出至雲端或資料中心，將控制權或顯示畫面，也可以透過網路傳給監控中心並利用轉換技術，以加入適當抗干擾及濾除雜訊之方式，得到完整且正確之放電圖譜，最後並以此圖譜，運用時頻分析之技術，提取合適之特徵向量並配合人工智慧之技術予以辨識，本計畫所得之結果，將能有效提供業者評估電

力設備元件之老化期別，提前更換過度老化之高壓元件，以利於避免絕緣事故之發生，提高系統之運轉效率及可靠度。其主要架構及功能方塊示意圖如圖 4 及圖 5 所示：



圖 4 整體系統架構圖

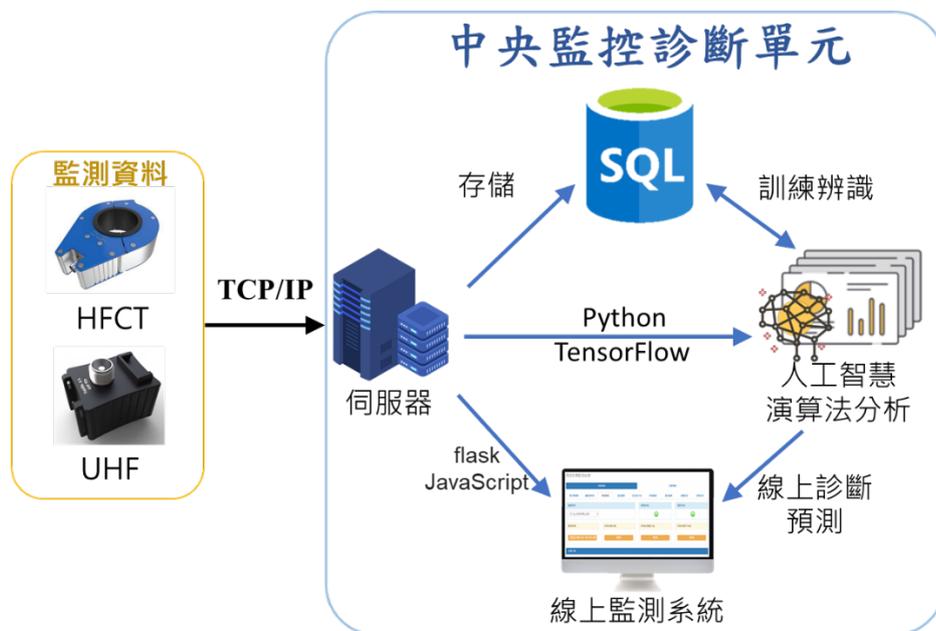


圖 5 中央監控診斷單元架構圖

## 2.2 設備儀器之使用介紹

### (一) HFCT (高頻 CT)

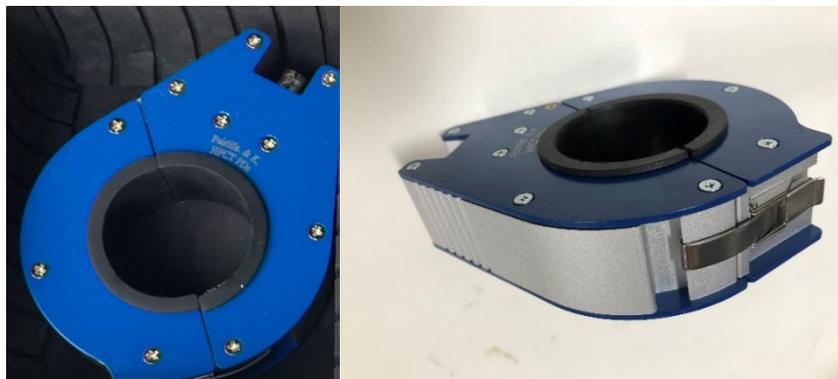


圖 6 HFCT 俯視圖(左) HFCT 側面圖(右)

頻寬	1M~50MHz
廠牌	Fairlife & k.
耐候等級	-10~65 華氏度，室內型
介面	輸出為 BNC 接頭
電源	被動式元件不需電源

以 IEC62478 部份放電線上量測建議方法 HF/VHF 量測法(感測器)為 3MHz 至 300MHz，此 UHF 使用的 HFCT 頻寬為 1M~50MHz，採用鎳鋅高頻磁粉鐵心繞置之開合電感式比流器，可監測接地線之部份放電訊號。

## (二) UHF (超高頻可繞式天線)



圖 7 UHF 俯視圖(左) UHF 側面圖(右)

頻寬	300M~1.2GHz
廠牌	Fairlife & k.
耐候等級	-40~90 華氏度，室外型
介面	輸出為 N-Type 高頻接頭
電源	被動式元件不需電源

以 IEC62478 部份放電線上量測建議方法 UHF 量測法(感測器)為 300MHz 至 3GHz，此 UHF 頻寬範圍為 300MHz~1.2GHz，工作環境的干擾頻率通常在 300MHz 以下，雜訊相對很少，不需太複雜的雜訊消除技術。

可量測距離小，適合於變壓器之高壓電纜端或套管端，電力電纜中間與終端接頭，高壓開關盤內。

### (三) 放大檢波片



圖 8 自製的放大檢波片

放大倍率	30dB
廠牌	自製
耐候等級	-50~150 攝氏度
介面	皆為 SMA 接頭
電源	12V 直流電源，靜態電流約 40mA

訊號輸入後先經過放大，再透過檢波電路使訊號變為包絡訊號，包絡訊號較能輕易地觀察出一次放電訊號的起始點與結束點，不需要再透過計算去判斷。

電路晶片損壞可在遠端由訊號輸出得知，預設為晶片損壞時有 5V 直流輸出，可依據數位系統准位調整。

### (四) 資料擷取器規格

資料處理的部分主要是交由 Adlink 的 MCM-100 處理器去做運算，並透過 USB 接孔連接 Adlink 的 USB-1210 最多可擴充成 16 個通道。

透過上一小節的流程圖判斷分析，從 HFCT、UHF 擷取到的局部放訊號，再將經過處理的信號透過光纖網路線傳輸至伺服器，即使不在案場也可以透過網路監測高壓設備的狀態。



圖 9 Adlink MCM-100



圖 10 Adlink USB-1210

中央處理器	Intel® Atom x7-E3950
記憶體	4 GB DDR3L 1600 MHz SODIMM module (Up to 8 GB support)
儲存裝置	128 GB mSATA SSD
有線網路介面	2 個 GbE ports (2 個 Intel I210IT)
通道數	4 個同步通道(可擴充成 16 通道)
解析度	16 bit

### 2.3 電力變壓器實裝擷取局部放電預警監測

本計畫於忠福廠域安裝局部放電監測系統，監測電力變壓器的實際運轉資料狀況。將感測器定時量測放電狀況資料傳送到中央監測診斷單元。實裝儀器環境如下圖：



圖 11 HFCT 感測器安裝位置  
(變壓器本體接地線)



圖 12 UHF 感測器安裝位置  
(高壓電纜進線處)



圖 13 現場資料蒐集櫃

## 2.4 局部放電警報功能

局部放電監控功能提供維護及操作人員了解電力變壓器即時狀態及可能之故障警示，並透過監測到的感測器資訊，將設備狀態分為三種：正常、注意、危險。警示程度狀態將如表 1 所規畫。

表 1 中央監控診斷單元精簡狀態之警示程度

絕緣狀態	代表意義
正常	電力變壓器處於正常運轉狀態，尚無檢測到任何異常現象。
注意	電力變壓器處於短時間異常狀態，需持續密切留意，是否有朝向老化、劣化情況發展。
危險	電力變壓器處於長時間且大量之異常現象，建議立即卸下進行維護保養。

目前主頁面設計有簡易單線圖可以一目了然個設備所對應的裝設位置與監測目標，若有警報單一顆旁邊的綠燈就會變紅燈，而總警報狀態也會變紅燈警示監控人員。

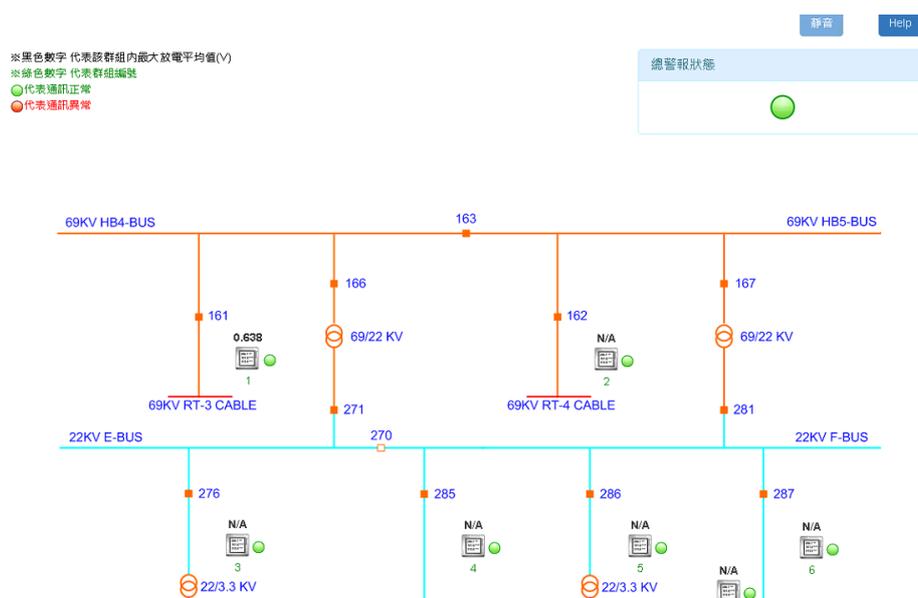


圖 14 警報單線圖

另外我們也提供警報設定頁面，警報可以有次數、最大值、平均值判斷設定，本系統感測器在建置完成時都進行過校正程序，將局部放電所產生之電磁波，校正為 1V 的顯示值。設備在發生真正內部放電且達到需要警戒的程度時，一般放電次數依週期內可達上千甚至是上萬次，並且會不停歇地出現。

因此使用初期建議以較嚴格的警戒狀態設定為佳，而危險狀態則以明確要特別注意之設定為宜，基於上述的建議，警報值設定應為以下建議值：

警戒：放電次數超過 500，放電平均值超過 1V(尚屬微弱)，放電最大值超過 1.3(有隨機性，符合局部放電特性)，連續 30 分鐘，超過 80%的發生機率。

危險：放電次數超過 1000，放電平均值超過 1.5V，放電最大值超過 2.0，連續 60 分鐘，超過 90%的發生機率。

使用者可依據對案場設備的了解在圖 15 警報設定畫面中智慧性的設定警報參數，並隨著長時間的觀察，逐步調整改變設定條件，以更符合使用者需求，若有需要也可依需求設定其他參數。

[儲存告警](#)

告警設定-Danger

單位	判別條件	數值	邏輯	刪除條件		持續時間(分)	<input checked="" type="checkbox"/> 是否傳送簡訊
次數	>	1	AND	Delete	新增條件	30	<input type="text" value="0912571920"/>
平均值	>	1000	AND	Delete			<input type="text" value="0960163856"/>
次數	>	4	AND	Delete			<input type="text"/>

告警設定-Warning

單位	判別條件	數值	邏輯	刪除條件		持續時間(分)	<input type="checkbox"/> 是否傳送簡訊
次數	>	5	AND	Delete	新增條件	1440	<input type="text" value="0988601689"/>
最大值	>	4	AND	Delete			<input type="text"/>
次數	>	3	AND	Delete			<input type="text"/>

圖 15 警報設定畫面

此部分之警報設定並不侷限於單一條件設定，使用者若有足夠的經驗，可以新增多項條件，以利用更多的智慧性邏輯條件，使警報的條件更具實用性，避免錯誤警報及危險時不警報之情況。

右方也可勾選是否在出現警告異常時傳送簡訊至指定手機中，此畫面調整參數也有密碼做保護，在按下儲存後需要輸入密碼才能變更其中的參數設定。

即時警報訊息可依據警報設定使用者告警訊息，如圖 16 即時警報畫面分為兩階，一階為“Warning”提醒使用者需加以注意，另一階為“Danger”提醒使用放電狀態較為嚴重，需立即處理。

即時告警-Danger (條件: 次數 > 1 AND 平均值 > 1000 AND 次數 > 4 持續時間: 30分)

Reset  全選

編號	IP	裝置名稱	發生時間	放電次數	放電最大值	放電平均值
<input type="checkbox"/> 16	192.168.1.102	EE305-1	2016-03-14 01:00:00	85	349	172
<input type="checkbox"/> 17	192.168.1.102	EE305-1	2016-03-14 01:18:00	103	367	190
<input type="checkbox"/> 18	192.168.1.102	EE305-1	2016-03-14 01:38:00	123	387	210
<input type="checkbox"/> 19	192.168.1.102	EE305-1	2016-03-14 02:00:00	145	409	232
<input type="checkbox"/> 20	192.168.1.102	EE305-1	2016-03-14 02:24:00	169	433	256
<input type="checkbox"/> 11	192.168.1.102	EE305-1	2016-03-14 12:00:00	25	289	112
<input type="checkbox"/> 12	192.168.1.102	EE305-1	2016-03-14 12:08:00	33	297	120
<input type="checkbox"/> 13	192.168.1.102	EE305-1	2016-03-14 12:18:00	43	307	130
<input type="checkbox"/> 14	192.168.1.102	EE305-1	2016-03-14 12:30:00	55	319	142
<input type="checkbox"/> 15	192.168.1.102	EE305-1	2016-03-14 12:44:00	69	333	156

即時告警-Warning (條件: 次數 > 5 AND 最大值 > 4 AND 次數 > 3 持續時間: 1440分)

Reset  全選

編號	IP	裝置名稱	發生時間	放電次數	放電最大值	放電平均值
<input type="checkbox"/> 6	192.168.1.102	EE305-1	2016-03-14 01:00:00	85	349	172
<input type="checkbox"/> 7	192.168.1.102	EE305-1	2016-03-14 01:18:00	103	367	190
<input type="checkbox"/> 8	192.168.1.102	EE305-1	2016-03-14 01:38:00	123	387	210
<input type="checkbox"/> 9	192.168.1.102	EE305-1	2016-03-14 02:00:00	145	409	232
<input type="checkbox"/> 10	192.168.1.102	EE305-1	2016-03-14 02:24:00	169	433	256
<input type="checkbox"/> 1	192.168.1.102	EE305-1	2016-03-14 12:00:00	25	289	112
<input type="checkbox"/> 2	192.168.1.102	EE305-1	2016-03-14 12:08:00	33	297	120
<input type="checkbox"/> 3	192.168.1.102	EE305-1	2016-03-14 12:18:00	43	307	130
<input type="checkbox"/> 4	192.168.1.102	EE305-1	2016-03-14 12:30:00	55	319	142
<input type="checkbox"/> 5	192.168.1.102	EE305-1	2016-03-14 12:44:00	69	333	156

圖 16 即時警報畫面

如圖 17 歷史警報畫面可選擇查詢並比對過去一段時間內的警報訊息。

選擇條件

2016-03-14 00 時 00 分 2016-03-14 23 時 00 分 查詢

即時告警-Danger

編號	IP	裝置名稱	發生時間	放電次數	放電最大值	放電平均值
15	192.168.1.102	EE305-1	2016-03-14 12:44:00	69	333	156
14	192.168.1.102	EE305-1	2016-03-14 12:30:00	55	319	142
13	192.168.1.102	EE305-1	2016-03-14 12:18:00	43	307	130
12	192.168.1.102	EE305-1	2016-03-14 12:08:00	33	297	120
11	192.168.1.102	EE305-1	2016-03-14 12:00:00	25	289	112
20	192.168.1.102	EE305-1	2016-03-14 02:24:00	169	433	256
19	192.168.1.102	EE305-1	2016-03-14 02:00:00	145	409	232
18	192.168.1.102	EE305-1	2016-03-14 01:38:00	123	387	210
17	192.168.1.102	EE305-1	2016-03-14 01:18:00	103	367	190
16	192.168.1.102	EE305-1	2016-03-14 01:00:00	85	349	172

即時告警-Warning

編號	IP	裝置名稱	發生時間	放電次數	放電最大值	放電平均值
5	192.168.1.102	EE305-1	2016-03-14 12:44:00	69	333	156
4	192.168.1.102	EE305-1	2016-03-14 12:30:00	55	319	142
3	192.168.1.102	EE305-1	2016-03-14 12:18:00	43	307	130
2	192.168.1.102	EE305-1	2016-03-14 12:08:00	33	297	120
1	192.168.1.102	EE305-1	2016-03-14 12:00:00	25	289	112
10	192.168.1.102	EE305-1	2016-03-14 02:24:00	169	433	256
9	192.168.1.102	EE305-1	2016-03-14 02:00:00	145	409	232
8	192.168.1.102	EE305-1	2016-03-14 01:38:00	123	387	210
7	192.168.1.102	EE305-1	2016-03-14 01:18:00	103	367	190
6	192.168.1.102	EE305-1	2016-03-14 01:00:00	85	349	172

圖 17 歷史警報畫面

## 2.5 故障診斷系統之功能規劃

本計畫開發之智慧故障診斷功能預計應用於辨識變壓器的局放特徵，使用 tensorflow 套件進行深度學習演算法開發，建立神經網路模型，考慮伺服器電腦硬體及功能穩定性，將採用輕量級的 CNN 模型，減緩伺服器的負擔並與準確度及速度間取之平衡。

因次將此功能設計於系統網頁之歷史查詢中，透過欲查詢時間區間內所收集的局放訊號，進行 PRPD 圖轉換，並協助操作人員辨識 PRPD 圖是否具有故障可能性。功能規劃位置如下圖所示。並提供演算法辨識結果之詳細資料，可由點選按鈕獲得更多資訊。

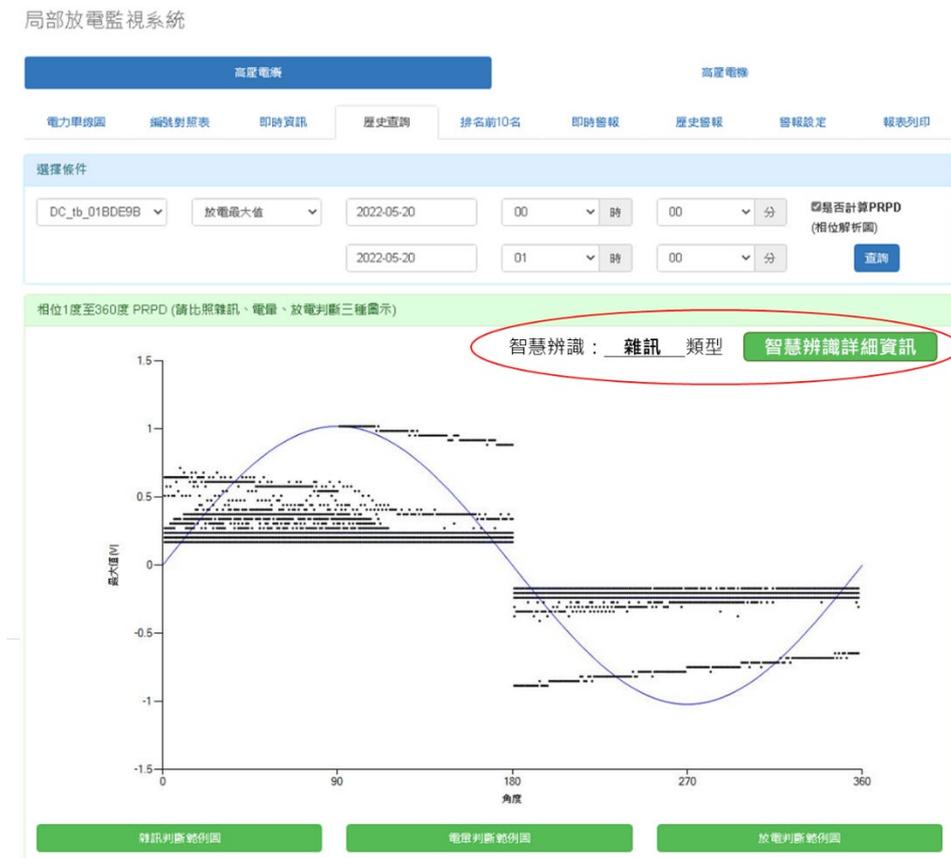


圖 18 PRPD 圖影像故障診斷功能示意圖

## 2.6 故障診斷系統之軟體功能規劃

本系統於中央監控診斷單元可即時監測變壓器狀態，但僅透過設定數值限制作為告警機制，缺少對於具有故障特徵的局放訊號做告警功能，因為這些故障特徵很有可能不會具有高數值的特性。因此透過深度學習之技術，對於這些 PRPD 圖考慮影像故障辨識技術，將能分析高壓設備老化狀態，以利於提早發出警報，爭取更多的維護時間，其進行之流程如(圖 19)所示。

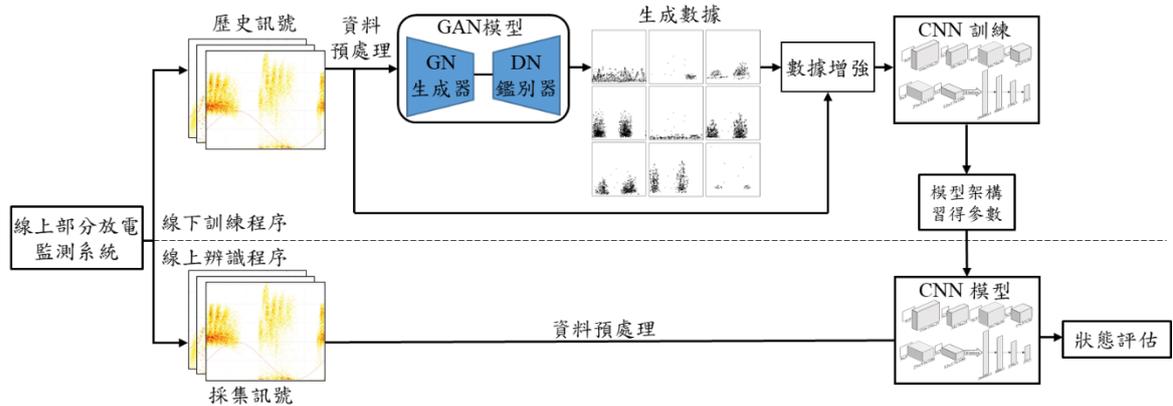


圖 19 PRPD 圖影像故障診斷流程圖

## 2.7 局部放電 PRPD 圖之資料蒐集與彙整

### 2.7.1 實際案場資料蒐集

本計畫執行期間，已於實際現場之監測系統收集平時設備運作狀態資料。因現場設備平時為無故障狀態，無明顯局放特徵，我們能夠把這些資料視為健康與雜訊。僅有少數幾次放電狀態，但並非全都是

異常，很有可能是雜訊，因此需要先經過初步的分類才能將此資料進行使用。

現場系統會先經過初步的過濾，設定一固定的閾值，把放電大小較低的值先過濾掉，這些值很有可能是來自設備或是周遭環境的雜訊，先做初步過濾可以排除多餘的不必要的資訊。目前過濾大小固定閾值設定為 100mV。

現場量測每過 30 分鐘量測一次局部放電，每次為兩週期，可從表 2 獲得有效的讀取次數，未顯示於表中的時間代表該次量測為 0。

表 2 案場放電資料統計 4 月~8 月

日期	編號	時間	次數	相位(次數)			
				1°~90°	91°~180°	181°~270°	271°~360°
4 月 28 日	ai05	18:09	37		9	6	22
6 月 9 日	ai05	03:56	9				9
6 月 9 日	ai05	16:57	36		18		18
6 月 11 日	ai05	02:00	7				7
6 月 12 日	ai05	00:04	25	9			16
6 月 12 日	ai05	01:04	6		6		
6 月 12 日	ai05	02:04	26		12		14
6 月 12 日	ai05	03:04	21		9		12
6 月 12 日	ai05	04:04	13		5		8
6 月 20 日	ai05	11:16	1	1			
6 月 20 日	ai05	11:45	1			1	
6 月 20 日	ai05	11:50	2	1		1	
6 月 20 日	ai05	13:50	4	4			
6 月 22 日	ai05	04:27	7		4		3

6月22日	ai05	15:30	2			2	
6月22日	ai05	15:30	2	2			
6月24日	ai05	13:35	4			4	
6月27日	ai05	14:50	1			1	
6月28日	ai05	21:25	1				1
6月29日	ai05	11:57	1	1			
6月29日	ai05	14:27	2	2			
6月29日	ai05	19:27	1	1			
6月30日	ai05	07:31	2			2	
6月30日	ai05	09:31	3	2		1	
6月30日	ai05	10:31	1		1		
6月30日	ai05	18:31	1			1	
6月30日	ai05	20:31	2	2			
7月1日	ai05	03:04	1	1			
7月1日	ai05	05:35	4	4			
7月1日	ai05	08:05	3	1	2		
7月1日	ai05	09:05	1	1			
7月1日	ai05	10:35	2	2			
7月1日	ai05	11:35	3	2		1	
7月1日	ai05	15:05	1	1			
7月1日	ai05	15:35	1	1			
7月3日	ai05	13:44	1			1	
7月5日	ai05	14:20	1	1			
7月6日	ai05	14:56	1	1			
7月7日	ai05	03:28	16		9		7
7月7日	ai05	11:28	1				1
7月9日	ai05	15:40	2	1	1		
7月10日	ai05	16:14	1	1			
7月15日	ai05	17:03	2	2			

8月8日	ai00	11:00					50
8月8日	ai00	14:30	100	50			50
8月9日	ai00	11:03	4	4			
8月2日	ai02	08:03		2			

可透過以上放電行為較明顯的 47 筆資料搭配放電大小轉換成可視化的 PRPD 圖形，並嘗試先以灰階圖像表示供訓練模型使用如圖 20。灰階影像對於電腦負擔較小，訓練時間也可大幅降低。除此之外適當壓縮影像的解析度，可避免訓練花費時間過長。嘗試以不同解析度進行訓練，比較結果選擇較適當的解析度進行。

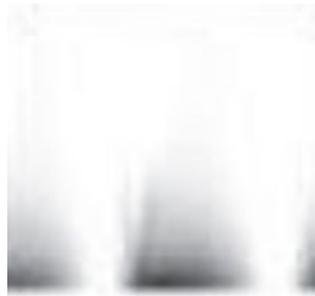


圖 20 PRPD 圖以灰階影像表示

### 2.7.2 PRPD 圖譜矩陣

本研究擷取局放感測器之訊號進行變壓器的故障診斷，因此本節先介紹局放訊號其取樣結果，透過取樣點數劃分相角作為樣本，可記錄具有放電的角度及大小，如圖 21。由於感測器支取樣頻率很高，一度包含數個取樣點，因此每筆有放電的相角不只記錄了取樣該角度之放電次數、放電最大值及放電平均值。

	P_key	sysDateTime	divDateTime	mode	angle	dissum	dismax	disavg
1	2807652	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	1	2	0.119999997317791	0.111000001430511
2	2807653	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	2	2	0.135000005364418	0.126000002026558
3	2807654	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	4	1	0.140000000596046	0.140000000596046
4	2807655	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	5	1	0.112000003457069	0.112000003457069
5	2807656	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	6	2	0.119000002741814	0.118000000715256
6	2807657	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	7	2	0.120999999344349	0.112999998033047
7	2807658	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	8	1	0.101999998092651	0.101999998092651
8	2807659	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	9	1	0.115000002086163	0.115000002086163
9	2807660	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	10	2	0.131999999284744	0.120999999344349
10	2807661	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	11	1	0.122000001370907	0.122000001370907
11	2807662	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	12	1	0.108000002801418	0.108000002801418
12	2807663	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	13	2	0.104999996721745	0.104000002145767
13	2807664	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	14	1	0.103000000119209	0.103000000119209
14	2807665	2021-07-16 10:32:20.000	2021-07-16 10:32:20.000	Auto	15	2	0.103000000119209	0.101999998092651

圖 21 局放感測器記錄之放電取樣點

因實際案場目前無法取得所需故障資訊，本計畫以實驗室內既有的故障資料做為參考。設計本研究使用於模型中的 PRPD 影像，尺寸為 120\*120 之灰階影像，如圖 22，分別具有電暈、內部、外部及雜訊。橫軸 120 像素代表相角 360°，每像素代表 3°。縱軸 120 像素代表放電電荷大小值，因此最小值為 0。根據放電次數越多，影像顏色深度則越深。由於限制了影像大小使得解析及辨識的難易度有所提升，但由於影像尺寸太高則影像後續訓練及辨識的伺服器效能，因此對此應須有所取捨。

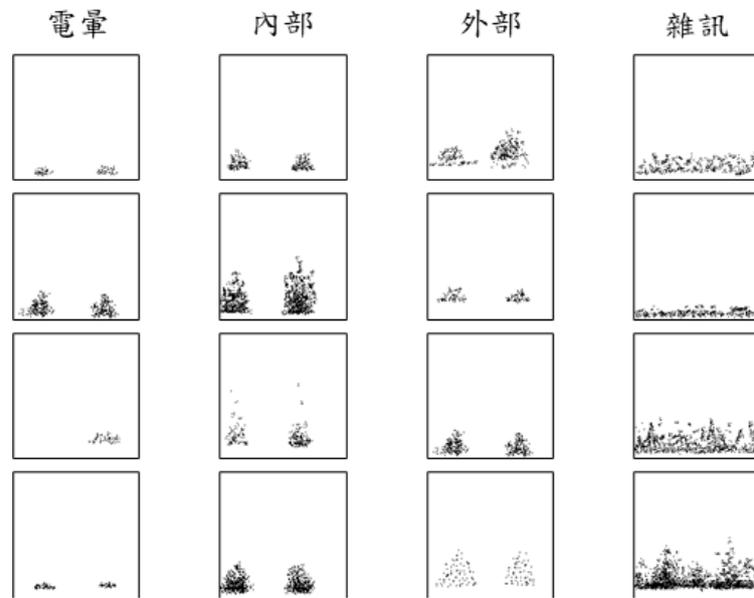


圖 22 局放感測器記錄之放電取樣點

### 2.7.2 有限數據之應用

考慮由於變壓器故障數據不易取得，因此會出現數據分佈不均勻之情形，導致一個或者少數類別數據比其它類別（多數類別）樣本數更加稀少，如圖 23 所示。造成標準機器學習模型訓練及效能上測試的困難，其原因是模型訓練期間傾向於訓練數據較多的類別，使得模型在訓練數據較多的類別上具有高準確性，而在少量數據的類別上準確率不佳，但是訓練數據較少的類別可能具有更好的知識[4]。另外，如果大多數類別的樣本於不平衡的情況下，則使模型訓練難度更加困難，為了應對此情況，文獻[5]整理一些方法，相關方法之細節將在下述中解釋。

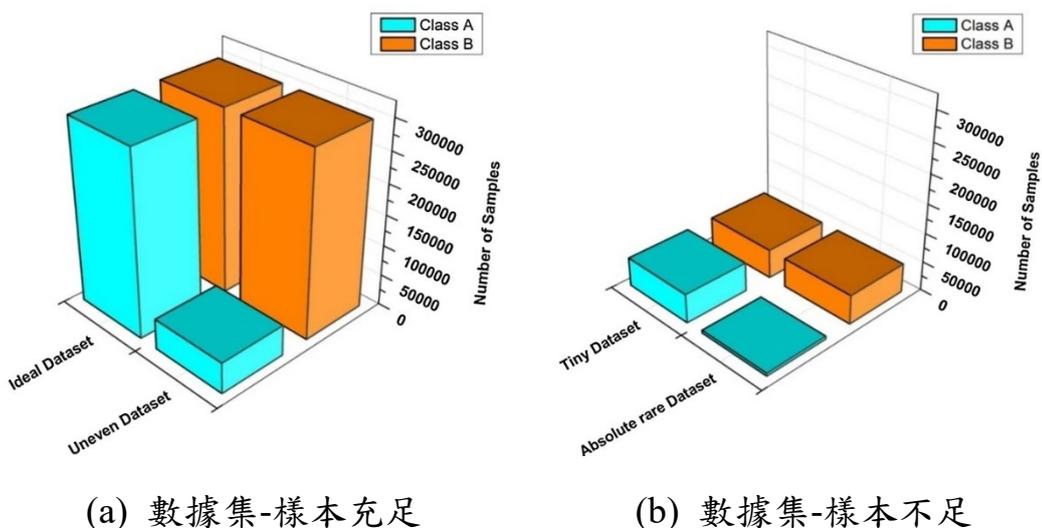


圖 23 不同類型數據集

### (1) 重採樣

為了解決數據不平衡問題，可以使用兩種重新取樣方式，其一是從較多樣本的類別中刪除樣本進行下採樣，其二是透過較少樣本的類別中複製樣本以進行過採樣。固然上述兩種方法，皆可平衡數據集，但是無法為訓練集提供任何額外的相關特徵訊息，且該方法具有所缺點，如過採樣會導致過擬合問題，而欠採樣會捨棄與數據相關的特徵訊息。欠採樣和過採樣的數據處理方式，一般採用實驗測試和經驗方式決定。為了給訓練集提供額外的特徵訊息，合成過採樣方法會創建新樣本而不是重複樣本，以增加樣本分佈的平衡。

### (2) 數據增強

數據增強是一種常用於增加訓練數據集的過採樣技術。將原始圖片進行水平翻轉、隨機旋轉、隨機放大和垂直翻轉等，主要目的在於

增強圖像數據中引入小的修改，以提高模型訓練之成效。於訓練過程完成之前，沒有標準方法可以判斷任何特定的增強策略是否可以改善結果。由於訓練 CNN 模型需耗費大量時間，模型建構之前可能僅限於測試有限數據。因此，可透過圖像的幾何處理中獲得多樣性相對較小，但是數據增強技術亦可作為深度神經網路架構中的一種正則化，從而減少過度擬合的機會。

### (3) 深度學習方法

生成對抗網路(Generative Adversarial Network, GAN)與傳統增強數據不同在於演算法。GAN 是近年仍持續發展的深度學習方法，使用少數類樣本進行數據擴充，於訓練期間，生成模型學習真實樣本的分佈，目的是以雜訊生成的樣本與真實樣本相似。然而，鑑別模型學習將樣本分類為真實樣本和生成樣本，經過足夠的訓練迭代次數後，生成模型和判別模型將共同收斂到判別模型無法區分生成樣本和真實樣本。訓練完後的生成模型可無限生成與真實樣本相似的樣本，且將此樣本輸入至分類模型進行訓練，以解決模型訓練數據不足，而導致訓練成效不佳的問題。

## 2.8 變壓器局部放電人工智慧故障診斷系統實作與分析

### 2.8.1 基於 GAN 的局部放電數據增強系統實作

GAN 屬於生成模型，其中通過兩個神經網路應用生成數據的分

佈來近似原始數據的分佈。GAN 的詳細介紹可以參考文獻[6]。GAN 中的兩個神經網絡是樣本生成器和樣本鑑別器。樣本生成器的輸入是隨機變量，樣本生成器的輸出是生成的樣本。樣本判別器用於判斷樣本是原始樣本還是生成樣本。在 GAN 中，樣本生成器的作用是使生成的樣本盡可能與原始樣本相同，從而使樣本鑑別器無法將生成的樣本與原始樣本區分開來。而樣本判別器的作用是盡可能地區分原始樣本和生成樣本。訓練網絡時，交替使用樣本生成器和樣本判別器進行訓練。

GAN 的訓練步驟如下，由兩部分組成：更新樣本判別器的參數，從 step1 到 step3，更新樣本生成器的參數，從 step4 到 step6。

Step1：從局放分佈中選擇隨機局放信號。

Step2：將局放信號輸入到樣本生成器中，使生成的樣本盡可能與原始樣本相同。

Step3：將生成的數據和原始數據輸入樣本判別器，樣本判別器的參數通過梯度下降算法更新，樣本生成器的參數固定。並且更新的目的是通過樣本鑑別器將樣本生成器獲得的數據與原始數據區分開來。

Step4：從局放分佈中選擇隨機局放信號。

Step5：將局放信號輸入到樣本生成器中，使生成的樣本盡可能與原始樣本相同。

Step6：將生成的數據和原始數據輸入樣本判別器，樣本生成器的參數通過梯度下降算法更新，樣本判別器的參數固定。而更新的目的是使樣本生成器得到的數據不能通過樣本判別器與原始數據區分開來。

Step7：若達到收斂條件則停止參數更新，否則從 Step1 開始訓練。

雖然，GAN 能有效解決數據不足之問題，但是 GAN 模型不易訓練，其原因包含模型架構、優化器參數、損失函數等。因此，WGAN-GP 提出新的損失函數以克服 GAN 及 WGAN 不足之處，此損失函數結合 Wasserstein 距離與梯度懲罰，Wasserstein 距離能有效的計算生成樣本與真實樣本之間距離，再以梯度懲罰方式修正模型參數(權重、偏差)，解決 GAN 梯度爆炸、訓練困難等問題。其次，轉移學習-微調是使用神經網路模型進行源域訓練，並根據所學習的大量知識，加強對於目標域的認知，是目前最常見且形式簡易的轉移學習方法，其主要問題在於凍結及微調層數的數量，若源域數據與目標域數據集相關性高，則微調層數可以適度減少；而若源域數據與目標域數據集相關性低，則微調層數需增加。另外，模型架構的選擇亦會影響分類成效，因此本研究參考文獻內容，最後選擇殘差神經網路架構分析有限數據下的分類成效。

## 2.8.2 深度學習 GAN 模型設計及訓練

分別介紹 GAN 的生成器與鑑別器架構及原理。生成器用於生成假樣本，先將雜訊向量輸入至上取樣卷積層，並藉由調整間距(Stride)方式以取代最大池化層，另外，只有雜訊向量是全連接層，因為需要調整維度，但是全連接層的功用僅用於矩陣運算，其架構示意圖，如圖 24 所示。

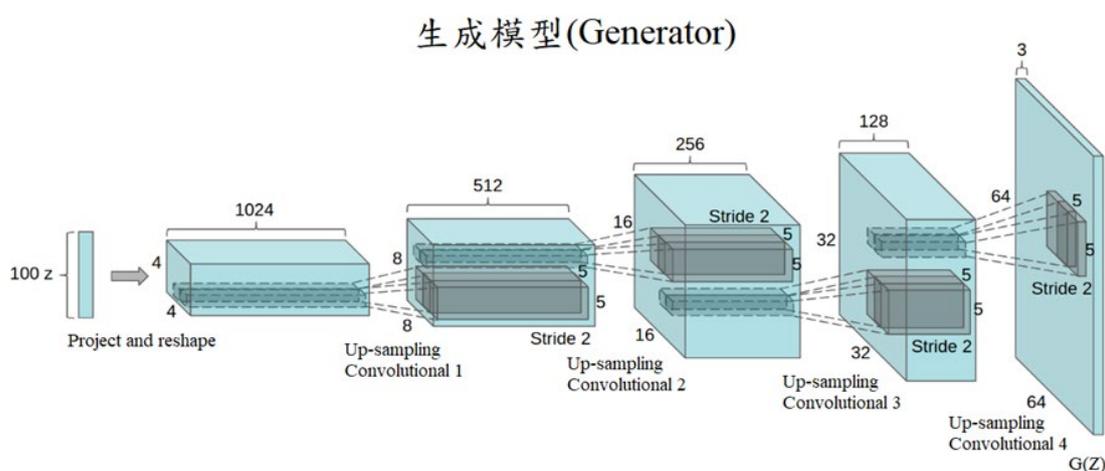


圖 24 GAN 生成器架構

而鑑別模型用於判斷是否為真實樣本，將圖片輸入至下採樣卷積層，且可以在適當位置加入批量歸一化以穩定學習，在進入輸出層前，會先將卷積層平坦化後再進入輸出層，並使用激活函數(Activation function)判斷樣本的真實性，其架構如圖 25 所示。

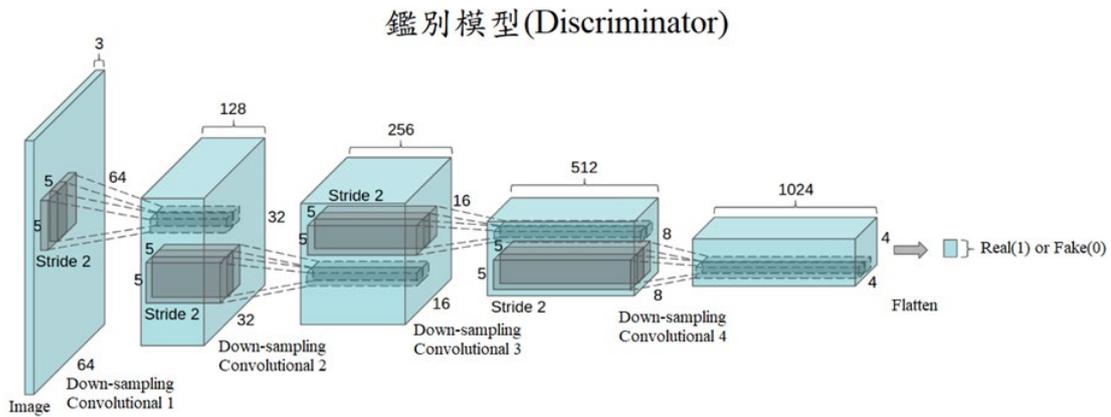


圖 25 GAN 鑑別器架構

由生成器和判別器組成，主要目的是讓隨機雜訊經由對抗訓練 (Adversarial training) 後，擬合出真實樣本的特徵分佈，使得鑑別器無法區分出數據的來源。

### (1) DCGAN 模型

DCGAN 生成模型架構如圖 26 所示。而鑑別模型用於判斷輸入數據真偽，計算損失後，用以得出生成模型之生成數據，與真實數據之間的差異，本研究 DCGAN 鑑別模型架構如圖 27 所示。若模型於訓練期間有達到納許平衡，代表 GAN 已完成訓練並且已經收斂。GAN 與 DCGAN 不同之處僅只於鑑別模型與生成模型的架構，DCGAN 其中在生成器中採用帶步長的卷積代替了上採樣，極大地提升了 GAN 訓練時的穩定性及生成結果質量，且幾乎每層都使用 batchnorm 層，將特徵層的輸出歸一化，加速訓練，提升訓練的穩定性。



圖 26 DCGAN 生成模型架構

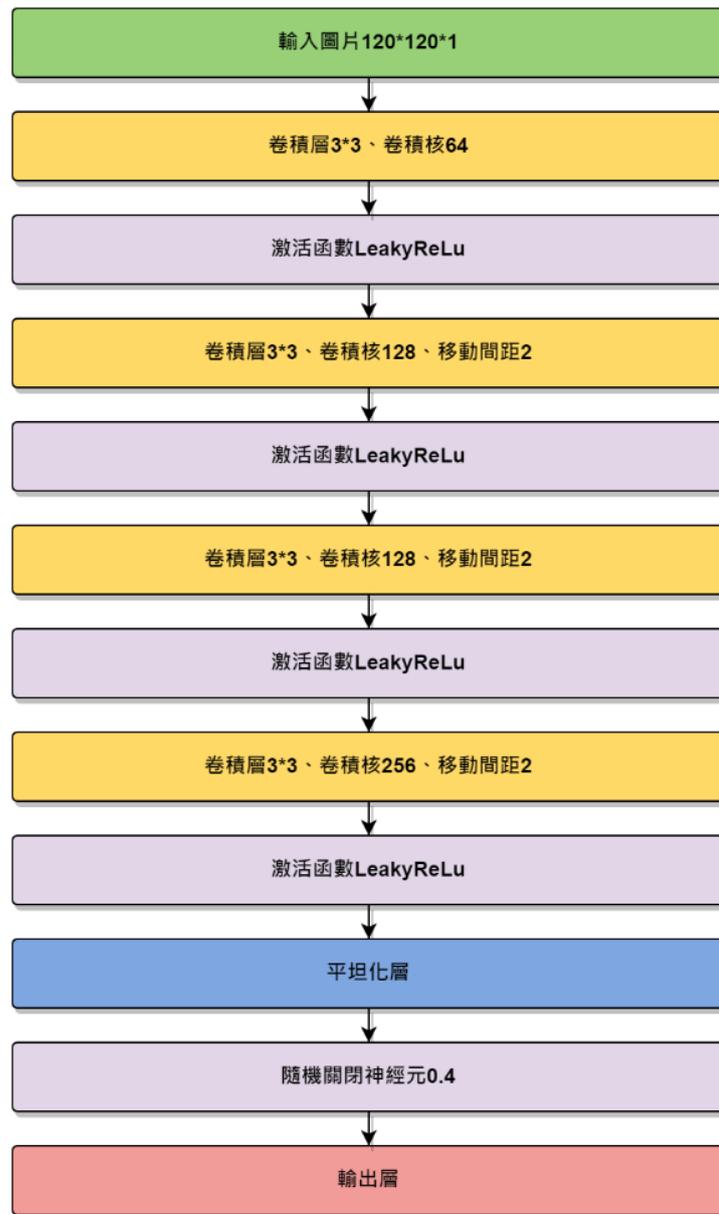


圖 27 DCGAN 鑑別模型架構

## (2) DCGAN 模型實作結果

如圖 28 所示，橫軸表示數據的真實性，縱軸表示密度，用以展示生成圖像與真實圖像之分佈，從圖中可以看出，生成圖像的分佈與真實圖像的分佈大致相同。由此我們可以得出結論，生成的圖像是真

實圖像的真實代表，學習了大部分變化。

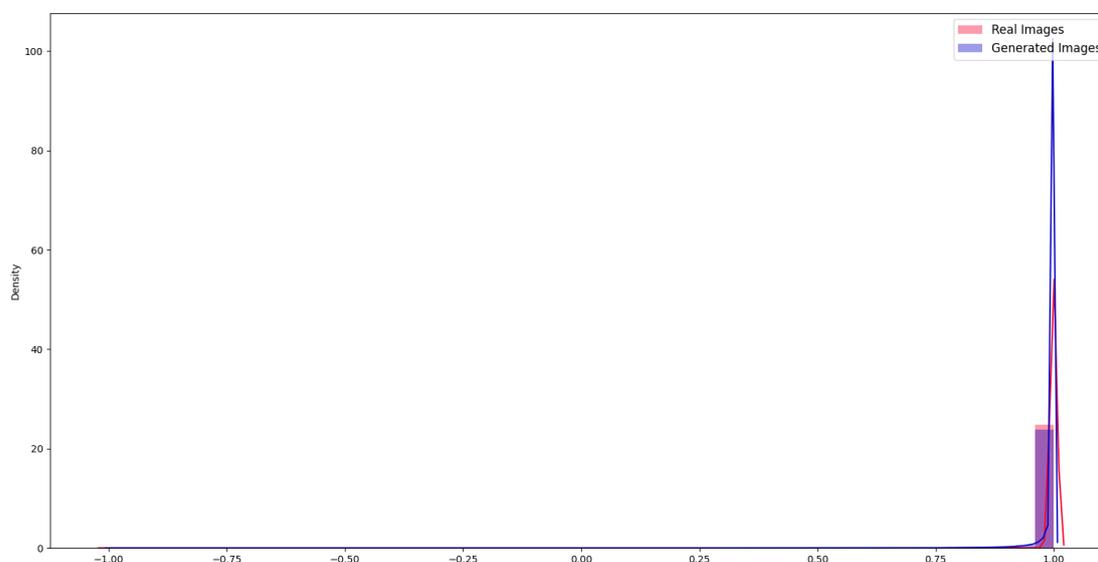


圖 28 生成圖像與真實圖像之分佈情形

### (3) DCGAN 損失函數

GAN 的訓練過程不容易進行，因為損失函數的每個梯度下降趨勢都可能改變。GAN 的另一個常見訓練失敗情形稱為模式崩潰。這代表 GAN 的生成模型難以學會複雜的真實數據，且被陷困在一個極低多樣性的小空間，使鑑別模型無法正確識別生成模型產生之生成數據。

生成模型和鑑別模型的目的相反，此消彼長。損失函數較不易降低至收斂狀態，對於生成模型，其損失函數下降快，很有可能是鑑別模型學習效果不佳，導致鑑別模型將生成模型產生之生成數據鑑別為真實數據。對於鑑別模型，其損失函數下降快速，意味著鑑別模型學習效果佳，也說明了生成模型的生成數據分佈不夠接近真實數據

分佈，使得鑑別模型能輕易判別，導致損失函數下降迅速。無論是鑑別模型，還是生成模型，損失函數的高低無法直接表示模型的好壞，在 GAN 裡，損失函數往往是不斷波動的。

依據圖 29 得知，DCGAN 於訓練起始這段期間，生成模型損失值振幅波動較劇烈，其原因為生成模型數據之分佈與真實數據之分佈仍然有很大的差異。訓練中期階段，生成數據之分佈逐漸趨近於真實數據之分佈，最後，模型訓練結束後，生成模型損失約落在 2 到 0.3 之間，鑑別模型損失趨近於 0.5，以上論述說明訓練過程。

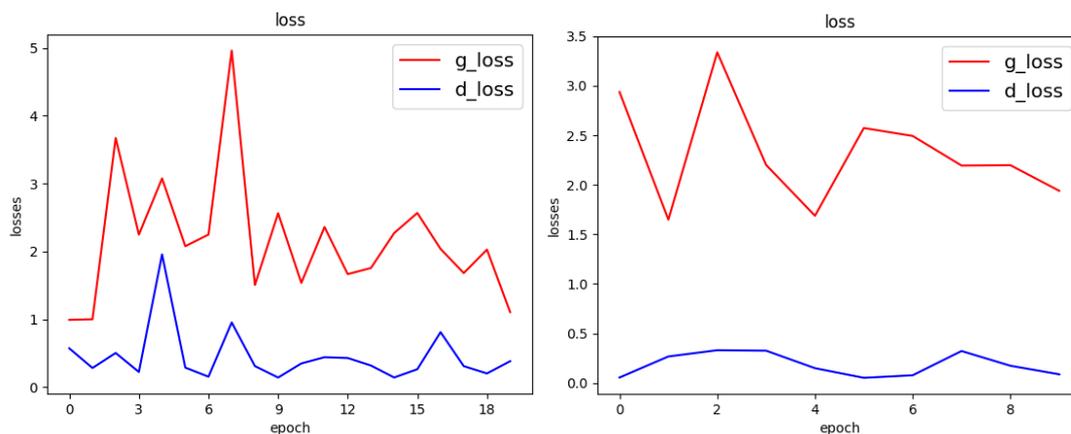


圖 29 左圖為生成模型之損失趨勢，右圖為生成模型之損失趨勢

模型對 PRPD 模式特徵提取的細節，不同 epoch 數量的輸出圖像，如圖 30 所示。隨次數增加，影像越擬合實際 PRPD 特徵。一開始提取 PRPD 模式的粗略特徵，例如邊緣和空白區域。從實驗結果來看，PRPD 模式的特徵提取成功完成，從而看出 GAN 的表現。

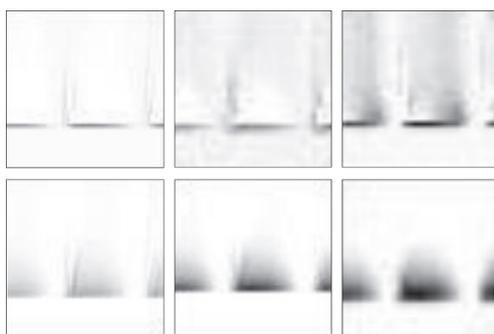


圖 30 GAN 訓練過程擷取，epoch 低到高

## 2.9 變壓器局部放電人工智慧自動辨識 PRPD 圖之訓練

本節著重介紹本研究 PRPD 故障的辨識訓練方法。提出透過利用基於 CNN 深度學習模型進行提取電力變壓器的 PRPD 故障特徵，加入上一節 GAN 所生成的影像，選取適當模型後進行資料處理及訓練獲得結果。

### 2.9.1 PRPD 辨識模型

近年來，捲機神經網路(CNN)在人工智慧領域中普及應用於識別影像領域，並且具有優秀的特徵學習。在局部放電的研究領域中，常使用 CNN 來辨識 PRPD 圖像特徵。CNN 深度學習模型基本是由輸入層、隱藏層和輸出層組成。卷積、池化和激活函數包含在隱藏層中。

CNN 發展至今已有許多研究者提出不同的深度學習模型架構，演化過程不斷進步。殘差神經網路(Deep Residual Neural Network, ResNet) [7]可以說是近年經典的 CNN 模型。

神經網路若增加深度，可增強學習能力，所以更深的模型不應比

更淺模型產生更高的錯誤率，而此問題原因是梯度消失或者梯度發散，使得模型開始訓練時不易收斂。然而，此問題能透過標準初始化(Normalized initialization)和批量歸一化解決，但是深度神經網路於訓練期間，開始收斂的過程中，卻產生退化問題(Degradation problem)。

因此，針對更深的模型提出解決方案，其方案為恆等映射(Identity mapping)。恆等映射是繞過前面一些隱藏層的輸出，直接連接到後面隱藏層的輸入，如圖 31 所示。由於殘差學習與直接學習原始特徵相較之下更加容易，故此，假設幾層堆積而成的神經網路的輸入為 $x$ ，則所學習到的特徵為 $H(x)$ ，為了讓神經網路學習到殘差 $F(x)=H(x)-x$ ，因此將殘差加到輸入中學習 $F(x)+x$ ，但是若訓練期間殘差為 0 時，而堆積層只會進行恆等映射，以維持神經網路學習成效，且此方法能讓堆積層在輸入特徵基礎上學習到新的特徵，從而擁有更好的學習成效。

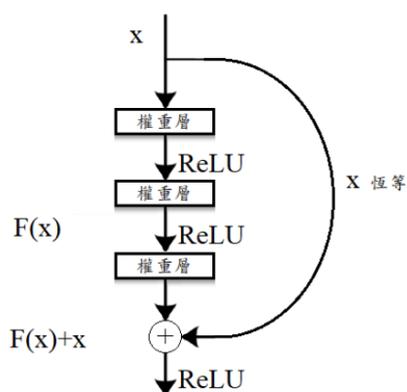


圖 31 殘差學習示意圖

ResNet-50 模型架構，如下圖 32 中間的結構所示。可以分成以下

幾個部分，組合後共 50 層。

- (1) conv1：卷積核 7×7，共 1 層。
- (2) conv2\_x：由卷積核 1×1，卷積核 3×3，卷積核 1×1，組成一個區塊，疊 3 次，共 9 層。
- (3) conv3\_x：由卷積核 1×1，卷積核 3×3，卷積核 1×1，組成一個區塊，疊 4 次，共 12 層。
- (4) conv4\_x：由卷積核 1×1，卷積核 3×3，卷積核 1×1，組成一個區塊，疊 6 次，共 18 層。
- (5) conv5\_x：由卷積核 1×1，卷積核 3×3，卷積核 1×1，組成一個區塊，疊 3 次，共 9 層。
- (6) output：由池化層+全連接層+softmax 組成，共 1 層。

由幾個堆疊的卷積區塊和恆等區塊組成，共有 49 個卷積層和 1

個分類層。使得 ResNet-50 在處理圖像分類具有出色的性能[50]。

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		$1.8 \times 10^9$	$3.6 \times 10^9$	$3.8 \times 10^9$	$7.6 \times 10^9$	$11.3 \times 10^9$

圖 32 ResNet 模型架構[7]，ResNet-50 為中間之架構

## 2.9.2 訓練資料預處理

本研究訓練資料預處理先經過歸一化後進行數據增強。直接輸入原始影像的情況下訓練結果容易呈現過擬合，因此將影像資料進行數據增強過程。而且當訓練數量過少時，更容易出現問題。為了避免

訓練模型結果對某些 PRPD 圖上特定局放訊號的位置過度擬合，因此此在進行輸入模型前先對它做調整。

由於 PRPD 影像之 x 軸及 y 軸精準的代表著角度及放電大小，因此不適合將整張影像進行旋轉、水平平移及縮放，影響到辨識重要的特徵參數。但我們可以透過垂直平移來去進行數據增強，移動幅度設定在正負 30 像素。

### 2.9.3 CNN 訓練結果

本次的訓練所使用的資料集數量如下表 3 所示，本次要透過將訓練集與驗證集加入生成資料，並於在測試集不考慮生成資料進行測試。調整適當的模型訓練參數，使損失可收斂，且收斂速度較快，達到較高的準確率，模型的訓練參數 Batch 大小設定 128，Step 設定為 5000。

表 3 資料集之數量表

設備狀態	訓練集		驗證集		測試集
	原始資料	生成資料	原始資料	生成資料	原始資料
雜訊	102	1000	13	100	13
電暈	537	1000	67	100	67
內部	588	1000	73	100	73
外部	384	1000	48	100	48
<b>總數</b>	<b>5611</b>		<b>601</b>		<b>201</b>

觀察損失函數的訓練過程模型，其損失以及準確率如下圖 33 所示，在此可發現損失在約一千個 Step 左右即可有效地收斂，並且也於驗證集也進行相同的訓練過程而有效收斂，並在結果無過擬合的現象，因此在訓練集與測試集皆有好的表現及結果。

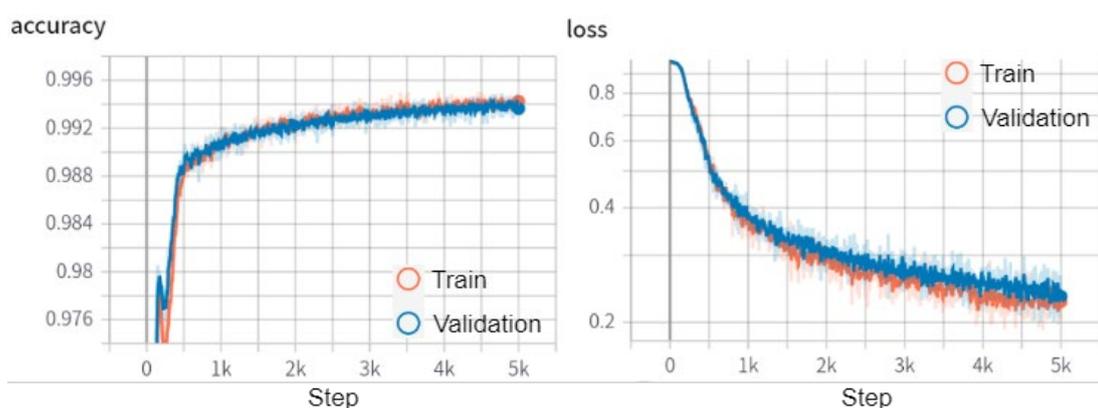


圖 33 訓練過程之損失與準確率

## 2.10 變壓器局部放電人工智慧自動辨識 PRPD 圖之整合測試

本計畫將此功能置於歷史查詢頁面中，可依使用者選取在意的時間區間資料。首先進入歷史查詢介面，如下圖 34，查詢過去的放電資料。選取感測器編號、紀錄類型、起始日期時間、結束日期時間，最後勾選計算 PRPD (相位解析圖)，進行查詢。

局部放電監視系統

電力單線圖 警報數趨勢 系統架構圖 編號對照表 即時資訊 歷史查詢 排名前10名 即時警報 歷史警報 警報設定 報表列印

選擇條件

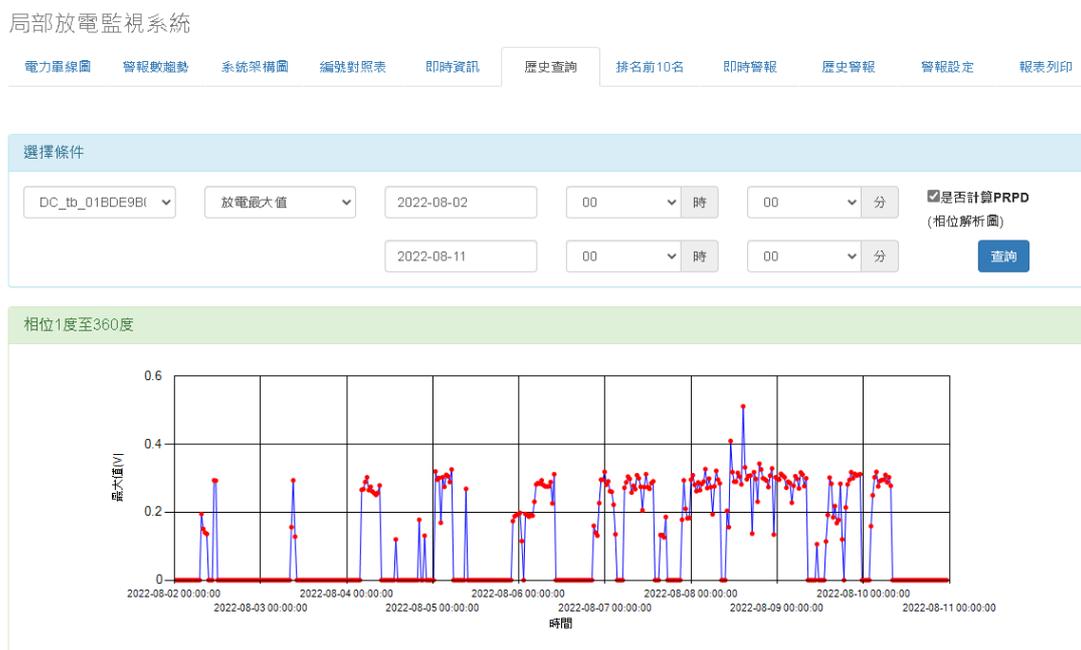
DC\_lb\_01BDE9Bf 放電次數 起始日期 00 時 00 分  是否計算PRPD (相位解析圖)

結束日期 00 時 00 分 查詢

圖 34 歷史查詢介面

紀錄類型主要分為兩種可進行繪製 PRPD，放電最大值及放電平均值。由於放電感測器接收的高頻率速度太過於精密，對於之後轉換成影像的部分不需要過多的細節像素。取一短時間的所接收到的資料進行觀察最大值或是平均是較佳的方式。

選取接收到局部放電的時間區間，經過查詢後，可獲得以時間作為橫軸，縱軸為放電大小的趨勢圖，如圖 35 所示。此外，也顯示區分四象限的趨勢圖(相位 1 度至 90 度、相位 91 度至 180 度、相位 181 度至 270 度、相位 271 度至 360 度)，方便做進一步的觀察分析，如圖 36 所示。



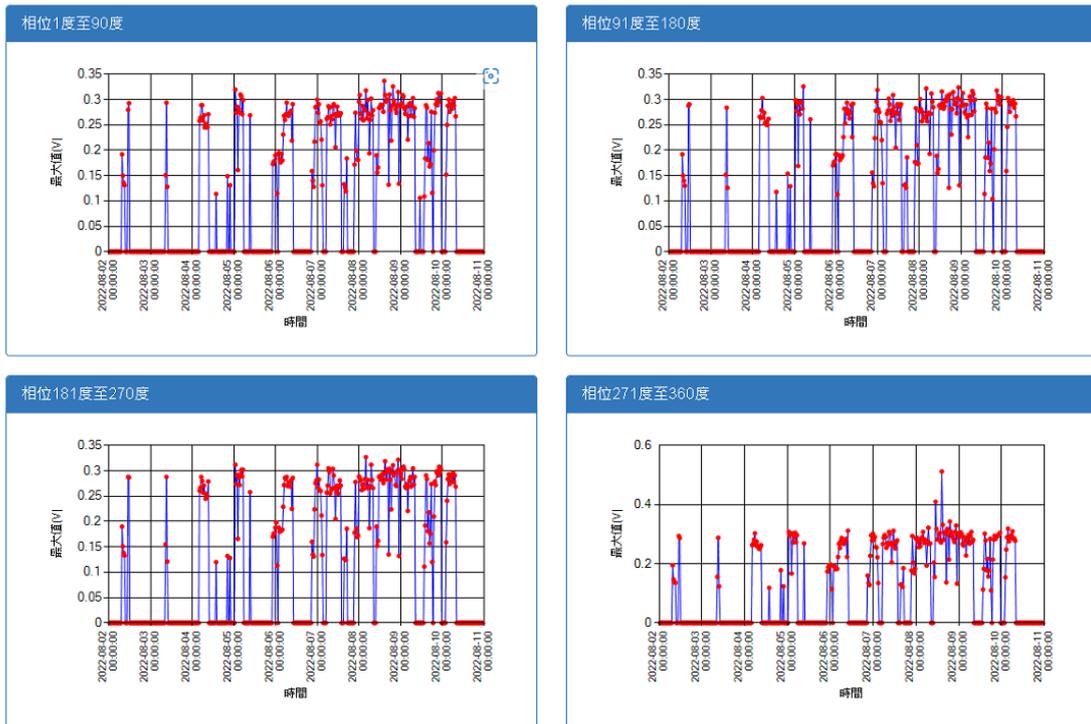


圖 36 四象限的局部放電趨勢圖

在 PRPD 圖畫面中，顯示選取該段時間區間的放電資料進行繪製相位解析圖譜，如圖 37 所示。可按右上角之智慧辨識按鈕進行此 PRPD 圖的 AI 辨識功能。等待演算法辨識出來後，辨識結果將顯示於右上角空格中，完成此次的辨識結果，如圖 39 所示。

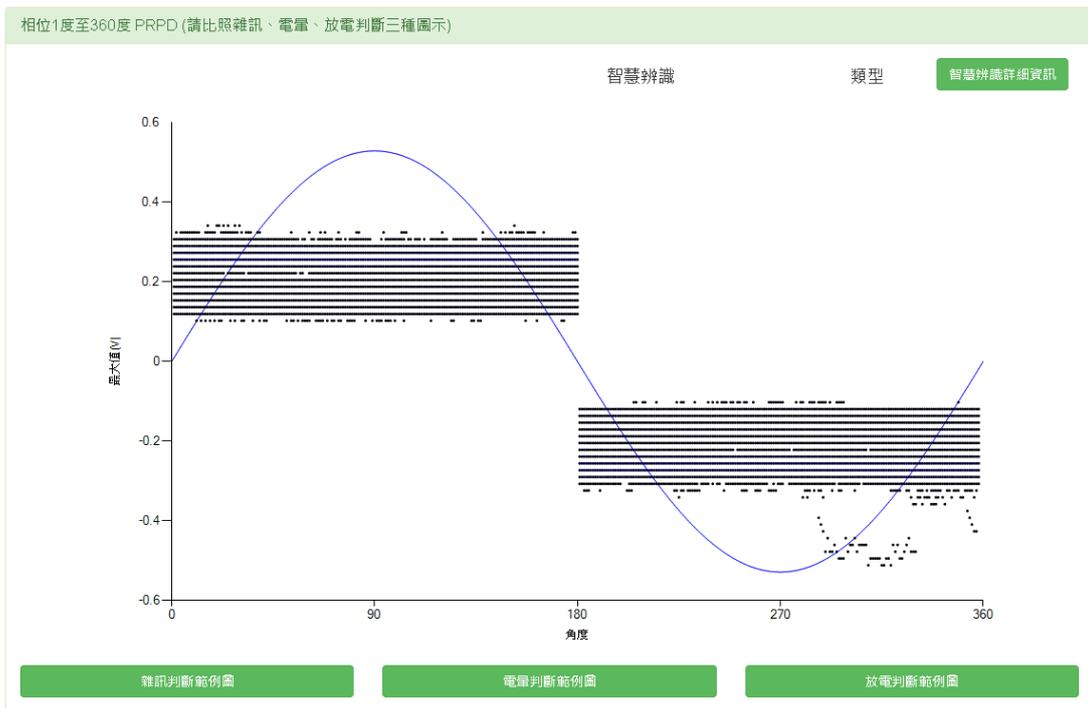


圖 37 PRPD 顯示兼智慧診斷辨識畫面

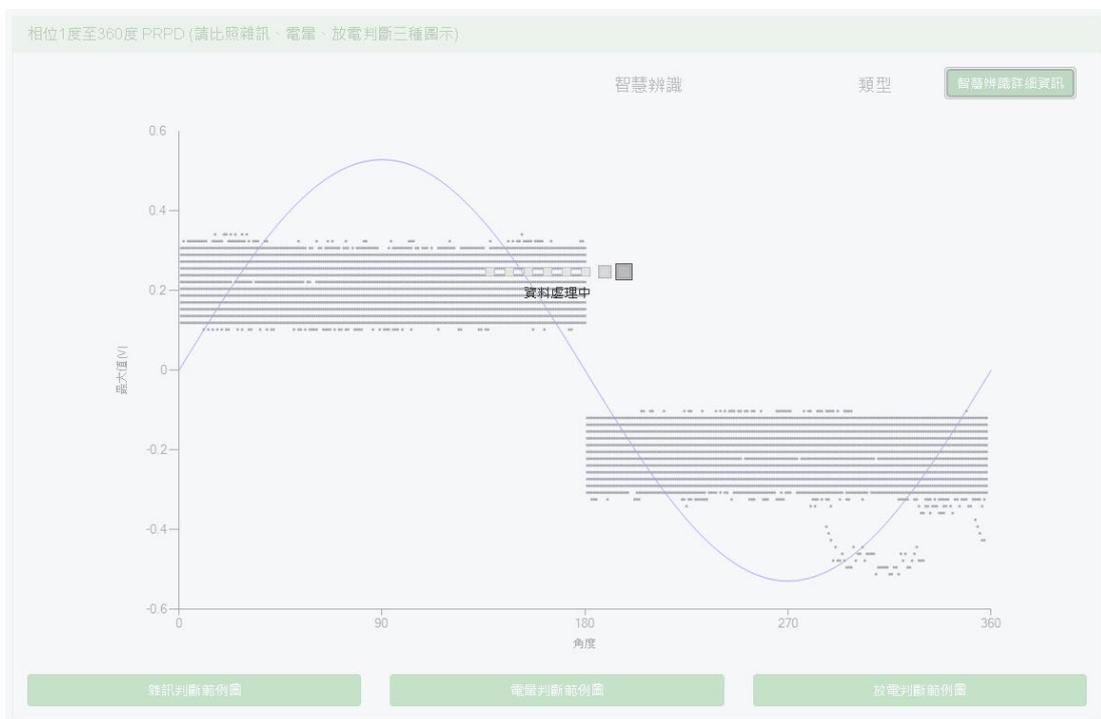


圖 38 智慧診斷辨識等待中之畫面

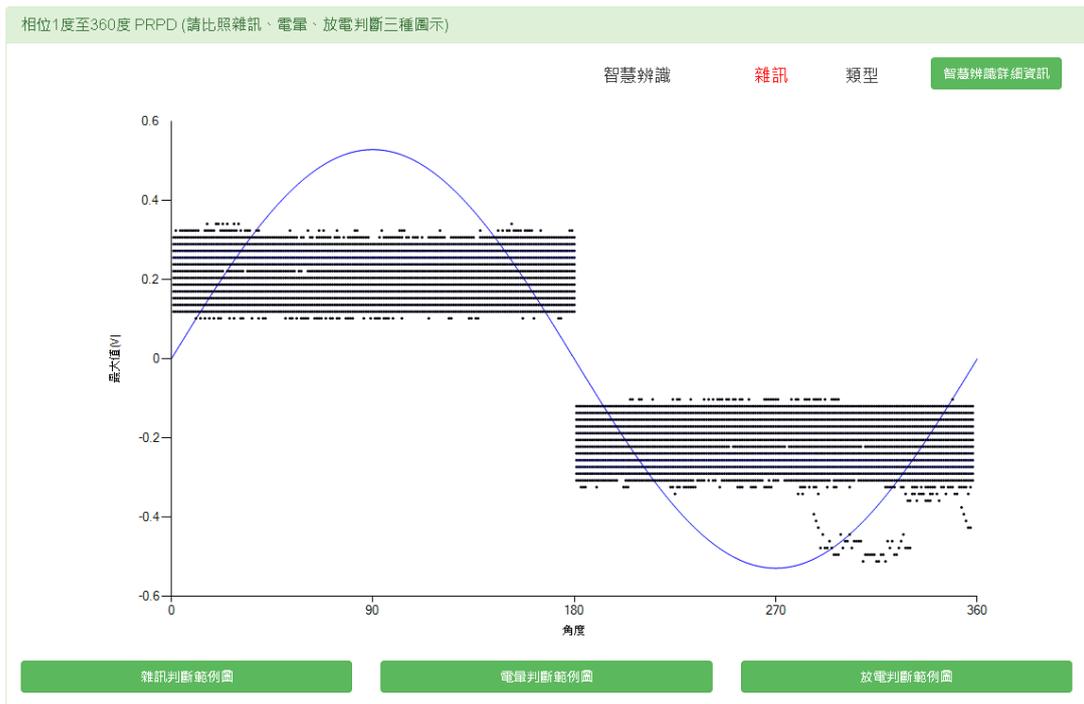


圖 39 歷史查詢介面

亦可以選取單筆放電資料或是少數幾筆資料進行觀察，如圖 40 所示。選取該筆放電之時間區間進行查詢並辨識，如圖 41 所示。

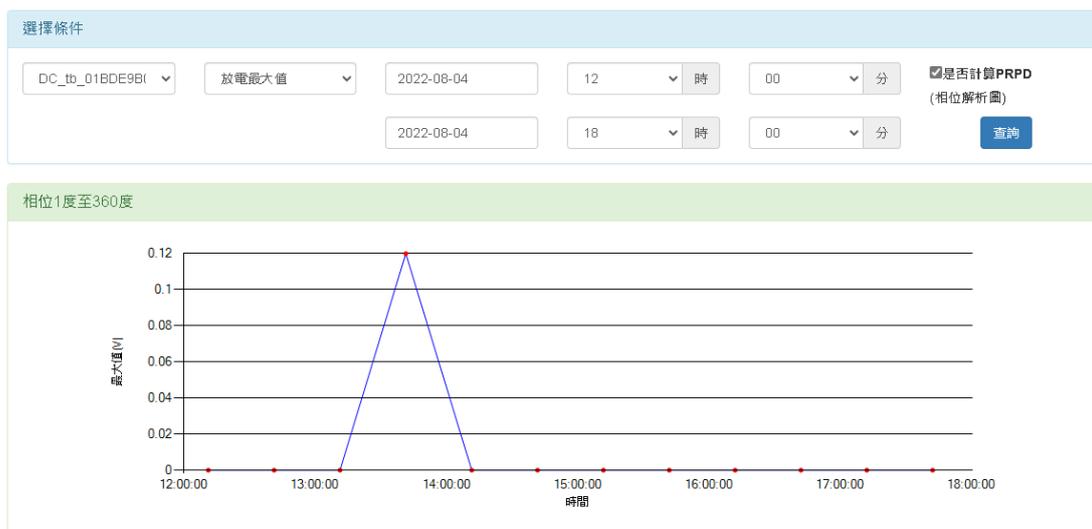


圖 40 進行單筆放電觀察示意圖

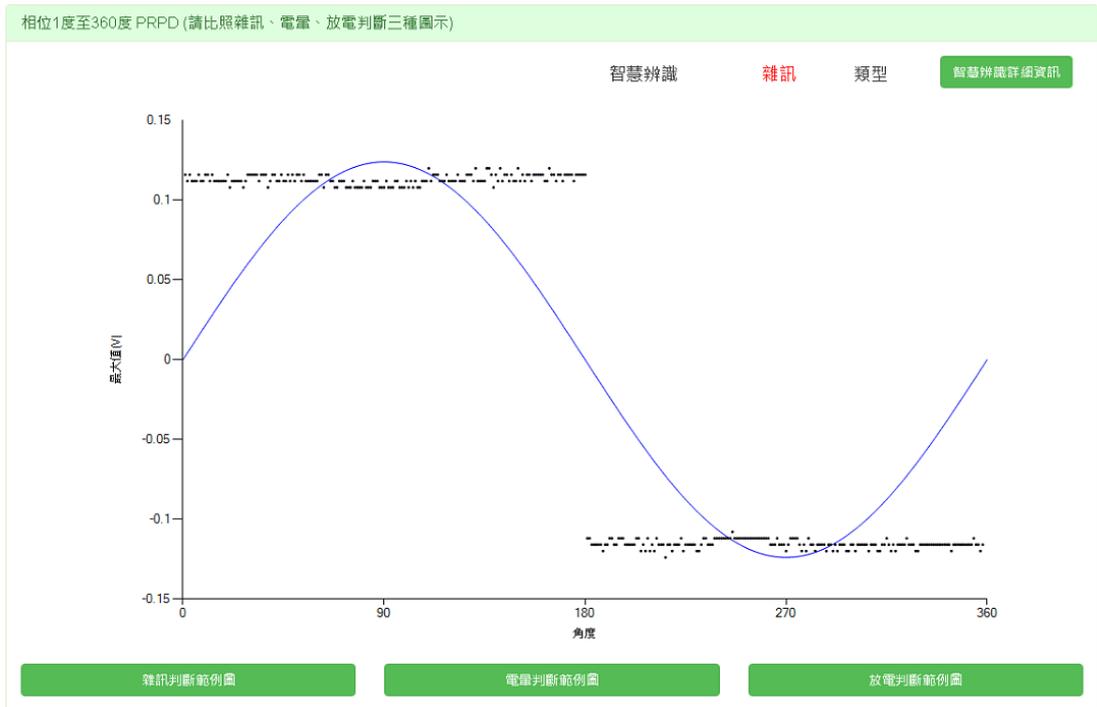


圖 41 PRPD 之放電智慧辨識示意圖

### 三、 結論與討論

#### 3.1 結論

本計畫建立一套變壓器局部放電人工智慧故障診斷系統，針對油浸式變壓器進行線上之局部放電量測，並將之轉為可用來評估變壓器故障類型的 PRPD 圖，輔以人工智慧深度學習的技術進行辨識及訓練，透過生成對抗網路及捲積神經網路進行資料生成及辨識，加速對於判斷設備異常的準確性，確保電力設備可靠的運行，降低維護費用，並提高安全性與穩定供電，避免未知的故障所引起的用電中斷現象，以掌握變壓器運轉狀態，進而後續可針對變壓器之健康狀態進行智慧診斷技術之開發研究。

此外，本計畫培育出具有變壓器故障診斷及運轉狀態監測評估的專業技術人才，這些學生畢業後，對國內電機產業界有相當大的貢獻，對於檢測設備自製國產化，提升國內檢測技術之發展，亦可有長足之推升。

#### 3.2 後續應用及發展

本計畫之研究已研發出透過深度學習神經網路建立之智慧診斷局部放電信號技術。後續可進一步對此技術提出進行延伸應用開發，在局放監測系統中可擴展使用情境及方式。如：結合滾動式即時檢測告警功能，與使用者提高相對應輔助，提高辨識頻率並結合既有告警系統規則。其目的為能夠完善發揮人工智慧的協助應用，帶來提

高電力的系統穩定及可靠度。

## 參考文獻

- [1] 邱敏彥、李長興、黃智賢、吳明學、曾威能，「應用 UHF 技術檢測高壓設備局部放電」，中華民國第二十七屆電力工程研討會，台灣新竹，2006 年 12 月
- [2] A. Cavallini, G.C. Montanari, and G.C. Montanari “Partial Discharge Analysis and Asset Management: Experiences on Monitoring of Power Apparatus” 2006 IEEE PES Transmission and Distribution Conference and Exposition Latin America, Venezuela
- [3] Sonia Barrios, David Buldain, María Paz Comech, Ian Gilbert and Iñaki Orue “Partial Discharge Classification Using Deep Learning Methods—Survey of Recent Progress”
- [4] J. Tanha, Y. Abdi, N. Samadi, N. Razzaghi and M. Asadpour, “Boosting methods for multi-class imbalanced data classification: An experimental review,” J. Big Data, vol. 7, no. 1, pp. 1-47, Dec. 2020.
- [5] V. Sampath, I. Mourtou, J. J. A. Martín and A. Gutierrez, “A survey on generative adversarial networks for imbalance problems in computer vision tasks,” J. Big Data, vol. 8, no. 1, pp. 1-59, Dec. 2021.
- [6] B. Tang, Y. Tu, Z. Zhang and Y. Lin, "Digital Signal Modulation Classification With Data Augmentation Using Generative Adversarial Nets in Cognitive Radio Networks", IEEE Access, vol. 6, pp. 15713-15722, Mar. 2018.
- [7] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," in 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016 pp. 770-778.