

行政院原子能委員會
委託研究計畫研究報告

配電級綠能與需量排程之研究

**Study on Switching Scheme of Distribution Networks Considering
Green Energy and Demand Response**

計畫編號：109A010

受委託機關(構)：國立彰化師範大學

計畫主持人：黃維澤

聯絡電話：04-7232105#7264

E-mail address：vichuang@cc.ncue.edu.tw

協同主持人：

研究期程：中華民國 109 年 01 月至 109 年 12 月

研究經費：新臺幣 78 萬元

核研所聯絡人員：蔡佳豪

報告日期：109 年 11 月 19 日

目 錄

目 錄	I
中文摘要	1
英文摘要	2
壹、 計畫緣起與目的	3
一、 計畫緣起.....	3
二、 計畫目的.....	4
三、 文獻探討.....	5
貳、 研究方法與過程	9
一、 整合氣象、負載與再生能源之精進預測演算法	9
(一) 長短期記憶(LSTM)	9
(二) 極限梯度提升(XGBoost).....	10
二、 饋線負載關聯性分析	11
(一) 沙普利值分析(SHAP).....	11
(二) 用電模型設定.....	13
(三) 多項式模型設定.....	13
三、 整合 FTU 資料與需量反應用戶之精進潮流解析	14
(一) 區域配電網參數、負載與再生能源資料蒐集.....	14
(二) 基於 FTU 資料之精進饋線三相電力潮流解析	22
(三) 需量反應用戶方案模組建立.....	22
四、 正常運轉下最佳饋線重組與負載相位配置	24
(一) 多目標函數規劃.....	26
(二) 強化學習最佳化演算法.....	28
(三) 放射狀拓撲辨識.....	32
(四) 軟體架構與整合平台	33
參、 主要發現與結論	36
一、 饋線負載預測與關聯因子分析結果	36
(一) 預測結果.....	36
(二) 多項式函數測試結果.....	37
(三) 關聯因子分析結果.....	39
二、 整合配電網線能與需量之饋線重構與負載換相最佳化模組與結果 .	
.....	40

三、	結論.....	46
肆、	參考文獻.....	49

中文摘要

本計畫建立一系統化饋線自動開關切換排程，其目的為降低饋線上分散式再生能源高滲透與需量用戶參與需量反應方案對區域配電網之衝擊與影響，因此擬訂進行配電級綠能與需量排程之研究。首先，廣泛蒐集彙整整合綠能高滲透與需量反應作法用以提高區域配電網運轉效能之相關文獻，作為本計畫後續研究參考；其次，擬定以 Python 為基礎建立模擬分析平台，包含資料庫系統、預測程式模組、電力潮流解析模組與最佳化程式模組；最後，藉由所開發之平台匯入區域配電網負載資料與氣象資料於 SQLite 資料庫，並利用 OpenDSS 建立電網模型，再以深度學習與最佳化演算法透過所建置之平台進行饋線負載與綠能關連性分析、負載最佳相位配置，以及饋線重組最佳開關切換排程，用以降低綠能併網與需量反應負面衝擊、提高對配電網正面的助益，進一步由下而上提高饋線、區域配電網至輸電網運轉穩定度，最終以群聚效應方式提高電力系統整體運轉安全性。本計畫研究成果除了可以強化變電所與饋線自動化功能外，亦可整合至需量反應與再生能源運轉策略相關研究。

英文摘要

This project aims to establish a systematic feeder automatic switching scheme for reducing the impact of distributed renewable energy high penetration and demand users' participation in the demand response program in the regional distribution networks. Therefore, a research on switching scheme on green energy and demand response in distribution networks is planned. Firstly, the relevant researches related to the integration of high penetration of distribution green energy and demand response to improve the operation efficiency of the regional distribution networks has been extensively collected as the following research reference for this project; secondly, it is proposed to build a simulation analysis platform based on Python, including a database system, forecasting program module, power flow analysis module, and optimization program module; finally, the load and weather data of the regional distribution networks was imported into the SQLite database through the developed platform, and the OpenDSS is used to build the grid model. Then the deep learning and optimization algorithms are also be applied to analyze the relationship between feeder load and green energy through the built platform, the optimal phase arrangement of the three-phase loads, and the optimal switching scheme for feeder reorganization. And it is to reduce the negative impacts of green energy connected to distribution networks and demand respond programs participated by customers; consequently, it is to improves positive benefits to the distribution network; furthermore, it is helpful for improving the operation stability of feeders, regional distribution networks to the transmission networks from bottom to top, and finally to improve the overall operating security of the power system by clustering effect. Besides, the substation and feeder automation functions are also be enhanced, the outcomes of this project can also be integrated into related research on demand response and renewable energy operation strategies.

壹、計畫緣起與目的

一、計畫緣起

隨著電力系統的演化與發展，區域配電網結構愈趨複雜，除了分散式再生能源與需量反應用戶造成的負載結構多樣化，饋線結構也隨著自動化饋線開關使得運轉上靈活性與日俱增。自動化饋線開關操作上通常以 2 個以上為單位，分為聯絡開關(Tie Switch, TS)以及分段開關(Disconnecting Switch, DS)，藉由開關啟閉操作進行負載轉供並保持配電饋線為放射狀。其主要用於發生永久性故障(Permanent Fault)時，搭配故障偵測器(Fault Detector)，可快速排查隔離故障並恢復部分無故障電網供電，達到節省人工巡查成本與增加復電速度與復電區域的效果。此外，在正常運轉情況下，當饋線尖峰負載過高時，例如：台灣夏季預期外的大量空調用電，造成部分饋線異常重載，故需即時切換轉供；或者當系統需要緊急卸載時，可將重要負載(如醫院等)切換轉移至其他饋線；再者，隨再生能源的大量併網，饋線上上群聚大量太陽光電發電系統所發電力可被轉供至相對時間下其他尖峰需量過高之饋線；除此之外，近年來(特)高壓用戶參與計畫性與臨時性需量反應，以及需量競價等方案，在尖峰用電與系統發生運轉可靠度期間抑低用電已舒緩供電瓶頸亦可能造成區域配電網內饋線負載分布不均，此時可透過開關切換達饋線負載均勻分布。

綜合上述，除了緊急饋線調度，自動化饋線開關提高了電網操作上的靈活度，使得系統可靠度隨之上升，透過自動化饋線開關操作在一般運轉情形下可發揮更大作用，如將相同或不同變電所之饋線相互轉移，平衡各饋線負載需求量，不僅降低尖峰需量過高與電壓過低的情形，亦提高負載因數(Load Factor)與參差因素(Diversity Factor)，以及饋線末端電壓，提高供電品質，使系統運轉狀態更佳。此外，饋線相互轉移亦可使三相負載更趨於平衡，是除了調整變壓器相別外另一個利用電網結構降低不平衡率的方法，且自動化饋線開關可無停電(Interruption free)遠端操作，相比調整變壓器相別需人工現場作業，其操作靈活度更高。而更智慧化的做法為，將以上兩者相互協調，計算所有變壓器相別以及自動化饋線開關切換排程，促使整體系統損失下降，以及降低饋線出口中性線電流預防保護電驛誤

動作的結果。

然綜觀饋線自動化開關操作對於系統緊急或正常運轉下雖都有卓越的貢獻，但在操作上仍有相關限制，比如在無停電的饋線轉供操作過程中，兩者之電壓大小、相角差過大的情形下，併聯瞬間可能產生異常暫態電流，而使變電所過流接地電驛動作，致全饋線停電。故台電「配電工程無停電施工作業推行要點」第六點明確規範：「饋線併聯轉供之實施，轉供點開關之各相對相之相角差應在十度以內，及電位差在額定之百分之十範圍內為原則，必要時在現場實施測定」。

綜上所述，自動化饋線開關賦予調度中心在運轉手段上有更多元的選擇，在台電調度中心，配電負載轉供可分為定期轉供與不定期轉供。定期負載轉供是以降低系統損失、提升系統運轉穩定為目的，以及變電所電力設備定期檢修時，將其負載轉移至其他變電所之手段；而不定期負載轉供則以縮小停電區域範圍及儘速復電為原則。而定期負載轉供搭配配電變壓器相別調整，可有效提高負載因素、參差因素、三相平衡度，以及饋線末端電壓，然而兩者間的相互關係複雜，在最佳運轉配置決定上不容易，台電目前亦缺乏較有系統性的整合方式，此即本計畫之研究目的。

二、計畫目的

台電配電變壓器相別調整操作習慣為以一個月為週期，區處以人工調閱報表的方式決定相位配置；而饋線開關轉供部分則由調度中心統籌，視情況進行饋線結構重整，達到系統更有效的運轉結果。上述兩者若有一套系統性的整合平台，將鄰近之各變電所、饋線，以及負載預測資料建模，再以負載因素、參差因素、饋線末端電壓、不平衡率等作為最佳化目標，並以饋線電壓以及併聯轉供電壓大小與相位差等作為限制，再利用演算學習法求解一個月的配電變壓器相別調整，以及各時段饋線開關的切換排程，使得系統有明確性、規劃性的得出最佳運轉方法，達到系統運轉效能提升、總損失下降，以及降低保護電驛誤動作等結果。

故本計畫提出一最佳化模擬平台，其架構圖如圖 1 所示。首先由台電蒐集負載歷史資料以及中央氣象局或氣象風險公司獲取氣象資料，於 Python 開發三相

負載預測程式，並與台電提供之饋線資料建立 OpenDSS 配電網模型。接著於 Python 開發最佳化演算法程式，呼叫 OpenDSS 模型改變結構以及計算電力潮流，並以前述之電網限制與目標函數，計算出建議之配電變壓器相別配置與饋線開關切換排程，以供台電運轉參考。




圖 1 本計畫架構圖

三、文獻探討

由前章所述，本計畫團隊提出區域配電網最佳化運轉整合模擬分析平台，其旨在：

1. 以大數據方式預測區域配電饋網路各區負載，並以配電系統模擬軟體建立模型，以利系統模擬開發；
2. 因應台電區域配電網上現有之饋線開關，以最佳化學習演算法估算開關切換排程，達到系統最佳運轉結果；
3. 除了開關切換排程，亦結合配電變壓器相別配置方法，兩者再演算出最佳配置與排程結果。

本研究的核心在於最佳化演算法的建立，使錯綜複雜的配電網結構與相位重

新配置之問題可有效求解。常見相關文獻通常針對單一問題、單一饋線，或者單一時間點進行最佳化演算，本研究整合各方面問題求解，雖較複雜但演算法精神類似，表 1 列舉國內外關於配電系統結構、相位最佳化重新配置之文獻，以及其使用之演算法。

近年來，隨著 GPU 的蓬勃發展，提升電腦運算速度，機器學習(Machine Learning, ML)亦受到高度重視，大至跨國大企業，小至新創公司紛紛投入研究。人工智慧(Artificial Intelligence)與大數據(Big Data)在現今社會已幫助解決數不清的問題，如智慧助理、辨識系統、模型預測、模型學習、自動規劃等。近年深度強化學習(Deep Reinforcement Learning, DRL)技術因 Google™ DeepMind 開發之 AlphaGo 戰勝人類棋王後[8]，熱度持續升溫，表 1 中[5]使用 DRL 推導機組與聯絡線路最佳排程問題。強化學習(Reinforcement Learning, RL)是機器學習中的一個領域，強調如何基於環境而行動，以取得最大化的預期利益。本計畫研究問題數據龐大、結構複雜，使用一般搜尋演算法顯得較漫無目的，而 RL 在學習過程中計算搜尋路線獎勵(Reward)分數，預期可達到更易收斂且更有效的演算結果，且 Google™ DeepMind 深耕 DRL 多年，亦開發多種開源工具供人使用，再研究上亦較容易上手。近年 RL 於電網最佳化演算亦開始嶄露頭角，其國內外相關文獻列舉於表 2。

表 1 國內外配電系統結構、相別最佳配置相關文獻

編號	文獻題目	內容簡介
[1]	On Robust Tie-Line Scheduling in Multi-Area Power Systems	以多參數線性規劃(Multi-parametric Linear Programming)推導聯絡線路排程問題。
[2]	Enforcing Intra-Regional Constraints in Tie-Line Scheduling: A Projection-Based Framework	根據投影理論，以頂點逼近枚舉演算法(Progressive Vertex Enumeration Algorithm)計算聯絡線路潮流注入之允許範圍。
[3]	Decentralized Multiarea Robust Generation Unit and Tie-Line Scheduling Under Wind Power Uncertainty	考慮風機不確定性，以交替最佳化過程(alternating optimization procedure)推導區域電網機組與聯絡線路排程。

[4]	Optimal network reconfiguration in distribution system for loss reduction and voltage-profile improvement using hybrid algorithm of PSO and ACO	以混合粒子群-蟻群最佳化演算法(Hybrid PSO-ACO Algorithm)進行饋線結構重組，降低系統損失與改善電壓分佈。
[5]	Deep Reinforcement Learning-Based Tie-Line Power Adjustment Method for Power System Operation State Calculation	使用深度強化學習(Deep Reinforcement Learning)估測最佳運行狀態，以之調整聯絡線路與機組發電量。
[6]	應用免疫算法於配電系統運轉策略之研究	以免疫演算法推導最佳線路開關操作策略及過載事故時之操作策略。
[7]	應用停限電運轉圖資系統支援配電饋線三相不平衡分析與改善	利用啟示性規則演算法推導分岐線及配電變壓器之相位調整策略，以改善三相不平衡。

表 2 強化學習用於配電系統最佳化之相關文獻

編號	文獻題目	內容簡介
[5]	Deep Reinforcement Learning-Based Tie-Line Power Adjustment Method for Power System Operation State Calculation	使用深度強化學習(Deep reinforcement learning)估測最佳運行狀態，以之調整聯絡線路與機組發電量。
[9]	A Reinforcement Learning Approach to Solve Service Restoration and Load Management Simultaneously for Distribution Networks	以強化學習中的 Q-learning 估算電網故障時最佳的開關切換隔離復電方式。
[10]	Data-Driven Load Frequency Control for Stochastic Power Systems A Deep Reinforcement Learning Method With Continuous Action Search	以深度強化學習來應對再生能源的不確定性，基於無模型(Model free)學習負載頻率控制方式。
[11]	Enhancing Power Quality in Microgrids With a New Online Control Strategy for DSTATCOM Using Reinforcement Learning Algorithm	提出基於強化學習的靜態電壓補償器(STATCOM)在線控制策略，解決不平衡、故障暫態自癒之問題。
[12]	Multiagent-Based Reinforcement Learning for Optimal Reactive Power	基於多重代理人之強化學習演算法，計算兩代理人間最佳虛功調度

	Dispatch	協調。
[13]	Reinforcement Learning Based Real-Time Wide-Area Stabilizing Control Agents to Enhance Power System Stability	提出即時分散控制結構，以強化學習之 Q-learning 演算合適的激磁控制，提高系統穩定度。

貳、 研究方法與過程

近年來電力負載預測之結果，應用在許多不同場合，如電力公司資訊網頁、電力潮流調度控制、配電系統調度維護最佳化[14]與綠色能源設備投資[15-17]等應用。台電亦成立整合大數據系統，計算出當時負載調度曲線供電力調度處參考。除要求實際與預測出的負載曲線吻合，亦需要減低預測所需之計算資源並且分析其組成之因子。較低之預測時間可採用較低成本之計算硬體；瞭解組成因子能掌握負載變動的趨勢。隨著資料儲存媒介與技術興起，電力設備與負載等資訊均能儲存供參考，傳統的統計法如迴歸分析，例如：ARIMAX，以及狀態方程式法，例如：Kalman 等，均有其實務應用的挑戰，前者為無法得知其組成因子；後者為狀態方程式的推導等挑戰。然而，機器學習(Machine Learning, ML)與數據資料的結合能夠分析出之標的模型，如股價趨勢等應用。本計畫採用之機器學習法之長短期記憶(Long Short Term Memory, LSTM) [15-17]與極限梯度提升(eXtreme Gradient Boosting, XGBoost)[5]等方法設計負載預測。並且採用沙普利值法(SHapley Additive exPlanations, SHAP)[18]分析預測模型之組成因子。

一、 整合氣象、負載與再生能源之精進預測演算法

機器學習通常思考成：分析歷史資料，取得其規則，達成人工智慧的方法。本研究採用的歷史資料為電力負載資料，取得其規則之方式分別為 LSTM 法與 XGBoost，達成人工智慧的目的且可當作後續的應用，如配電系統調度維護最佳化[1]等等。本章節將陸續介紹 LSTM 法與 XGBoost 法之背景與基本理論。

(一) 長短期記憶(LSTM)

LSTM 法為 Hochreiter[19]於 1997 年所提出，屬於機械學習內的深度學習分枝，特點是在神經單元內加入遺忘門(Forget Gate)，免除梯度消失等因傳統遞歸神經網路(Recurrent Neural Network, RNN)問題，如圖 2 所示。Ospina 等人亦提出以此法搭配穩定小波轉換(Stationary Wavelet Transform, SWT)取得 PV 發電之預測結果，與傳統 LSTM 法相比可減少約 30%的 RMSE 誤差，但增加約一倍的運算時間[4]。




圖 2 典型 LSTM 神經網路

數學表示式分別由(1)至(6)式所示，其中 b_i , b_f , b_o 與 b 表示為偏壓向量，記憶體單元 $\bar{c}_t$ 用用來儲存經由激活函數所得出之長期記憶參數，狀態變數 C_{t-1} 與 H_{t-1} 表示為前次疊代之記憶體參數與輸出向量。

$$i_t = \sigma(w_i H_{t-1} + U_i X_t + b_i) \quad (1)$$

$$f_t = \sigma(w_f H_{t-1} + U_f X_t + b_f) \quad (2)$$

$$o_t = \sigma(w_o H_{t-1} + U_o X_t + b_o) \quad (3)$$

$$\bar{c}_t = \tanh(w_c H_{t-1} + U X_t + b) \quad (4)$$

$$C_t = f_t C_{t-1} + i_t \bar{c}_t \quad (5)$$

$$H_t = o_t \tanh(C_t) \quad (6)$$

若有 $N(w)$ 個 LSTM 單元則整體所需記憶體，可以由(7)表示，用於計算機記憶體容量評估。其餘計算細節與程式編寫技巧，可參考 Brownlee 之說明[20]。

$$M = 4(N(w)(N(w) + 1) + N(X_t)N(w)) + N(H_t)(N(w) + 1) \quad (7)$$

(二) 極限梯度提升(XGBoost)

如前述之 LSTM 法，XGBoost 法亦擔任計算出負載模型之任務，但為監督式(Supervised)學習問題，利用多個特徵之輸入 x_i 來預測目標 $\hat{y}_i$ 並以(8-9)式表示。為一組分類與回歸樹(Classification and Regression Trees, CART)[21]

$$\hat{y}_i = \phi(x_i) = \sum_{j=1}^K f_j(x_i), f_j \in \mathcal{F} \quad (8)$$

$\mathcal{F}$ 屬於回歸樹樹枝 q 與之權重 $w_q(x)$ 。

$$\mathcal{F} = \{f(x) = w_q(x)\} \quad (9)$$

目標函數包含訓練誤差與其正則化，

$$\mathcal{L}(\phi) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (10)$$

$l(.)$ 為誤差損失函數與 $\Omega(.)$ 回歸樹之複雜度處罰函數[22]。

二、饋線負載關聯性分析

天氣因子對於饋線負載與再生能源有著密不可分的關係，在負載預測時透過因子關聯分析不僅可以驗證預測模型的有效性，亦可以分析饋線負載的組成成分，故本研究已 SHAP 法分析進行天氣因子與負載、再生能源之關聯性分析。因子表示法雖可知預測參數分析結果，並無法直覺地反映出影響因子間的相對貢獻度，故本計畫以統一因子(Unified Factor)集合至單一標準，轉換至相對性關係因子供直覺性參考。再者，不同的負載預測法則、訓練資料庫多少與設定等均會影響最後相對性關係因子的結果。較少的資料庫僅需較少的模型訓練時間，但降低結果之精確性。有其必要性在預測完畢後以標準化模型驗證出關係因子之誤差性，供最終資料交換時之參考。本計畫以多項式模型取得統一因子結果，作為評鑑之標準。

(一) 沙普利值分析(SHAP)

SHAP 被用於分解並分析預測模型中每個特徵的影響，Shapley 值是賽局理論(Game Theory)中使用的一種技術，用於解析合作賽局(Cooperative Game Theory)中每個玩家對其結果的貢獻程度。該理論由 Lloyd Shapley 於 1953 年提出，其以公平、合理的方式給予賽局理論嚴格的公式描述，使得賽局中擁有唯一公平的利益分配。而後 Shapley 值被用於解釋機器學習模型中每個局部輸入因子，具有對人工智慧的驗證與分析的強大功能。(11)為 Shapley 回歸值：

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F|-|S|-1)!}{|F|!} \left[f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S) \right] \quad (11)$$

$f(x)$ 為欲解釋的函式， F 為所有特徵的集合、 S 為 F 的一個子集，分別訓練 $f_{S \cup \{i\}}$ 與 f_S ，比較兩者差異後乘以一個期望因子，在所有不含第 i 特徵的子集 $S \subseteq F \setminus \{i\}$ 中計算該差異值並加總，便可得的 i 特徵之 Shapley 值，即為第 i 特徵貢獻於 $f(x)$ 之期望值。

而 SHAP 是以可加特徵歸因法(Additive Feature Attribution Method)計算 Shapley 值，簡單來說就是使用簡單的可解釋模型 g ，局部的解釋任意的複雜模型 f ，如(12)所示：

$$g(z') = \phi_0 + \sum_{i=1}^M \phi_i z'_i \quad (12)$$

其中， ϕ_i 為第 i 個特徵的影響程度， Z_i 為 0 或 1，代表該特徵是否出現在模型中。

在下列限定的 3 個性質下，SHAP 值會有唯一解：

1. 局部準確性(Local accuracy)：

$$f(x) = g(x') = \phi_0 + \sum_{i=1}^M \phi_i x'_i \quad (13)$$

表示每個特徵的重要度之和等於 $f(x)$ 的重要程度。

2. 缺失性(Missingness)：

$$x' = 0 \rightarrow \phi_i = 0 \quad (14)$$

表示缺失值對於特徵的重要度沒有貢獻。

3. 一致性(Consistency)：

對任意兩模型 f 與 f' ，若

$$f'_x(z') - f'_x(z' \setminus i) \geq f_x(z') - f_x(z' \setminus i) \quad (15)$$

對所有輸入 $z' \in \{0,1\}^M$ ，則

$$\phi_i(f', x) \geq \phi_i(f, x) \quad (16)$$

表示改變模型不會對特徵的重要度造成改變。

滿足上述三種性質的模型 g 會有唯一解，其解的形式即為 Shapley 值：

$$\phi_i(f, x) = \sum_{z' \subseteq x'} \frac{|z'|!(M-|z'|-1)!}{M!} [f_x(z') - f_x(z' \setminus i)] \quad (17)$$

基於 SHAP 理論之一致性原則，本文提出以多項式模型進行預測與分析，可得出與電力負載分析一致之結果。目的為設定各預測法之張量(Tensor)、疊代次數、學習率與學習樹深度等參數。再者，比較各多項式權位(因子)值，與標準值相比較，即可得公平地比較出各方法之效率與信心度。

(二) 用電模型設定

以饋線之負載為模型，輸入的參數有年(2018-2019)、月(1-12)、日(1-31)、小時(0-23)、星期(1-7)、溫度(5.4-36.5°C)與濕度(0.21-0.99%)等共計有七種，輸出的為負載功率一種；資料時間長短約為 18 個月份(13,104 筆)並分成歷史資料與預測資料，前者作為模型訓練；後者作為預測輸入資料以驗證預測功率。真實的運轉預測時，預測資料可由中央氣象局預報資料取得。均採 LSTM 與 XGBoost 法為預測法則；LSTM 法之因子分析則以 SHAP 法；XGBoost 法即可提供因子分析結果。下圖 3 為整體關係示意。




圖 3 預測程序、輸入與輸出關係

(三) 多項式模型設定

基於前述之局部準確性與缺失性，設計此模型用於驗證預測正確性與因子關係，若存在於如(15)之向量 y_j

$$y_j = \begin{bmatrix} y_1 \\ \vdots \\ y_j \end{bmatrix} = \begin{bmatrix} w_{11} & \cdots & w_{1j} \\ \vdots & \ddots & \vdots \\ w_{i1} & \cdots & w_{ij} \end{bmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_j \end{bmatrix} \quad (18)$$

y_j 為第 j 個狀態時的總和，由相對的 i 個取樣次數與 x_j 個的亂數值所組成，其中 w_{ij} 為權位值。基於大數原則，當取樣數 i 越值多時，則期望值將接近於平均值，

故第 j 個狀態變數的期望值 $E[x_j]$ ，在有 i 個樣數樣本時，滿足於下式。

$$E[x_j] = \frac{1}{i} \sum_{j=1}^{100} w_{ij} x_j \quad (19)$$

配合本文所提之負載預測實驗，狀態 j 為 7，取樣個數 i 設定為 100 次，各權位值 w_{ij} 均設定為 1。顯見期望值 $E[x_j]$ 應接近於 1/7，表示各狀態變數 x_j 均勻地組成向量 $\mathbf{y}_j$ 。相對性統一因子(Unified factor) U_j 則可表示為，即可表示出各狀態變數之整體貢獻度。

$$U_j = \frac{E[x_j]}{\sum_{n=1}^j E[x_n]} \quad (20)$$

再者，設計權位值差異測試項目，當狀態 j 為奇數時，權位值 w_{ij} 設計為 $\frac{2}{7}$ ；偶數則為 $\frac{6}{7}$ 。依據局部準確性原則與(20)式定義，所得出之相對性統一因子 U_j 應分別為 0.08 與 0.23，實驗結果詳述於後續章節。

此多項式模型亦可提供分析因子的正確性參考值。再者，經由取樣數 n 與期望值結果，可調整如輸入資料批次(Batch)、疊代次數、學習率與學習樹深度等參數的設定。

三、整合 FTU 資料與需量反應用戶之精進潮流解析

(一) 區域配電網參數、負載與再生能源資料蒐集

本計畫採用台電虎菁變電所及其所屬饋線最為標的系統，圖 4 為該區實際地理座標圖，圖 5 為該轄區 SCADA 系統圖，圖 6(a)~(r)為其所轄饋線 SCADA 開關位置圖，其共有 2 座 60 MVA 三繞組變壓器、18 條饋線(XJ21~XJ30、XJ51、XJ53~XJ56、XJ58~XJ60)、48 具自動化開關(包含 15 具常開聯絡開關)、以及 41 具饋線資訊末端設備(Feeder Terminal Unit, FTU)，且該轄區有太能光電併網。圖 10 以 XJ21 饋線 2020 年 1 月負載曲線為例呈現其負載特徵，各饋線該月尖峰、離峰負載，以及三相負載最大差值列於表 3。本研究之 FTU 負載資料是由台電雲林區處取得之資料庫檔(.bak、.sql)，如圖 7 所示，而饋線拓撲則是由核研所提供之轉檔程式取得，其資料形式為文字檔(.set、.txt)，內容資料包含各開關連接母線座標、經緯度、開關型號、開關狀態、所屬饋線、是否為常開點、住址、與下一個開關距離、線路編號、其等效範圍之配電變壓器座標、相別與容量，如圖 8 所

示。文字檔經 Python 程式語言轉換為 OpenDSS 腳本檔(.dss)並擷取虎菁 D/S 資料；而資料庫檔則將虎菁 D/S 所屬 FTU 資料取出，依據各 FTU 所轄饋線配電變壓器容量分攤負載量，並轉換為.dss 檔以及負載曲線(.csv)，所輸出之 OpenDSS 腳本如圖 9 所示。本計畫基於台電資料庫中該轄區各月份負載模型，針對其負載抽接點進行相位重新配置，同時進行各時段開關切換策略之最佳算演算，以期達到降低三相不平衡、中性線電流、與系統總損失的目的。




圖 4 虎菁變電所轄區實際地理座標圖(x:經度, y:緯度)







圖 5 虎菁變電所轄區 SCADA 系統圖




(a) XJ21




(b) XJ22




(c) XJ23




(d) XJ24




(e) XJ25




(f) XJ26




(g) XJ27




(h) XJ28




(i) XJ29




(j) XJ30




(k) XJ51




(l) XJ53




(m) XJ54




(n) XJ55



(o) XJ56



(p) XJ58



(q) XJ59



(r) XJ60

圖 6 虎菁變電所各饋線 SCADA 開關位置圖

圖 7 FTU 資料庫.sql

圖 8 饋線拓樸.set 檔

圖 9 OpenDSS 腳本.dss 檔




圖 10 饋線 XJ21 一月份負載曲線

表 3 一月份各饋線尖、離峰負載以及三相負載最大差值

Feeder	Peak load (kVA)	Off-peak load (kVA)	Max load deviation between phases (kVA)
XJ21	773	271	367
XJ22	3877	1542	343
XJ23	2581	890	252
XJ24	3031	1008	281
XJ25	3015	1369	197
XJ26	4372	333	412
XJ27	3394	1271	483
XJ28	4031	859	375
XJ29	2371	970	285
XJ30	4994	518	550
XJ51	744	426	119
XJ53	744	426	119
XJ54	744	426	119
XJ55	413	298	67
XJ56	418	313	50
XJ58	507	198	165
XJ59	507	198	165
XJ60	235	178	19

(二) 基於 FTU 資料之精進饋線三相電力潮流解析

本計畫由核研所所提供之 FTU 資料庫以及饋線線路、變壓器等轉檔資料，透過 Python 程式語言建立 OpenDSS 通用配電網模型，以此模型進行三相功率、電壓、電流精進潮流解析，並計算損失等。一般來說，單條饋線約裝設有 2 至 3 座 FTU，饋線斷路器(Feeder Circuit Breaker, FCB)上亦有電壓電流資料，而以 FTU 量測之電壓電流所計算出來的三相功率為該量測點至饋線末之功率，本計畫將 FTU 之三相功率分配至該所屬區域之所有配電變壓器，分配方法以各變壓器容量為基準，採加權比重法分配之。圖 11 以 XJ51 為例，該饋線裝置有 3 具自動化四路開關(其中一具為常開開關)，皆裝設有 FTU，而 FCB 與 FTU 則可劃分出 3 個區域 Area1~3，故各區域從其上游所視之三相功率即為該區域前端所量測之功率減去末端之功率。計算出各區負載後，依據該區各配電變壓器容量分配之，如式(21)，其中 P_{Tri} 為各變壓器最大負載， P_{Area} 為該區域最大負載， C 為該區域各變壓器容量。將 FTU 之每小時三相負載標么化，其基準值則為其尖峰負載，以尖峰負載分配至各變壓器後轉換為(.dss)檔，而其標么曲線則匯至(.csv)檔，OpenDSS 引擎即可求解每小時電力潮流。

$$P_{Tri} = P_{Area} \times \frac{C_i}{\sum C} \quad (21)$$




圖 11 饋線 XJ51 之 FCB、FTU 及其所轄範圍示意圖

(三) 需量反應用戶方案模組建立

FTU 資料為量測之電壓電流，故其計算之三相功率為用電戶與再生能源所加總之淨負載，而近年來參與需量反應用戶與日俱增，除了併接於輸電系統之大型用戶外，部分中小型用戶亦可參與計畫性減少用電措施與需量競價措施，其方

案內容如表 4。若將需量反應亦考慮近配電饋線模型中，則可得到更準確之負載模型，惟需量措施資料涉及用戶資訊隱私問題難以取得，故本計畫假設饋線上有小型用戶參與計畫性減少用電措施，並建立至 OpenDSS 負載模型中。

表 4 台電公司現行需量反應措施內容

負載 管理 措施	方案	用戶 等級	通知 方式	執行 時間	最低抑低 容量
計畫 性減 少用 電措 施	月減 8 日型	100 kW↑	申請時即約 定抑低用電 時段，無須 通知	事先約定於 6 月 ~9 月工作日 10~17 時	經常契約容 量之 25%，但須 50 kW↑
	日減 6 時型	100 kW↑		事先約定於 6 月 ~9 月工作日 10~12、13~17 時	
	日減 2 時型	100 kW↑		事先約定於 6 月 ~9 月工作日 13~15 時	
臨時 性減 少用 電措 施	限電回 饋型	1000 kW↑	抑低前一日 16 時前	全年依系統需要 時	經常契約容 量之 15%
	緊急通 知型	100 kW↑	抑低 15min~2hr 前	全年依系統需要 時，以日為單位 每次 2~4hr，每月 不超過 36 hr	經常契約容 量 5000 kW 以下者取其 20%，5001 kW 以上者 取其 10%
需量 競價 措施	經濟型	100 kW↑	抑低前一日 18 時前或 2hr 前	全年依系統需要 時及競價結果， 以日為單位每次 2~4hr，每月不超 過 36 hr	50 kW↑
	可靠型	100 kW↑	抑低前一日 18 時前		50 kW↑
	聯合型	100 kW↑	抑低前一日 18 時前或 2hr 前		100 kW↑

假設負載資料以 1 小時為單位，月減 8 日抑低時間為 10:00~17:00；日減 6 時抑低時間為 10:00~12 與 13:00~17:00；日減 2 時抑低時間為 13:00~15:00；故單日抑低量等效負載矩陣 $DayD_{24h}^A$ 、 $DayD_{24h}^B$ 、 $DayD_{24h}^C$ 可分別表示如式(22)至(24)所示。

$$DayD_{24h}^A = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -D_1 & -D_1 & -D_1 & -D_1 & -D_1 & -D_1 \\ -D_1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (22)$$

$$DayD_{24h}^B = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -D_2 & -D_2 & 0 & -D_2 & -D_2 & -D_2 \\ -D_2 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (23)$$

$$DayD_{24h}^C = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & -D_3 & -D_3 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (24)$$

四、 正常運轉下最佳饋線重組與負載相位配置

本計畫提出整合開關切換與相位平衡最佳化演算法，使得系統正常運轉下可達到整月的最佳化運轉策略。在台電配電系統中，大部分的負載抽接點如配電變壓器或分歧線皆為單相，而三相配電變壓器亦有非對稱結構，如 U-V 接或 V-V 接。因此，若饋線各負載抽接點相位配置不當，則會有嚴重的三相不平衡情形發生，輕則提高線路損失，重則因中性線電流過大導致饋線斷路器(Feeder Circuit Breaker, FCB)上小勢能過電流電驛(Low Energy Over Current (LCO) Protective Relay, LCO)誤動作，降低系統穩定性與可靠度。相位平衡旨在重新安排饋線上各負載抽接點相別，經過圖 13 之六種相別配置法之排列組合，達到最佳化相位配置。




圖 12 三相四線配電饋線負載抽接示意圖




圖 13 負載抽接點六種相別配置圖

另一方面，最佳開關切換策略則是運用饋線自動化開關，其中亦包含三路開關或四路開關等，不像負載抽接點相位調整是由人工現場作業，由於這種開關是可以由饋線調度中心(FDCC)遠端操作。一般來說，除了饋線出口之 FCB 外，饋線上會有 2 具以上座自動化開關，包含與其他饋線互聯之聯絡開關，其可能與所屬變電所或者其他變電所相連。因此，倘若該區域各饋線負載、欲度差異過大時，利用開關切換進行饋線重組可平衡各饋線負載量，進而達到降低總線路損失、提高各饋線欲度等效果。然而配電網之饋線重組與負載抽接點相位平衡將互相影響，故本計畫將針對兩者進行同步最佳化演算，並開發整合配電網線能與需量之最佳化運轉平台，以提供台電配電網最佳相位配置與開關切換之建議。以下針對標的系統、資料轉換、饋線模組建置、演算法內容、軟體平台架構，以及最佳化結果做進一步說明。

(一) 多目標函數規劃

本計畫之最佳化運轉策略主要針對線路損失、饋線負載平衡、電壓展幅，以及饋線出口中性線電流為最佳化標的。然而，最佳化演算法必須針對一個參數進行求解，故須將各目標函數壓縮為單一數值，稱為多目標函數規劃。一般多目標求解最終目標為達到柏拉圖前緣(Pareto-optimal Front, POF)，如圖 14 所示，假設欲求解最小化二維問題(f_1, f_2)，在可行解區域中最靠近平面座標軸(最小值)之邊緣即稱為 POF。以下為常見的幾個多目標函數規劃方法，以逼近目標函數可行解之 POF。




圖 14 可行解集合與柏拉圖前緣

A) 權重和法(Weighted sum method)

此方法將各目標函數乘以一權重並將加，如(25)與(26)所示：

$$\text{minimize } F(x) = \sum_{m=1}^M w_m f_m(x) \quad (25)$$

$$\text{subject to } \sum_{i=1}^k w_i = 1 \quad (26)$$

權重和法為非常廣為使用的多目標函數規劃法，其計算簡單且可依據使用者需求調整目標函數權重，但是在非凸型解集合中，該發法可能無法逼近到適當的 POF，如圖 15 所示。




圖 15 權重和法於凸型與非凸型解集合之表現


B) 切比雪夫權重法(Tchebycheff weighted metric method)


此方法解決了權重和法在非凸型解集合下無法迫近 POF 的問題，將每個目標函數取 p 次方乘以權重並相加後，再開 p 次方，其數學式如(27)與(28)所示：

$$\text{minimize } (\sum_{m=1}^M w_m |f_m(x) - z_i^*|^p)^{\frac{1}{p}} \quad (27)$$

$$\text{subject to } \sum_{m=1}^M w_m = 1 \quad (28)$$

當 $p=1$ 時，即可視為權重和法；當 $p=2$ 時，可視為平面座標上至最佳解的距離；當 $p \rightarrow \infty$ 時，則可迫近任何非凸型解集合，如圖 16 所示。





(c) $p \rightarrow \infty$

圖 16 切比雪夫權重法於非凸型解集合之表現

(二) 強化學習最佳化演算法

強化學習(RL)是機器學習的一個分支，相較於機器學習經典的監督學習(Supervised Learning)、無監督學習(Unsupervised Learning)問題，強化學習最大的特點是在交互中學習 (Learning from Interaction)。Agent 在與環境的互動中根據獲得的獎勵或懲罰不斷的學習知識，更加適應環境。

RL 主要分為 model-based 與 model-free 兩種方法，Model-based 是在 Agent 已知任何狀態下執行任何動作獲得的回報，採取對環境進行建模的強化學習方法；而 Model-free 則是不需要對環境進行建模也能找到最佳的策略。由於本計畫環境模型複雜（相位平衡與開關切換），故使用 Model-free 的方法來處理。而 Model-free 又有 Policy-based 與 Value-based 兩個領域，以下分別說明。

Policy-based 主要是在訓練一個 Actor，Actor 對於一個特定的任務，都有自己的一個策略 π ，策略 π 通常用一個神經網絡表示，其參數為 θ 。從一個特定的狀態(State)出發直到任務的結束，被稱為一個完整的 episode，在每一步 Actor 都會採取一個動作 a (Action)並能獲得一個獎勵 r (Reward)，一個完整的任務所獲得的最終獎勵被稱為 R 。這樣，一個有 T 個時刻的 episode，Actor 不斷與環境交互，形成如圖 17 的序列 τ 。




圖 17 Actor 與環境互動示意圖

這樣一個序列 τ 是不確定的，因為 Actor 在不同 State 下所採取的 action 可能是不同的，一個序列 τ 發生的概率為：

$$\begin{aligned}
 p_{\theta}(\tau) &= p(s_1)p_{\theta}(a_1|s_1)p(s_2|s_1, a_1)p_{\theta}(a_2|s_2)p(s_3|s_2, a_2) \cdots \\
 &= p(s_1) \prod_{t=1}^T p_{\theta}(a_t|s_t)p(s_{t+1}|s_t, a_t)
 \end{aligned} \tag{29}$$

序列 τ 所獲得的獎勵為每個階段所得到的獎勵之和，稱為 $R(\tau)$ 。因此，在 Actor 的策略為 π 的情況下，所能獲得的期望獎勵為：

$$\overline{R_{\theta}} = \sum_{\tau} R(\tau) p_{\theta}(\tau) = E_{\tau \sim p_{\theta}(\tau)}[R(\tau)] \tag{30}$$

而我們的期望是調整 Actor 的策略 π ，使得期望獎勵最大化，於是有了策略梯度(Policy Gradient)的方法，該方法將期望函數使用梯度提升的方法更新網絡參數 θ （即更新策略 π ），期望獎勵的梯度如下：

$$\nabla \overline{R_{\theta}} = \sum_{\tau} R(\tau) \nabla p_{\theta}(\tau) = \sum_{\tau} R(\tau) p_{\theta}(\tau) \frac{\nabla p_{\theta}(\tau)}{p_{\theta}(\tau)} \tag{31}$$

由於 $R(\tau)$ 對環境而言是不可微的，再加上：

$$\nabla f(x) = f(x) \nabla \log f(x) \tag{32}$$

3 故期望獎勵又可改寫為：

$$\nabla \overline{R_{\theta}} = \sum_{\tau} R(\tau) p_{\theta}(\tau) \nabla \log p_{\theta}(\tau) \tag{33}$$

若將期望值近似於每一次取樣訓練的平均，即可得到：

$$\begin{aligned}
 \nabla \overline{R_{\theta}} &= E_{\tau \sim p_{\theta}(\tau)}[R(\tau) \nabla \log p_{\theta}(\tau)] \\
 &\approx \frac{1}{N} \sum_{n=1}^N R(\tau^n \nabla \log p_{\theta}(\tau^n))
 \end{aligned}$$

$$= \frac{1}{N} \sum_{n=1}^N \sum_{t=1}^{T_n} R(\tau^n) \nabla \log p_{\theta}(a_t^n | s_t^n) \quad (34)$$

其中，每次與環境互動所採取動作所得到的獎勵可能因時而異，比如目前的狀態可能與最近的動作有所相關，較久之前的動作影響現在的狀態相對較小，故在每個獎勵乘以一個折扣率 γ (Discounting Rate)。此外為了讓每次的獎勵有正有負以得到更好的學習效果(獎勵若為負則下次採取該動作機率將更小)，可將獎勵加上一個基線 b (baseline)，最後可得到的策略梯度為：

$$\nabla \overline{R_{\theta}} = \frac{1}{N} \sum_{n=1}^N \sum_{t=1}^{T_n} \left(\sum_{t'=t}^{T_n} \gamma^{t'-t} r_{t'}^n - b \right) \nabla \log p_{\theta}(a_t^n | s_t^n) \quad (35)$$

再將獎勵期望拿來更新網絡參數 θ ：

$$\theta \leftarrow \theta + \eta \nabla \overline{R_{\theta}} \quad (36)$$

另一方面，Value-based 主要是在訓練一個 Critic，Critic 並不與環境互動，而是評斷與環境互動的策略 π 之優劣，並由 Critic 網路更新策略。其主要由狀態價值函數 $V^{\pi}(s)$ (State Value Function) 與狀態-動作價值函數 $Q^{\pi}(s, a)$ (State-action Value Function) 來評估策略。其中， V 值是從某個狀態按照策略走到最終狀態所獲得獎勵總和的平均值；而 Q 值則是從某個狀態選取動作走到最終狀態所獲得獎勵總和的平均值。

在 Policy Gradient 中，對累積的獎勵取期望其實就是 Q 的定義，同時創建一個 Critic 網路來計算 Q 函數值，則可得到 Actor-Critic 方法。Actor 參數的梯度變為：

$$\nabla \overline{R_{\theta}} = \frac{1}{N} \sum_{n=1}^N \sum_{t=1}^{T_n} Q^{\pi_{\theta}}(s_t^n, a_t^n) \nabla \log p_{\theta}(a_t^n | s_t^n) \quad (37)$$

此時的 Critic 根據估計的 Q 值和實際 Q 值的平方誤差進行更新，對 Critic 來說，其損失函數 loss 為：

$$\text{loss} = \frac{1}{N} \sum_{n=1}^N \sum_{t=1}^{T_n} \left(r_t^n + \max_{a_{t+1}^n} Q^{\pi_{\theta}}(s_{t+1}^n, a_{t+1}^n) - Q^{\pi_{\theta}}(s_t^n, a_t^n) \right)^2 \quad (38)$$

為了讓 Actor-critic 與環境互動時可較容易的排除不可行的結果，將 Q 值增加一個基線，使得獎勵有正有負，而 V 值其實是下一步 Q 值的平均，所以 Q 減

V 一定是有正有負，故通常 b 會以 V 值代替，因此梯度就變為了：

$$\nabla \overline{R_\theta} = \frac{1}{N} \sum_{n=1}^N \sum_{t=1}^{T_n} (Q^{\pi_\theta}(s_t^n, a_t^n) - V^{\pi_\theta}(s_t^n)) \nabla \log p_\theta(a_t^n | s_t^n) \quad (39)$$

但是，如此則需要有兩個網絡分別計算狀態-動作價值 Q 和狀態價值 V，因此可將 Q 轉為 r 加 V，即得到了 Advantage Actor-Critic(A2C)方法，此時的 Critic 變為估計狀態價值 V 的網絡。因此 Critic 網絡的損失變為實際的狀態價值和估計的狀態價值的平方損失：

$$\text{loss} = \frac{1}{N} \sum_{n=1}^N \sum_{t=1}^{T_n} (r_t^n + V^\pi(s_{t+1}^n) - V^\pi(s_t^n))^2 \quad (40)$$

然而，若以 A2C 方法直接更新策略其迭代速度都是非常慢的，為了充分利用計算資源，則產生了 Asynchronous Advantage Actor-Critic (A3C)方法。這種方法有效利用了電腦 CPU 多核心平行運算的功能。首先，由一個中央主網路 Global Network 儲存著全域網路參數，負責異步接收各個 Agent(Worker)的參數梯度來更新全域參數。而各個 Agent 同步中央主網路的參數到自身，再各自進行單獨的 actor 訓練，每個 agent 都先根據策略網絡進行訓練數據的收集，再累積多個時間的樣本來更新策略網絡和值網絡，不僅可提高訓練速度，亦保證了訓練的穩定性，其示意圖如圖 18 所示。




圖 18 Actor 與環境互動示意圖

(三) 放射狀拓樸辨識

對於演算法來說，任何目標變數皆為隨機產生並往更佳解方向隨機性移動，然而若變數為開關狀態則不可行，因為開關若無規則的隨機切換，可能發生孤島運轉之無效解。此外，配電網由於可靠度問題必須保持放射狀拓樸狀態，若開關隨機切換產生環路、網狀拓樸，亦不可行。若是給予演算法限制式，則會發生大部分的解都被排除掉的情況，進而造成演算法發散。因此，本計畫以[23]之方法，首先找到所有可能之放射狀拓樸，再以這些既定拓樸架構下去進行最佳化求解，

即可在保證可行解的情況下又可使演算法收斂。[23]之方法首先將饋線拓樸進行簡化，將鄰近所有無開關之母線集結為超節點，故簡化之拓樸只含有超節點以及開關。圖 19 為虎菁 D/S 系統簡化拓樸，其含有 22 個互聯之自動化開關，以此拓樸以[23]採用之圖形理論則可找出所有放射狀拓樸，共計 10,780 種放射狀拓樸。而這些可能性中，再以配電系統模擬軟體 OpenDSS 進行額定負載潮流解析，將損失、壓降比原系統低之拓樸排除，其餘的拓樸即為可行拓樸。




圖 19 虎菁 D/S 系統簡化拓樸

(四) 軟體架構與整合平台

本計畫之軟體架構如圖 20 所示，其主要分為 4 個方塊。饋線資料處理與放射狀拓樸辨識方塊為前置作業，將台電雲林區處與核研所所提供之資料轉換為 OpenDSS 腳本以供最佳化運轉模擬用，如本章第 1 節所敘；再辨識放射狀拓樸並存放於資料庫中，如本章第 5 節所敘。而 A3C 學習與資料交換方塊為演算法主體，首先以第 4 節所述之 A3C 演算法生成網路，並依據電腦 CPU 核心分配 Worker 異步學習，學習過程為採樣不同相位配置法與饋線重組(開關切換)法，經

資料交換方塊連接 OpenDSS 求解電力潮流並更新 Actor 與 Critic 神經網路，各核心分別更新主網路(Global Network)，最後學習完成的結果再輸出為報表、圖表以供饋線運轉規畫者參考。




圖 20 軟體架構

圖 21 為整合平台之使用者介面，將前述之軟體架構及其功能整合後，建立一使用者介面(User Interface, UI)，提供更具方便與直觀之整合平台。使用者可選擇最佳化目標：饋線重組或負載換相，或兩者皆選，達到自定義目標之功能；演算法部分可選擇本計畫開發之 A3C 與常用之粒子群最佳化演算法(Particle Swarm Optimization, PSO)可擇一使用，未來若有其他演算法亦可再行加入；使用者亦可調整不同之目標權重(詳如下一小節說明)，以針對系統損失或中性線電流等目標進行最佳化求解。而模擬月份以及目標變電所亦可在 UI 中選擇，惟 FTU 資料以

及饋線拓樸資料有部分瑕疵，故需手動修正後才可使用。

區域配電網最佳化運轉平台

最佳化目標

☒ 饋線重組

☒ 負載換相

演算法

A3C

PSO

目標權重 (總和須為10)

總損失

4

最高出口中性線電

3

母線平均壓降

0

調整個數

3

模擬月份

1月

2月

3月

4月

5月

6月

7月

8月

9月

10月

11月

12月

目標變電所

口湖

土庫

大美

元長

斗工

斗六

斗南

水林

北勢

古坑

台西

四湖

西螺

東北

虎科

虎背

崙背

雲林

臺南

柳中

橋村

潭水

塭田

開始演算

計算完成，模擬結果與配置建議已輸出至目標資料夾。

圖 21 整合平台之使用者介面

參、 主要發現與結論

一、 饋線負載預測與關聯因子分析結果

(一) 預測結果

本計畫以饋線負載資料進行模擬分析，任選某二段之饋線負載測試資料，進行負載預測與相對性重要關係 U_j 。預測法則之細節設定則整理入下表 5。

表 5 預測法則之細節設定比較

LSTM	訓練輸入 張量維度	訓練輸出 矩陣維度	疊代次數
	12051x4x7	12051x1	50
XGBoost	訓練輸入 矩陣維度	訓練輸出 矩陣維度	樹個數/ 學習率
	12055x7	12055x1	32000/ 0.0080

下圖 22 與圖 23 分別為 168 小時之饋線負載實際值、LSTM 法與 XGBoost 法之預測結果。與實際值相比，此二種方法都能達成預測但無法完全相符。時間區域 1，各方法之方均根偏移(Root Mean Square Deviation)分別為 56.43 與 63.56；時間區域 2，則分別為 94.41 與 52.35。




圖 22 實際負載、LSTM 法與 XGBoost 法預測之比較(時間區域 1)




圖 23 實際負載、LSTM 法與 XGBoost 法預測之比較(時間區域 2)

(二) 多項式函數測試結果

以亂數產生出與上表 5 相同之輸入資料維度與設定，並且進行 100 次的估測實驗。每次實驗需重新產生資料以確保其獨立性。擷取某段之真實(Real)且由亂數產生之多項式與預測法結果於圖 24 所示，二種估測法與真實多項式結果非常相似，曲線幾乎重疊且無明顯差異。




圖 24 多項式函數(藍色)、LSTM 法預測(橘色)與 XGBoost 法預測之比較

此多項式模型不僅可驗證由 LSTM、XGBoost 與 SHAP 計算出的預測模型，亦可提供分析因子的正確性參考值。再者，經由取樣數 n 與期望值結果，可調整如輸入資料批次(Batch)、疊代次數、學習率與學習樹等參數的設定。表 6 整理出模型訓練與因子分析時間，LSTM 法需要平均 1015.009 秒完成模型訓練；較 XGBoost 法多出 654.279 秒。因子分析亦多需要 5.526 秒時間。測試之各狀態變數的平均貢獻度等分析數值整理於表 7。可知 LSTM 法與 XGBoost 法均能提供約 14.1%誤差之分析，但 LSTM 法提供較一致性，即低標準差之分析結果。

表 6 100 次多項式計算平均時間

	模型訓練與估測時間(秒)	因子分析時間(秒)	合計(秒)
LSTM	1015.009	5.856	1020.865
XGBoost	360.730	0.330	361.060

表 7 100 次多項式計算測試之各因子之貢獻度、平均值、誤差比與標準差

方法	x_1	x_2	x_3	x_4	x_5	x_6	x_7	平均值	誤差比 (%)	標準差
LSTM	1.137	1.145	1.137	1.139	1.149	1.149	1.141	1.141	14.1	0.00516
XGBoost	1.112	1.177	1.113	1.148	1.037	1.243	1.154	1.143	14.3	0.06376

圖 25 為以不同權位函數測試多項式模型法之結果，奇數權位設定為 0.08；偶數權位設定為 0.23。以同樣之資料格式與訓練模型參數，可得 LSTM 法分別得出奇數與偶數之平均統一性因子為 0.08 與 0.23；同樣地，XGBoost 法分別得出奇數與偶數之平均統一性因子為 0.045 與 0.27。相較於設定值，LSTM 法較 XGBoost 法能求得較精確之統一性因子數值。




圖 25 多項式函數(藍)、LSTM 法預測(橘)與 XGBoost 法預測之不同權位值測試

(三) 關聯因子分析結果

相對性關係因子 U_j 分析結果於圖 26 與圖 27 表示。於時間區域 1 與 2 內，LSTM 法之最大統一因子為小時(Hour) 且分別為 0.45 與 0.42；XGBoost 法則為月份(Month)且分別均為 0.23。較不相同的是 LSTM 法完全無任何年(Year)與月(Month)的關聯性；XGBoost 法則其統一因子則有較多的月份因子考慮。




圖 26 LSTM 法與 XGBoost 法之分析因子結果於時間區域 1




圖 27 LSTM 法與 XGBoost 法之分析因子結果於時間區域 2

二、整合配電網線能與需量之饋線重構與負載換相最佳化模組與結果

本計畫首先以台電虎菁變電所之系統總損失、饋線出口最大中性線電流，以及負載抽接點調整個數作為目標函數，針對 2019 年 8 月的瞬間片段資料負載資料進行饋線重組與相位平衡最佳化求解。目標函數如(41)所示， ω_1 、 ω_2 與 ω_3 分別為各目標權重， p 則為無限大；而虎菁變電所 1699 個負載抽接點以及 22 個該轄區本體與互聯之自動化開關則為最佳化目標。

$$OF = \left[\omega_1 \left(\frac{E_{loss}^i - E_{loss}^{min}}{E_{loss}^{max} - E_{loss}^{min}} \right)^p + \omega_2 \left(\frac{I_n^i - I_n^{min}}{I_n^{max} - I_n^{min}} \right)^p + \omega_3 \left(\frac{N^i - N^{min}}{N^{max} - N^{min}} \right)^p \right]^{\frac{1}{p}} \quad (41)$$

本研究以 DRL 之 A3C 進行最佳化學習，其獎勵函數即為目標函數(式(41))，不過此處須乘以負號，使得獎勵越大系統總損失越小。以表 8 之案例 1~4 為例，案例 1 與 2 分別針對當時總線路損失以及 18 條饋線出口最大中性線電流進行最佳化，以片段推估一個月的總損失，總損失最高可從 9512kWh 降至 8249 kWh，而饋線出口最大中性線電流最高可從 34.8 A 降至 19.9 A；案例 3 以 8 比 2 之比例分配兩者權重，再犧牲部分系統總損失下可將中性線電流降至 23.2 A；案例 4 目標函數加入負載抽接點調整個數，並以 4 比 3 比 3 比例分配之，再犧牲部分系統總損失與中性線電流下可將負載抽接點個數降低至 398 個。4 個案例之學習過

程如圖 28 所示。

表 8 模擬案例及其結果

Case	Weighting			E_{loss} (kWh)	I_n (A)	N
	ω_1	ω_3	ω_3			
Original	-	-	-	9512	34.8	-
Case 1	1	0	0	8249	28.8	812
Case 2	0	1	0	8698	19.9	774
Case 3	0.8	0.2	0	8297	23.2	796
Case 4	0.4	0.3	0.3	8331	21.2	398




圖 28 各案例 A3C 目標函數學習過程

圖 29 為案例 1~4 最佳化前後各饋線損失，饋線損失與其負載有著正相關，圖中顯示各饋線損失在相別配置與饋線重組後趨於平衡，意味著各饋線負載差異

亦較原本小，重載饋線裕度亦提高。圖 30 為案例 1~4 最佳化前後各饋線出口最大中性線電流，由此得知雖部分饋線最大中性線電流升高，但變電所總體最高點下降，可防止因中性線電流過高所產生的 LCO 誤動作情形，有效提高系統可靠度。




圖 29 A3C 最佳化前後各饋線損失




圖 30 A3C 最佳化前後各饋線出口最大中性線電流

表 9 為虎菁 D/S 案例 4 最佳化後所建議之開關接換結果，其包含了 22 個互聯之自動化開關之切換策略，而 1699 個負載抽接點相別配置結果如表 10 所示，由於篇幅問題只取部分呈現。

表 9 虎菁 D/S 建議之開關切換策略

編號	開關圖號座標	開關狀態
1	K2746DA35-S01	on
2	K2945CB68-S01	off
3	K2745AE20-S01	off
4	K2645CA64-S01	off
5	K2746DA99-S01	off
6	K2747BA77-S01	on
7	K2748AB72-S01	on
8	K2746DA1573-S07	off
9	K2647EA44-S01	off
10	K2746GB38-S01	on
11	K2946CC15-S01	on
12	K2946GD38-S01	off
13	K2849FA01-S01	off
14	K3046CD68-S01	on
15	K2849FA36-S01	off
16	K2746FC82-S01	off
17	K2747FE0400-S01	off
18	K2748HC42-S01	off
19	K2646FB63-S01	off
20	K2645AA6600-S01	on
21	K2746HB11-S01	off
22	K2945HA20-S01	off

表 10 虎菁 D/S 八月份建議之相別調整策略

編號	圖號座標	相別配置	編號	圖號座標	相別配置
1	k2945cd00-t01	cab	44	k3044ac84	bca
2	k2945cd89-t01	acb	45	k2944hc52	cab
3	k2945bd92-t02	bac	46	k2746da88	bca
4	k2945cd95-t01	acb	47	k2945bc4500	bac
5	k2945bd71-t01	cba	48	k2643fa94	cab
6	k2945ad0781-t01	acb	49	k2643fb81	bac
7	k2746da7310-t01	cba	50	k2643ga89	bac
8	k2642fd66-t01	bca	51	k2642ee18	bac
9	k2945cd94-t01	acb	52	k2743aa89	bca
10	k2845he41	acb	53	k2743ba19	cab
11	k2945ad51	bac	54	k2743aa39	abc
12	k2945cc11	bac	55	k2743ab53	cab
13	k2945bd92-t01	acb	56	k2643hb00	bac
14	k2642dd79	acb	57	k2643hb41	abc
15	k2642fe17	cab	58	k2543hd93-t03	acb
16	k2642bc58	acb	59	k2543hd93-t02	cba
17	k2945bd30-t01	bac	60	k2543hd93-t04	bac
18	k2743ec58	cba	61	k2645cb8980-t01	bac
19	k2743cb83	cba	62	k2644ab59-t01	cab
20	k2743cc71	cab	63	k2644ba25-t01	bac
21	k2743bc66	acb	64	k2644ab70-t02	bac
22	k2743bc35	bac	65	k2644ab70-t01	cba
23	k2743gb56	abc	66	k2644ab70-t03	cba
24	k2743eb11	abc	67	k2644ab05-t03	bca
25	k2743dc43	bca	68	k2644ab05-t02	cab
26	k2743dc22	bca	69	k2644ab05-t01	cab
27	k2743db34	bca	70	k2644ca86-t01	bca
28	k2743gd01	cab	71	k2644db38-t02	bca
29	k2743de31	bca	72	k2644db38-t01	abc
30	k2743ec08	acb	73	k2644dd10-t01	bca
31	k2743db55	bac	74	k2645db77-t01	acb
32	k2743ab58	abc	75	k2544hb20-t01	acb
33	k2643hc85	bca	76	k2645db75-t01	abc
34	k2743ac27	cab	77	k2542cb93	cba
35	k2743be13	abc	78	k2643be42	bac
36	k2642gd17-t01	bca	79	k2643ce32	acb
37	k2746fb25	acb	80	k2643bd46	cba
38	k2746da98	bca	81	k2643ac59	bac
39	k2746da67	abc	82	k2543gb23	bac
40	k2746ea19	cba	83	k2541be71	bac
41	k3044cd12	cba	84	k2543fb90	bca
42	k2945bd80	abc	85	k2542ed28	bca
43	k2944hc91	cab	86	k2542ca67	abc

三、 結論

本計畫依據所擬定目標與工作項目。首先，廣泛蒐集並彙整有關綠能高滲透、需量反應、需量預測與人工智慧最佳化等方法用以提高區域配電網運轉效能之相關文獻，作為本計畫立論參考依據；其次，以 Python 程式語言為基礎建立一套系統化求解方法與模擬分析平台，包含 FTU 資料轉檔方法、預測程式模組、電力潮流解析模組、影響因子分析模組與最佳化排程模組；最後，藉由所開發之程式匯入區域配電網負載資料與氣象資料於 SQLite 資料庫，並利用 OpenDSS 建立電網模型，再以深度學習與最佳化演算法進行饋線負載與綠能關連性分析、負載最佳相位配置，以及饋線重組最佳開關切換排程，本計畫以台電雲林區處虎菁配電變電所二台 60 MVA 三繞組變壓器所轄饋線形成之區域配電網進行模擬分析，結果顯示本計畫所提方法以每月開關切換排程與相位平衡建議可有效降低中性線電流與系統損失，提高配電網運轉效能，以期進一步由下而上提高饋線、區域配電網至輸電網運轉穩定度；此外，本計畫亦藉由分析影響饋線淨負載變動因子，粗略評估饋線之負載與再生能源佔比，用以瞭解饋線淨負載受天候之影響程度。

表 11 為本計畫擬定之預定進度甘梯圖與工作項目，已依照進度完成，並建立一系統化饋線自動開關切換排程，本計畫研究成果除了可以強化變電所與饋線自動化功能外，亦可整合至需量反應與再生能源運轉策略相關研究。

表 11 本計畫執行甘特圖

工作項目 \ 月	1	2	3	4	5	6	7	8	9	10	11	12
國內外整合再生能源、需量反應與饋線開關智慧切換排程平衡策略相關文獻與技術資料蒐集與彙整。												
正常運轉情況下之主饋線負載抽取點最佳相位配置演算法與程式模組建立與驗證。												

正常運轉情況下之饋線重組最佳開關切換排程演算法與程式模組建立與驗證。			※								
基於饋線重組之區域配電網正常運轉情況下之最佳相位配置演算法與程式模組建立與驗證。											
區域配電網元件參數、負載與再生能源等資料蒐集、統計與分析。											
考量氣象站溫度、濕度、風速等資料應用統計方法完成饋線負載與綠能關連性分析。					※						
整合關連資料庫內氣象、負載與再生能源發電之精進預測演算法與程式模組建立與驗證。											
基於 FTU 資料之饋線三相功率、電壓、電流精進解析演算法及程式模組建立。								※			
需量反應用戶參與方案及其參與期間抑低用電資料統計分析精進模組建立。											
整合配電網綠能與需量最佳開關排程模組建立。											
研究成果彙整與與期末報告撰寫。											※

工作進度估計百分比（累積數）	10%	20%	30%	40%	50%	60%	65%	70%	80%	85%	95%	100%
預定查核點	第 1 季：完成需量負載最佳相位配置之三相平衡策略演算法開發。											
	第 2 季：完成配電饋線之系統架構與運轉數據彙整與分析。											
	第 3 季：開發饋線架構轉換程式，並完成需量負載與再生能源關連性分析。											
	第 4 季：完成配電饋線之需量負載最佳相位配置平台開發。											

肆、 參考文獻

- [1]. Ye Guo, Subhonmesh Bose, and Lang Tong, “On Robust Tie-Line Scheduling in Multi-Area Power Systems” *IEEE Transactions on Power Systems*, Vol. 33, No. 4, pp. 4144 - 4154, 2018.
- [2]. Zhenfei Tan, Haiwang Zhong, Jianxiao Wang, et al., “Enforcing Intra-Regional Constraints in Tie-Line Scheduling A Projection-Based Framework” *IEEE Transactions on Power Systems*, Vol. 34, No. 6, pp. 4751 - 4761, 2019.
- [3]. Zhigang Li, Mohammad Shahidehpour, Wenchuan Wu, et al., “Decentralized Multiarea Robust Generation Unit and Tie-Line Scheduling Under Wind Power Uncertainty” *IEEE Transactions on Sustainable Energy*, Vol. 6, No. 4, 2015.
- [4]. Mohammad Amin Heidari, “Optimal network reconfiguration in distribution system for loss reduction and voltage-profile improvement using hybrid algorithm of PSO and ACO” *CIREN - Open Access Proceedings Journal*, Vol. 2017, Iss. 1, pp. 2458–2461, 2017.
- [5]. Huating Xu, Zhihong Yu, Jinxiu Hou, Yawei Wei, et al., “Deep Reinforcement Learning-Based Tie-Line Power Adjustment Method for Power System Operation State Calculation” *IEEE Access*, Vol. 7, pp. 156160-156174, 2019.
- [6]. 吳家駿，應用免疫算法於配電系統運轉策略之研究，碩士論文，國立中山大學電機工程學系，高雄，2001 年。
- [7]. 黃明陽，應用停限電運轉圖資系統支援配電饋線三相不平衡分析與改善，博士論文，國立中山大學電機工程學系，高雄，2007 年。
- [8]. Google DeepMind Alphago 中文網站 <https://deepmind.com/alphago-chinese>
- [9]. Lucas Roberto Ferreira, Alexandre Rasi Aoki, and Germano Lambert-Torres “A Reinforcement Learning Approach to Solve Service Restoration and Load Management Simultaneously for Distribution Networks” *IEEE Access*, Vol. 7, pp. 145978-145987, 2019.
- [10]. Ziming Yan ,and Yan Xu, “Data-Driven Load Frequency Control for Stochastic Power Systems A Deep Reinforcement Learning Method With Continuous Action Search” *IEEE Transactions on Power Systems*, Vol. 34, No. 2, pp. 1653-1656, 2018.
- [11]. Mehdi Bagheri, Venera Nurmanova, Oveis Abedinia, and Mohammad Salay Naderi, “Enhancing Power Quality in Microgrids With a New Online Control Strategy for DSTATCOM Using Reinforcement Learning Algorithm” *IEEE Access*, Vol. 6, pp. 38986-38996, 2018.
- [12]. Yinliang Xu, Wei Zhang, Wenxin Liu, Frank Ferrese, “Multiagent-Based

- Reinforcement Learning for Optimal Reactive Power Dispatch” *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, Vol. 42, No. 6, pp. 1742-1751, 2012.
- [13]. Ramtin Hadidi, Benjamin Jeyasurya, “Reinforcement Learning Based Real-Time Wide-Area Stabilizing Control Agents to Enhance Power System Stability” *IEEE Transactions on Smart Grid*, Vol. 4, No. 1, pp. 489-497, 2013.
- [14]. Y.-D. Lee, J.-L. Jiang, Y.-H. Ho, W.-C. Lin, H.-C. Chih, and W.-T. Huang, "Neutral Current Reduction in Three-Phase Four-Wire Distribution Feeders by Optimal Phase Arrangement Based on a Full-Scale Net Load Model Derived from the FTU Data," *Energies* 2020, vol. 13, no. 1844. doi: <https://doi.org/10.3390/en13071844>. p. 20, 2020.
- [15]. M. Dong and L. Grumbach, "A Hybrid Distribution Feeder Long-Term Load Forecasting Method Based on Sequence Prediction," *IEEE Transactions on Smart Grid*, vol. 11, no. 1. doi: 10.1109/TSG.2019.2924183. pp. 470-482, 2020.
- [16]. Y. Hong, J. J. F. Martinez, and A. C. Fajardo, "Day-Ahead Solar Irradiation Forecasting Utilizing Gramian Angular Field and Convolutional Long Short-Term Memory," *IEEE Access*, vol. 8, doi: 10.1109/ACCESS.2020.2967900. pp. 18741-18753, 2020.
- [17]. J. Ospina, A. Newaz, and M. O. Faruque, "Forecasting of PV plant output using hybrid wavelet-based LSTM-DNN structure model," *IET Renewable Power Generation*, vol. 13, no. 7. doi: 10.1049/iet-rpg.2018.5779. pp. 1087-1095, 2019.
- [18]. M. Wang, K. Zheng, Y. Yang, and X. Wang, "An Explainable Machine Learning Framework for Intrusion Detection Systems," *IEEE Access*, vol. 8, doi: 10.1109/ACCESS.2020.2988359. pp. 73127-73141, 2020.
- [19]. S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8. doi: 10.1162/neco.1997.9.8.1735. pp. 1735-1780, 1997.
- [20]. J. Brownlee, *Long Short-term Memory Networks with Python: Develop Sequence Prediction Models with Deep Learning*. 2017.
- [21]. T. Chen and C. Guestrin, *XGBoost: A Scalable Tree Boosting System*. 2016, pp. 785-794.
- [22]. S. Jansen, "Hands-On Machine Learning for Algorithmic Trading," (in Undetermined), doi: 2018.
- [23]. H. Andrei, and G. Chicco, “Identification of the Radial Configurations Extracted From the Weakly Meshed Structures of Electrical Distribution Systems” *IEEE Transactions on Circuits and Systems*, Vol. 55, No. 4, pp. 1149-1158, 2008.