

應用智慧電表監測與資料探勘技術預測冷凍設備之性能

周瑞生*

國立臺灣科技大學 營建工程系 教授

許瑜倩

國立臺灣科技大學 營建工程系 碩士

林良澤

盛德節能科技有限公司 總經理

邱繼弘

國立臺灣科技大學 營建工程系 研究助理

摘要

隨著「節能科技」在國際潮流的推動，臺灣在冷凍設備耗能資料的處理未能跟上智慧節能電表的安裝速度，龐大的耗能監測資料雖受妥善儲存，所累積而看似無用的時間序列資料與自動紀錄之高維度屬性卻無從採擷蘊涵的用電行為與性能推測。再者，冷凍設備屬耗電量大且長時間用電之設備，有較大之節能空間。故本文以冷凍設備為研究對象，針對不同型態(液態、氣態)之冷媒洩漏狀況下之耗能相關屬性資料進行智慧探勘，並分析不同冷媒填充量對其冷凍能力及性能之影響。本研究首先建立遠端監測系統量測與記錄傳統控制系統之設備運轉模型，監控冷凍設備之運轉訊號、性能與耗電量變化藉以預測性能係數。研究結果發現，針對液態冷媒洩漏試驗，類神經網路最能準確預測設備性能係數(C.O.P.)，平均絕對誤差百分比(MAPE)值為 8.257%；而針對氣態冷媒洩漏試驗，則是廣義線性迴歸模型在預測 C.O.P.值的 MAPE 值較佳，達 10.665%。此外，針對 3.24 M² 冷凍庫而言，當冷媒填充量為 3kg 時，設備運轉性能及冷凍能力皆為最佳狀態。研究成果期能將系統化建構與資料分析流程技術應用於節能科技產業以作為知識管理的一環，後續研究方向可建立設備用電異常之特徵資料庫，透過遠端監測系統分析訊號，建立異常反應機制與處理作業流程。

關鍵字：資料探勘、智慧電表、冷凍設備管理、遠端監測、物業管理

APPLYING SMART METER MONITORING AND DATA MINING TECHNIQUES TO PREDICT REFRIGERATION SYSTEM PERFORMANCE

Jui-Sheng Chou*

Professor, Department of Construction Engineering, National Taiwan University of Science and Technology, Taiwan

Yu-Chien Hsu

Master, Department of Construction Engineering, National Taiwan University of Science and Technology, Taiwan

Liang-Tze Lin

General Manager, San Der Saving Energy Technology, Ltd, Taiwan

Chi-Hung Chiou

Graduate Research Assistant, Department of Construction Engineering, National Taiwan University of Science and Technology, Taiwan

ABSTRACT

This study presents six data mining techniques for the prediction of refrigeration performance. These techniques include artificial neural networks (ANNs), support vector regression, classification and regression tree, multiple regression, generalized linear regression (GLR), and chi-squared automatic interaction detector. The purpose of this

work is to predict coefficient of performance (C.O.P.) for the refrigeration equipment under different amount of R404A refrigerant. By obtaining the value of C.O.P., we can evaluate the abnormal situation of equipment which might cause the overdose leakage of refrigerant. Analytical results from cross-fold validation are compared and the best model is determined. The investigation shows that the data mining techniques can effectively and efficiently assess the C.O.P. for given amount, temperature and pressure of refrigerants. In the liquid leakage phase, ANNs predicts C.O.P. the best, whose mean absolute percentage error (MAPE) is 8.257%; while in the vapor leakage phase, GLR obtains the most accurate value, whose MAPE is 10.665%. The models built in this study can facilitate the managers to evaluate the performance of the refrigeration equipment.

Keywords: Data mining, Refrigerator performance diagnose, Smart meter, Remote monitoring

一、緒論

1-1 研究背景

隨著地球石化能源存量減少，全球面臨能源短缺，相關替代能源或再生能源的技術目前仍不足以解決問題(Lo and Lin, 2009; Ahmed, Korres et al., 2011)，因此節約能源伴隨地球暖化日益嚴重的減碳議題成爲焦點。國際間多數先進國家無不投入大量人力物力研發探討具體之節能措施與管理方法，許多高科技廠房與高耗能產業也日益重視相關節能議題的研究。臺灣地區近年來產業及民生用電均大幅增加，在電業自由化的趨勢下，利用通訊、網路、資訊科技與電子技術，建構整體電能管理系統，不僅能嚴格監測用電量，並能藉由預測用電行爲進而改善用電效率(Lo and Lin, 2009)。

節能減碳已爲全球趨勢，響應節能減碳與採用省能設備已係未來新設備的採購趨勢，然設備製造生產過程中無法預測未來設備運轉性能，雖然具備省能功能及部份省電功能，在不同情境與環境需求下之運轉行爲，仍然是產品開發者與製造商所無法明確掌握的。空調、冷凍與熱泵設備等高耗能設備爲現代生活或工業生產不可或缺的主要項目之一，由於設備高耗能與使用量大，且受環境因素影響甚大，不同的環境、季節、空間及使用方式都將造成設備運轉行爲的不同。

再者，現今電力監控系統的應用隨著資訊化及網路化之技術層次日益提高的優勢下，電力系統應用不再侷限於單純電力使用，已達多向相互交流，不但可即時掌握用電狀況，更能提供各種管理與控制的服務，提升整體的電能使用效率。故本研究因

應科技資訊化之趨勢，欲利用智慧電表監測冷凍設備用電行爲，進而運用資料探勘技術預測其設備性能。

1-2 研究動機與目的

臺灣的電力供應，屬海島型獨立系統，因自產能源匱乏，99.4%的能源需仰賴進口供應，發電燃料以進口的燃煤與天然氣爲主要能源(李涵茵，2011)。爲能有效監測用電行爲，臺灣電力公司規劃於 2015 年前，推動 100 萬戶裝置智慧電表，長期則以 1,200 萬戶爲建置目標，預計 2012 年先選定 1 萬戶換裝智慧電表，取代傳統電表，2013 至 2015 年再完成 100 萬戶裝置，建置率以 5%即 600 萬戶規劃換裝爲目標(湯政仁，2010)。此舉，根據國外類似計畫之經驗，預估未來可節電 18 億度，減少二氧化碳排放量 111 萬噸。

此外，辦公大樓、住宅、工廠、大賣場甚至便利商店等，皆需長時間的營業或運作，不論是照明、空調、冷凍櫃等設備，皆需使用大量的電力，又隨著油電價格的持續飆漲，若未能妥善進行有效的節能措施，將導致全年的電量所費不貲。然而，隨著「節能科技」在國際潮流的推動，臺灣在耗能資料的處理未能跟上智慧節能電表的安裝速度，龐大的耗能監測資料雖受妥善儲存，所累積而看似無用的時間序列資料與自動紀錄之高維度屬性卻無從採擷所蘊涵的用電行爲與性能推測。

爰此，本研究以冷凍設備爲研究對象，配合國職訓單位籌建組合式冷凍庫教學設備案，模擬不同型態之冷媒洩漏實驗，並應用資料探勘技術，建構

冷凍設備性能係數(Coefficient of Performance, 簡稱 C.O.P.)預測模型。此外,國內外鮮少有應用資料探勘技術於 R404A 冷媒洩漏變化與冷凍設備運轉性能的相關研究,而設備內的冷媒多寡不僅關係到設備之耗電量,亦影響著經濟成本的支出。為提供冷凍產業評斷設備性能優劣之依據,本研究進而分析不同冷媒量對其冷凍能力及 C.O.P.之影響程度。本研究除供實務教學研習外,並將可作為建構冷凍(藏)設備智慧型遠端監測及設備性能診斷系統之初期研究參考。

二、文獻回顧

利用科學方法分析電力系統負荷為時勢所趨(Liu and Yi, 2011),而,預測電力資訊的方法目前大致可細分為:迴歸模型(regression model)(Taylor and Buizza, 2003)、時間序列模型(time series model)(Saab, Badr et al., 2001)、人工智慧技術(artificial intelligence technique)(Chen, Tzeng et al., 1996)、卡爾曼濾波器(state space and kalman filtering technology)(Park, Park et al., 1991)以及模糊邏輯方法(fuzzy logic method)(Ye, Guo et al., 2004),然而在當代資料探勘技術的應用卻缺乏更廣泛之論述與比較。

國外雖有部份研究應用資料探勘技術預測冷凍冷藏設備之熱學性質,例如:熵值與焓值。但國內外應用資料探勘在不同的冷媒量下預測冷凍冷藏設備性能相關研究仍有值得著墨之處,本章節將回顧資料探勘應用於參數與電力耗能之相關研究。

人工智慧應用於冷凍冷藏設備預測最為廣見的技術為類神經網路(Artificial Neural Networks, ANNs)。Şahin (2011)回顧數篇將資料探勘應用於電力範疇之研究發現,ANNs 為有效預測電力負荷、熱學性質及性能係數的方法之一(Şahin, 2011)。此外,Al-Saba and El-Amin (1999)使用類神經網路預測長時間下之電力負載量,並與時間序列模型比較,研究結果顯示類神經網路的預測值較接近實際值(Al-Saba and El-Amin, 1999)。

同樣應用類神經網路預測電力負載量,Mandal 等人(2006)預測便利商店的電力負載,同時也預測用電成本,發現類神經網路建立之模型平均絕對誤差

百分比(MAPE)範圍僅介於 0.56% 至 1.30% 之間(Mandal, Senjyu et al., 2006)。Ying and Pan (2008)則應用調適性網路模糊推論系統 ANFIS (Adaptive network based fuzzy inference system) 及類神經網路預測臺灣區域性之電力負載狀況。研究結果發現,調適性網路模糊推論系統預測結果比類神經網路準確(Ying and Pan, 2008)。

Şencan (2007)採用線性迴歸(Linear Regression, LR)、逐步迴歸(Pace Regression, PR)、序列最小化法(Sequential Minimal Optimization, SMO) 以及倒傳遞類神經模型(Back Propagation Neural Networks, BPNN) 預測不同冷媒之熱學性質,包含焓值、熵值等。分析結果顯示倒傳遞類神經網路最能準確預測目標(Şencan, 2007)。Şencan et al. (2011)更進一步延續研究預測 R143a、R404A、R407c 及 R410a 冷媒之熱傳遞係數與熱散佈性(Şencan, Köse et al., 2011)。

設備性能係數(C.O.P.)為設備抽走的熱量與設備消耗熱量的比值,係判斷設備運轉性能優劣的指標之一。Bechtler et al.(2001)應用動態類神經模型以冷水機之出入口溫度及蒸發器容量預測設備性能係數。而 Swider (2003)應用資料探勘預測設備性能發現類神經網路模型準確度較迴歸模型高(Swider, 2003)。Arcaklioglu 等人(2004)利用類神經網路預測冷媒成份 R12/R22 在不同比率下之熱泵設備性能係數及其效率 R^2 高達 0.9999(Arcaklioglu, Erişen et al., 2004)。

然而,除類神經網路及迴歸模型外,許多當代的資料探勘技術於預測設備性能方面的應用尚顯不足。本研究期望藉由數值分析模型,實證比較 ANNs、SVR、CHAID、CART、MR 及 GLR 方法於預測冷凍設備性能係數上之表現,並進而探尋監測屬性與 C.O.P.間之關係,利用維度的縮減,維持適當的準確率下降低預測的成本。

三、研究方法

3-1 資料探勘技術

人工智慧(Artificial Intelligence, AI)係透過計算機科技(Computing technology)建構的系統所表現出來的智能,藉以協助人類解決問題(Chou, Tai et al.,

2010)。而資料探勘係指從大量的資料中運用人工智慧建立具有意義的關聯性資訊。資料挖掘通常與電腦科學有關，並通過統計分析處理、資訊檢索、機器學習、專家系統等諸多科學方法與技術來實現目標。

資料探勘過程可分為三個階段：(1)初步探索與統計敘述(2)模型的建立和驗證(3)知識部署。在初步探索階段，通常需進行數據前處理，選擇全部記錄或子集，作初步的屬性篩選。本階段的數據挖掘過程多採迴歸模型，可運用的圖形和統計方法繁多。第二階段模型的建立和驗證，即是應運資料探勘技術以預測目標，並驗證模型的準確率。最後，即可將模型結果部署應用於研究知識領域。

3-2 複回歸 (MR)

複迴歸(Multiple Regression)為分析資料常被運用的工具之一，利用雙變項資料(bivariate-data)通常可研究相關(correlation)和預測(prediction)的問題(SPSS, 2007)。在現實問題研究中，因變量的變化往往受幾個重要因素的影響，此時就需要用兩個或兩個以上的影響因素作為自變量來解釋因變量的變化，即為複迴歸，公式如式(1)：

$$\hat{y} = b_0 + b_1x_1 + b_2x_2 + \dots + b_kx_k + e \quad (1)$$

\hat{y} 為因變量； x_1, x_2, \dots, x_k 為自變量； b_0 為常數項； b_1, b_2, \dots, b_k 為迴歸係數； e 為迴歸誤差。

為使複迴歸模型具有優良的解釋能力和預測效果，自變量選擇準則為(Chou, Tai et al., 2010)：

- (1) 自變量對因變量必須有顯著的影響，並呈適當的線性相關。
- (2) 自變量之間應具有一定的互斥性，即自變量之間的相關程度不應高於自變量與因變量之間的相關程度。

複迴歸常使用之檢定方法為適配度檢定 R^2 、標準誤差檢定 S_y 、 F 檢定、 t 檢定，公式如式(2)~(5)：

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} = 1 - \frac{\sum_{i=1}^n (y - \hat{y})^2}{\sum_{i=1}^n (y - \bar{y})^2} \quad (2)$$

SSR 為迴歸式的已解釋變異，又稱迴歸變異；

SST 為總變異量；

SSE 為誤差平方和；

n 為樣本數；

y 為觀察值；

\hat{y} 為估計值；

\bar{y} 為觀察值之平均值。

$$S_y = \sqrt{\frac{\sum_{i=1}^n (y - \hat{y})^2}{n - k - 1}} \quad (3)$$

k 為估計母體的數目。

$$F = \frac{\sum_{i=1}^n (y - \bar{y})^2}{\sum_{i=1}^n (y - \hat{y})^2 / (n - k - 1)} \quad (4)$$

$$t = \frac{\bar{x} - \mu}{s / \sqrt{n}} \sim t_{n-1} \quad (5)$$

\bar{x} 為樣本均數；

μ 為母體平均數；

s 為樣本標準差。

t -test 是用以檢驗每一個自變項的個別斜率(亦即個別的迴歸係數)是否顯著，也係用以決定反應變項 \hat{y} 與各別預測變項 x_i 之間是否存在顯著直線關係。

3-3 廣義線性迴歸 (GLR)

廣義線性迴歸(Generalized Linear Regression, GLR)也稱做廣義線性模型(Generalized Linear Model)，係簡單最小二乘迴歸的擴展，假設觀測值來自指數分佈(SPSS, 2007)，1972年由 Nelder 和 Wedderburn 提出(Kao, Chen et al., 2011)。此模式假設量測的隨機變數之分佈函數與實驗中系統性效應(即非隨機效應)可經由一鏈結函數(link function)建立可解釋其相關性的函數。公式如式(6)：

$$E(y) = \mu = g^{-1}(x\beta) \quad (6)$$

$E(y)$ 為 y 的期望值；

$x\beta$ 由未知待估計參數 β 與已知變數 x 構成的線性估計式； g 為鏈結函數。

在此模式下， y 的變異數可表示為式(7)：

$$\text{Var}(y) = V(\mu) = V(g^{-1}(x\beta)) \quad (7)$$

一般假設 V 可視為一指數隨機變數的函數，而未知參數 β 通常可以最大似估計量或貝氏方法求得。

GLM 主要構成部分如下：

- (1) 隨機成分(random component)：確認反應變數 y 及其分配；
- (2) 系統成分(systematic component)：描述解釋變數的結合方式；
- (3) 連結函數(link function)：描述系統成分與 y 的期望直之間的關係。

3-4 人工神經網路 (ANNs)

人工神經網路(Artificial Neural Networks, ANNs)係是一種應用類似於大腦神經突觸連接的結構，進行信息處理的數學模型，也稱為「神經網路」或類神經網路(Li, Chen et al., 2008; Liu, Yuan et al., 2009)。各神經元經由軸索連結成一複雜網絡，使其能夠從外在環境中學習適應，如圖 1。生物神經網路組成元素如下(Haykin, 1999)：

- (1) 神經核(Soma)：神經細胞的中心體，為轉換信號的單元，經由神經軸將信號傳送至其它神經細胞中。
- (2) 神經軸(Axon)：又稱軸索，負責傳送神經核產生的信號至其他神經細胞。
- (3) 神經樹(Dendrites)：又稱樹突，為神經細胞之輸入與輸出單元，在神經元之間接收與傳遞信號。
- (4) 神經節(Synapse)：又稱突觸，為連結神經軸輸出和神經樹輸入的點狀單元。

類神經網路由許多的人工神經細胞(Artificial Neurons)即類神經元組成，每一個處理單元(processing element)的輸出值傳到其他的處理單元便成為該單元的輸入值，對於網路模式輸入輸出關係可寫成下列模式，如圖 2、公式如式(8)：

$$Y_j = F \left[f(\sum X_i W_{ij} - \theta) \right] \quad (8)$$

X_i =輸入值(input)，其他神經元輸出至本神經元的訊號；

Y_j =輸出值(output)，輸出至其他神經元，成為其輸入值；

W_{ij} =兩神經元之間的連結權重值(weight)；

f =激發函數(activation function)；

F =非線性轉換函數(transfer function)；

θ =門檻值。

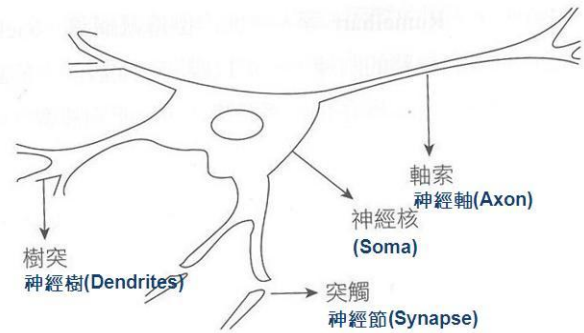


圖 1、類神經神經元模型

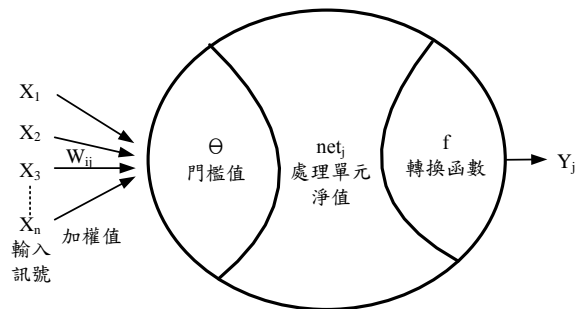


圖 2、類神經模式

其中，在各節點的輸出函數，稱為激發函數(activation function)。而每兩個節點間的連接都代表一個對於通過該連接信號的加權值，稱之為權重(Tso and Yau, 2007; Yezioro, Dong et al., 2008)。網路的輸出則依網路的組態連接方式(configuration)，權重值和激發函數的不同而有所不同。

3-5 支援向量迴歸 (SVR)

Support Vector Regression 是 Support Vector Machines (SVMs)用來處理迴歸問題的另一種方法，迴歸指得是每個實體(instance)所對應的標籤(label)是連續的實數，而非離散的相異類別(SVMs 裡常用整數來表示)，而處理迴歸問題的 SVMs 稱為 Support Vector Regression (SVR)。

當支援向量機被運用來估計迴歸方程式時有以下特性，其一為支援向量機估計迴歸時，使用了定義在高維度空間中之線性方程式的集合；第二特性為支援向量機藉由結構風險最小化的原則實現迴歸

估計的功能，且此結構風險使用 Vapnik (Ahmed, Korres et al., 2011) 的 ϵ 不敏感損失函數加以估計；另一特性為支援向量機採用由經驗誤差含結構風險最小化原則所導出的懲罰項(regularization term)所組合而成的風險函數(Shmueli, Patel et al., 2007)。

SVR 的目標為尋找空間中的最適平面(hyperplane)，和 SVMs 不同的是 SVMs 找的是能將資料一分為二的平面，而 SVR 所找的是能準確預測資料分佈的平面。給定一個資料點的集合，公式如式(9)：

$$G = \{(x_i, d_i)\}_i^n \quad (9)$$

x_i 為輸入向量；

d_i 為目標值；

n 為樣本資料量。

支援向量迴歸的基本概念係透過一個非線性映射 Φ ，將資料 x 映射至高維特徵空間，並在空間進行線性迴歸。公式如式(10)、(11)：

$$f(x) = \omega\Phi(x) + b \quad (10)$$

$$\Phi: R^n \rightarrow F, \omega \in F \quad (11)$$

ω 為權重向量(weight vector)；

代表 $f(x)$ 在高維空間中的平坦程度(flatness)；

b 為門限值；

Φ 為高維特徵空間函數；

代表輸入空間 x 的非線性映射。

如此，在高維特徵空間的線性迴歸便可對應於低維輸入空間的非線性迴歸，免去在高維空間中 ω 和 $\Phi(x)$ 之內積計算。由於 Φ 是固定不變的，為使 $f(x)$ 能更平坦，因此必須尋找最小化的 $\|\omega\|^2$ 。且在遵循結構風險最小化原則之下，藉著參數 C 的導入，為使支援向量迴歸的誤差($R_{reg}(C)$)能權衡於模型複雜度與經驗誤差之間，因而定義式(12)的懲罰風險函數(regularized risk function)，同時藉著最小化式(12)的過程推估 ω 和 b 的係數。

$$R_{reg}(C) = R_{emp} + \frac{1}{2} \|\omega\|^2 = C \times \frac{1}{n} \sum_{i=1}^n L_{\epsilon}(d_i, y_i) + \frac{1}{2} \|\omega\|^2 \quad (12)$$

$$L_{\epsilon}(d, y) = \begin{cases} |d-y|-\epsilon & |d-y| \geq \epsilon \\ 0 & otherwise \end{cases} \quad (13)$$

$R_{reg}(C)$ 為迴歸誤差(regression risk)；

$C \times \frac{1}{n} \sum_{i=1}^n L_{\epsilon}(d_i, y_i)$ 為經驗誤差；

第二項的 $\frac{1}{2} \|\omega\|^2$ 為懲罰項；

C 為懲罰常數(regularized constant)；

$\|\omega\|^2$ 可用來衡量 $f(x)$ 的平坦度，也代表模型的複雜度。

經驗誤差係藉由式(13)中的 ϵ 不敏感損失函數加以估計，導入損失函數的優點是使用較少的資料點即能提供式(10)的決策函數足夠的樣本。

懲罰常數用於控制產生誤差時的懲罰程度，它將在經驗誤差和懲罰項(代表迴歸的預測能力)之間進行權衡。增加 C 值時，會導致經驗誤差相對於懲罰項的重要性也增加，其次，只有當擬合誤差大於 ϵ 時才接受懲罰。使用 ϵ 不敏感損失函數的好處可提高估計的穩健性，具有抗雜訊能力。因此， ϵ 如同一個管狀空間(tube size)，其意義為在訓練資料上的預估精確度。需注意的是， C 和 ϵ 皆為研究者自行選定的參數。

3-6 分類迴歸樹 (CART)

早期主要的分類方法為 Quinlan 於 1979 年提出 ID3 分類法則，主要係處理離散型的類別資料，但由於 ID3 無法處理連續型的類別資料，故 1984 年 Breiman 等人提出分類迴歸樹法(Pitt and Kirschen, 1999; Scheetz, Zhang et al., 2009)。

分類迴歸樹(Classification and Regression Tree, CART)為樹狀結構，樹的中間節點為測試條件，樹的分支代表條件測試的結果，樹的葉節點代表分類後所得到的分類標記及分類結果(Breiman, Friedman et al., 1984)。CART 無需花費很長的時間訓練，其資料格式與衡量的尺度方式具有彈性，輸出的欄位可為數值型資料，亦可為類別型資料(Samanta, Bird et al., 2009)，若目標變數是類別型變數，稱為分類樹，若目標變數為數值型變數，則稱迴歸樹，CART 主要的特色在於不需要事前的離散化步驟，且演算法可透過不斷切割樹狀的二元分割方法，提高分類的準確率，但也造成複雜度的增加。CART 的分支大多以

Gini (Gini Index)係數為標準，也以 Gini index 來做分支節點的選擇，公式如式(14)：

$$Gini(t) = 1 - \sum_{i=1}^n p_i^2 \quad (14)$$

式(14)中， t 代表已知節點 t ，其中具有 n 個類別， p_i 表示第 t 個節點中第 i 個類別的機率。

$$Gini_{split}(S) = \frac{N_1}{N} gini(S_1) + \frac{N_2}{N} gini(S_2) \quad (15)$$

式(15)中，資料小集合 S 分為 S_1 與 S_2 ，各個子集合的大小分別為 N_1 和 N_2 ， N 為總樣本數。依照上式可看出當 $Gini_{split}$ 值越小，其所產生的子節點中，組成的樣本資料將越單純，亦即 $Gini_{split}$ 值小的分割代表不同類別樣本之間的的差異，因此所造成的錯誤分類機率也越低。

接下來為修剪樹狀結構，找出大小適當的決策樹，其修剪的準則是透過誤判率(Error Rate)或是誤判成本(Errone Cost)的計算作為決策樹修剪判斷依據。再修剪樹型的過程中所使用的準則為重代估計值(Resubstitution Estimate)。 $R(T)$ 為該樹狀結構 T 的重代估計值，當 $R(T)$ 值較小則表示該樹的末端節點個數越多，換言之，即是樹狀結構中的切割點越多，其樹狀結構也越大，公式如式(16)：

$$R(T) = \sum_{t=T} R(t) \quad (16)$$

T 表前一步驟所產生的最大樹狀結構；

t 表樹狀結構中某個節點。公式如式(17)：

$$R(t) = \gamma(t)p(t) \quad (17)$$

$R(t)$ 表第 t 個葉節點的重代估計值；

$\gamma(t)$ 表第 t 個葉節點的誤判率。公式如式(18)：

$$\gamma(t) = 1 - \max_j p(j|t) \quad (18)$$

$p(j|t)$ 表第 t 個葉節點中的第 j 類出現的機率；

$p(t)$ 表任一樣本出現在 t 節點的機率。

$$p(j|t) = \frac{p(j,t)}{p(t)} \quad (19)$$

$P(j,t)$ 表任一樣本出現在 t 節點中屬於第 j 類的機率。

$$p(t) = \sum_j p(j,t) \quad (20)$$

最後為挑選最佳樹狀結構，待所有可能的樹狀結構被尋找出來後，使用者可運用測試樣本進行交叉驗證，亦即將測試樣本代入所有可能的樹狀結構並計算每個樹狀結構的 $R(T_k)$ 值，最後再選取最小 $R(T_k)$ 值的樹狀結構為最佳樹狀結構。

3-7 廣義線性迴歸 (GLR)

廣義線性迴歸(Generalized Linear Regression, GLR)係簡單最小二乘迴歸的擴展，假設觀測值來自指數分佈(SPSS, 2007)，1972年由Nelder和Wedderburn提出(Kao, Chen et al., 2011)。此模式假設量測的隨機變數之分佈函數與實驗中系統性效應(即非隨機效應)可經由一鏈結函數(link function)建立可解釋其相關性的函數。公式如式(21)：

$$E(y) = \mu = g^{-1}(x\beta) \quad (21)$$

$E(y)$ 為 y 的期望值；

$x\beta$ 由未知待估計參數 β 與已知變數 x 構成的線性估計式； g =鏈結函數。

在此模式下， y 的變異數可表示為式(22)：

$$\text{Var}(y) = V(\mu) = V(g^{-1}(x\beta)) \quad (22)$$

一般假設 V 可視為一指數隨機變數的函數，而未知參數 β 通常可以最大概似估計量或貝氏方法求得。

3-8 卡方自動交叉檢驗 (CHAID)

卡方自動交叉檢驗(Chi-squared Automatic Interaction Detector, CHAID)係於1980年由Kass等人提出，它在建立決策樹過程中主要係利用卡方統計檢定(Chi-square test)來尋找最優的分支節點。其分析方法係利用Bonferroni的調整卡方值作為樣本群體的依據，用卡方檢定使同質的樣本單位歸於同一群，逐次搜索而完成分割的過程(SPSS, 2007)。CHAID運用半層級的(semihierarchical)逐次搜索，對每一預測變數的反應水準進行成對的合併及分割，以求得各預測變數水準的最少分群數目，此一分割過程一直進行到分群結果無顯著差異或分群後之小群體所含之樣本數已過少，以致無法做有意義的機率估計時為止(Shmueli, Patel et al., 2007)。

值得注意的是，CHAID會防止資料被過度套用並讓決策樹停止繼續分割，依據的衡量標準是計算

節點中類別的統計 p 值大小，以此決定決策樹是否繼續分割。此外，Exhaustive CHAID 演算法是 CHAID 的改進演算法，於 1991 年由 Biggs、de Ville 等人提出。CHAID 在分支過程中，如果發現無需再合併即會停止合併，但 Exhaustive CHAID 將繼續合併屬性變數組(依據統計量觀測值大小)，最終形成兩個組合，在組的合併上較 CHAID 演算法更為徹底，有利於分支變數的選擇。此外，CHAID 與 CART 兩種演算法的最大差異在於，後者先過度套用資料，再加以修剪，而 CHAID 嘗試在過度套用的情況發生之前就讓決策樹停止蔓生擴大。另一差異是 CHAID 只限於類別變數使用。連續變數必需被區隔成幾個區段範圍，或是以高、中、低等類別來取代。

3-9 交叉驗證法

當比較兩個或兩個以上的預測方法的準確性時，通常係採交叉驗證法(k-fold cross validation)，此方法可確保區隔建模與測試的樣本，有效降低隨機抽樣之誤差。交叉驗證法先將資料樣本分成 k 組子樣本群，輪流將其中 k-1 個子樣本群當作訓練(training)樣本，剩餘的子樣本群當作測試(testing)樣本，重複此建模動作 k 次(Salzberg, 1997)，如表 1。Kohavi 等人(1995)指出，使用分層的十群交叉驗證的模型較具效率且可靠(Orenstein, Kohavi et al., 1995)。

本研究資料分為兩部份：冷媒液態洩漏試驗計有 528 筆資料、冷媒氣態洩漏試驗共 217 筆資料。以 k=10 將資料筆數各分為 10 組，分組方式為在每筆資料編號欄位前加入一欄 random 函數，並將所有監測資料由 random 數值由大至小進行排序，分為 10 等分，前十分之一筆為資料第 1 組，依此類推。每一組輪流當作測試樣本，即可得到 10 組分類準確率之平均值以作為本研究模型預測準確率之效能評估(performance evaluation)。

表 1、交叉驗證組合

	測試組(10%)	訓練組(90%)
交叉 驗證 組合	第一組	第二組~第十組
	第二組	第一組、第三~第十組
	第三組	第一組、第二組、第四組~第十組
	⋮	⋮
	第 k 組	第一組~第 k-1 組

3-10 模型預測誤差衡量方法

本研究使用四種計算誤差的統計方法，量測模型預測值之誤差率與適配度：準確度的相關係數平方(R^2)、平均絕對誤差率(MAPE)、方根誤差(RMSE)與平均絕對誤差(MAE)。 R^2 為判斷模型適配度之一重要指標， R^2 愈趨近於 1，代表其預測擬合度越高；MAPE、RMSE、MAE 值愈低，代表其模型預測誤差率愈低，公式如式(23)~(26)：

$$R^2 = \frac{SSR}{SST} = 1 - \frac{SSE}{SST} = 1 - \frac{\sum_{i=1}^n (y - \hat{y})^2}{\sum_{i=1}^n (y - \bar{y})^2} \quad (23)$$

$$MAPE(\%) = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \times 100 \quad (24)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n [\hat{y}_i - y_i]^2}{n}} \quad (25)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (26)$$

SSR 為迴歸式的已解釋變異，又稱迴歸變異；

SST 為總變異量；

SSE 為誤差平方和；

\hat{y}_i 代表 i^{th} 預測值；

y_i 代表 i^{th} 實際觀察值；

\bar{y} 為實際觀察值之平均值；

n 為樣本總數；

R^2 為模型的適配程度。

MAPE 和 MAE 皆為平均絕對誤差值，但因 MAPE 為相對評估數值，較不受觀察值與預估值之單位與大小所影響，較能客觀得獲得兩者間之差異

程度；RMSE 的定義為預測值及實際值平方和的平方根，故稱為方根誤差。

四、實驗原理、設計與監測系統

本研究係運用遠端智慧網路及資料探勘技術，預測分析冷媒填充量變化對冷凍(藏)設備運轉性能的影響。本實驗之主體設備為面積 3.24 M² 的組合式冷凍(藏)庫，係國內職訓單位的教育訓練設備。實驗過程中不考慮外在環境對冷凍循環蒸發及冷凝(卻)效能的影響，且在同一冷凍(藏)庫、無負載運轉 15 分鐘、使庫內溫度由 +20°C 下降至 -20°C 停止運轉等條件下，模擬冷凍庫在液態及氣態冷媒洩漏，冷媒填充量變化時，對其製冷性能進行量測，並透過預設之溫度、壓力感測器及網路監測系統，蒐集實驗數據及進行資料探勘分析。下述章節詳述實驗設備、原理、設計、與監測系統。

4-1 冷凍設備循環原理

冷凍循環屬於相變製冷，乃利用冷媒由液態轉變成氣態(汽化)時吸收汽化熱的原理，達到熱量轉移傳遞及製冷的目的。冷凍系統的四大組成元件為：壓縮機、冷凝器、膨脹閥、蒸發器，各元件間經由銅管進行連接，並充填冷媒作為熱傳媒介。壓縮機係冷凍循環系統的心臟，將來自於蒸發器的低溫低壓氣態冷媒，壓縮成高溫高壓的氣態冷媒送至冷凝器進行冷凝(卻)，降溫後的液態冷媒經集液器、膨脹閥降壓成為低溫低壓的液態冷媒。冷媒一進入蒸發器後，因具備低溫沸騰特性，再因吸收冷凍庫內的熱量而汽化為低溫蒸氣冷媒，接著進入壓縮機進行前述之冷凍循環，冷凍系統基本循環圖，如圖 3 所示。




圖 3、冷凍系統基本循環圖

莫利爾曲線圖(Mollier Chart)是一種用來表示冷媒狀態變化特性圖，屬於壓力-焓線圖(P-h 線圖)(圖 4)。實用之溫度及壓力範圍內，皆可由圖中查得冷媒的各種狀態數值，包括溫度、壓力、比容積、焓...等，其縱座標為絕對壓力(P)，橫坐標為焓值(h)。莫利爾曲線圖為目前最常採用的冷媒狀態特性曲線圖，圖 5 為本研究使用的 R404A 冷媒壓焓圖。

壓焓圖以特定制冷劑的焓值(Enthalpy)(kJ/kg)為橫座標，以壓力(Pressure)(kPa)為縱座標繪製成的線圖；縱座標使用壓力的對數值 LgP 繪製，因此壓焓圖又稱 LgP-E 圖。本研究預測對象為冷凍設備性能係數(C.O.P.)，將感測器量測到之蒸發器冷媒出口溫度(T14)、蒸發器冷媒入口溫度(T10)、壓縮機冷媒出口溫度(T1)、壓縮機冷媒入口溫度(T16)對應到 R404A 冷媒壓焓圖，計算四處溫度對應之各焓值，連結起來即可繪出不同時間點下之莫利爾曲線圖。




圖 4、莫利爾曲線示意圖

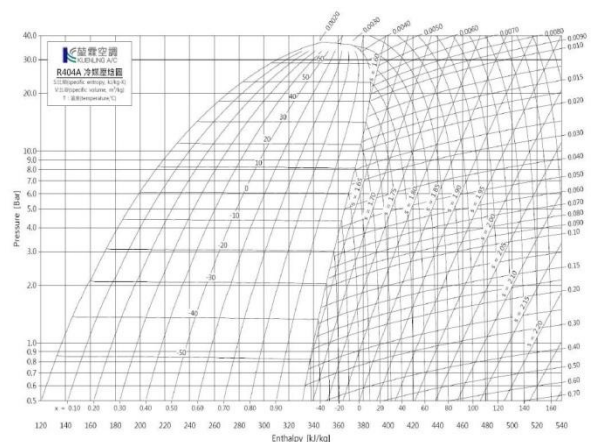


圖 5、R404A 冷媒壓焓圖

4-2 實驗對象與背景

本研究試驗分為兩部份，第一部份為模擬液態冷媒洩漏對冷凍庫庫內溫度下降速度之影響，進而計算其性能係數(C.O.P.)；第二部份為氣態冷媒洩漏對冷凍設備性能之影響。

實驗中，冷媒洩漏係定義為初始階段將 6kg 冷媒全數填充至冷凍設備內，依據不同形式之冷媒洩漏方式，依序在低壓液態冷媒處及低壓氣態冷媒處抽取冷媒。抽取過程中冷媒於設備內皆為動態狀態，一次抽取一公斤，液態及氣態冷媒洩漏試驗分別各抽取五次，使其設備內運轉之冷媒量由 6kg 逐次下降至 1kg。

實驗器材包含 16 支溫度感測器、4 支壓力感測器、真空泵、電子磅秤、複合壓力表、冷媒回收瓶；量測資訊包含溫度、壓力、電力資訊；實驗背景一覽表如表 2。蒸發氣溫度、冷凝器溫度、過冷溫度，過熱溫度和冷卻能力等皆會影響設備內部熱交換器

的性能，不同形式冷媒洩漏也會影響著設備之性能表現，而性能係數(C.O.P.)為最直觀可判斷設備性能好壞之指標之一(Şahin, 2011)。

當蒸發溫度或冷凝溫度任一條件固定之下，C.O.P.值越高，代表其設備之性能表現越佳。本實驗不考慮外氣溫度、濕度之影響，並假設冷凝溫度固定，因此，蒸發溫度將影響著設備之性能。

C.O.P.可定義為設備之冷凍能力除以設備之壓縮功，即為冷凍設備抽走的熱能(kJ/kg)除以冷凍設備消耗的熱能(kJ/kg)，公式如式(27)：

$$C.O.P. = \frac{\Delta H_{\text{evap}} \left(\frac{\text{kJ}}{\text{kg}} \right)}{\Delta H_{\text{ecomp}} \left(\frac{\text{kJ}}{\text{kg}} \right)} \quad (27)$$

熱能單位：(kJ/kg)；

C.O.P.：性能係數(Coefficient of Performance)；

ΔH_{evap} = 冷凍能力 = 冷凍設備抽走的熱能；

ΔH_{ecomp} = 壓縮功 = 冷凍設備消耗的熱能。

表 2、實驗背景資料

項目	內容
監測地點	桃園楊梅職業訓練中心
實驗目的	探討 R404a 近共沸冷媒如液態氣態冷媒充填量過多或洩漏不足時對冷卻能力係數 C.O.P. 及耗能影響
實驗變數	液態冷媒變化量、庫內溫度下降時間、系統各感測點壓力、溫度變化
實驗條件	冷凍庫庫內溫度由 20°C 降至 -20°C 之下降時間
實驗器材	真空泵、電子磅秤、複合壓力表、冷媒回收瓶
監測數值	電力資訊、各感測溫度(T1~T16)、壓力(P1~P4)
冷媒種類	R404A
冷凍設備內冷媒量	液態冷媒量 6kg、5kg、4kg、3kg、2kg、1kg

4-3 實驗設計

考量環保因素，政府禁用含氟元素之 R22 冷媒，本研究以普遍採用的 R404A 為實驗冷媒。R404A 冷媒是由 R125(44%)、R143a(52%)、R134a(4%)三種冷媒所組成，因 R404A 冷媒 ODP (Ozone Depletion Potential，臭氧層破壞指數)為 0，GWP (Global Warming Potential，全球暖化潛勢)值為 3300，此種冷媒為不會破壞大氣臭氧層的環保非共沸制劑，主要用於替代 R22 和 R502 冷媒，具有清潔、低毒、不燃、制冷效果佳等特點，廣泛用於中、低溫冷凍冷藏系統。

R404A 屬共沸冷媒但滑落溫度僅 0.5°C(泡點溫度-46.5°C、露點溫度-46.0°C)，在定壓下蒸發或凝結時氣態和液態的成份不同，溫度也不斷變化，當其按氣態和液態兩種不同方式對系統進行充填時，隨冷媒容器移充填率的變化，冷媒容器中的冷媒成份將輕微發生變化。電器技術開發中心人員指出：R404A 冷媒氣態方式充填時，冷媒容器中冷媒成份隨著冷媒容器移充填率的變化，移充填率由 0%至移充填率為 90%時，R143a 成份前後變化 0.5%，R125 成份變化 4%，R134a 成份變化 3.5%。若改採液態方

式充填時，冷媒容器中的冷媒成份大部分不隨冷媒容器移充填率而變化。

目前，業界對 R404A 冷凍冷藏系統發生冷媒洩漏能力不足時，因無法確認冷凍系統中剩餘冷媒之組成比例，在考量系統性能表現與可靠度下，維修作業時多採取全量回收、系統抽真空後，再以液態方式充填規定量新冷媒之作法，而回收後之冷媒則無法再利用。故本研究在不考慮冷媒成份變化率因素下，針對 R404A 冷媒以液態或氣態方式充填，以及不同的冷媒量對冷凍設備的製冷性能之影響分析，期可供後續研究參考。

4-4 實驗設備與量測裝置

4-4-1 冷凍設備系統

圖 6 為冷凍設備實體示意圖，本研究實驗之冷凍設備分為兩大部份：設備元件與控制設備，各元件之功能介紹於表 3。設備元件主要包含：壓縮機(鐵甲武士牌-5 馬力)、油分離器、冷凝器、儲液器、過濾乾燥器、液氣混合器、膨脹閥以及蒸發器。控制設備則是配合傳統的機械控制及智慧電表的數位控制如圖 7 達到量測電力資訊之目的；其中，電子觸控面板的優點在於其不僅可即時讀取感測器所量測到之溫度、壓力值、外氣濕度溫度值，更能即時的讀取電力負載趨勢，幫助顧客端隨時監控設備耗能趨勢，檢討耗能過量可能造成之原因；開關設備則為方便實驗進行中，用以控制設備運轉時間之裝置。

本實驗將溫度及壓力感測器安裝至冷凍設備元件出入口，包含：壓縮機、油分離器、冷凝器、膨脹閥及蒸發器，利用數位電表量測其變化，監測點位置一共包含了 16 處溫度值：壓縮機吐出口、油分離器入口、油分離器出口、冷凝器冷媒入口、冷凝器入風口、冷凝器出風口、冷凝器冷媒出口、庫內溫度、膨脹閥入口、蒸發器冷媒入口、蒸發器回風口、蒸發器出風口、蒸發器、蒸發器冷媒出口、室外溫度、壓縮機冷媒入口；以及 4 處壓力值：壓縮機冷媒壓力、壓縮機冷媒吐出壓力、凝結器出口冷媒壓力、蒸發器出口冷媒壓力。溫度、壓力感測

器安裝位置如圖 8，箭頭方向為冷凍設備內之冷媒流動方向，監測點位置說明詳如表 4。




圖 6、冷凍設備實驗配置圖



圖 7、數位控制與機械控制裝置

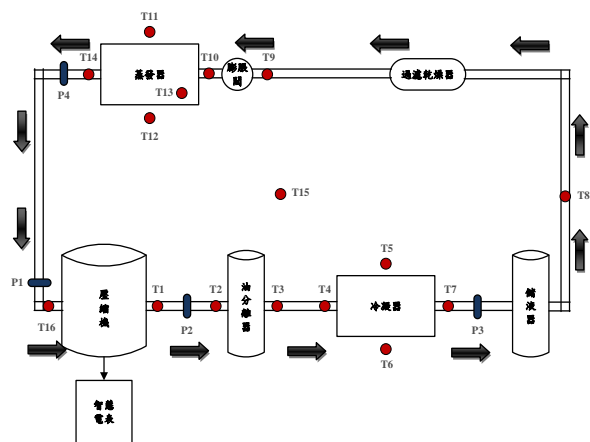


圖 8、溫度與壓力監測點位置

表 3、設備元件功能

設備	描述/功能	
蒸發器	蒸發器係將膨脹閥送來低溫的液態冷媒在低壓下吸收週圍空氣的熱量而蒸發，使庫內的溫度降低。	
乾燥器	乾燥器在冷凍系統中兼具暫時儲存冷媒、過濾及除濕與氣態液態冷媒分離的功能。	
儲液器	儲液器是防止液態冷媒流入吸氣管並進入壓縮機的安全裝置	
油分離器	油分離器具有從制冷氣體混合物中分離油的能力，從而促使制冷系統的有效運行。	
壓縮機	壓縮機是冷媒在冷凍循環系統中之原動力，使冷媒在冷氣系統內連續的循環。壓縮機之運轉為內燃機之反運轉，藉引擎傳動之機械能，把低溫、低壓氣體壓縮為高溫高壓的氣體。	
冷凝器	冷凝器是將壓縮機送來的高溫高壓氣態冷媒冷卻，使其液化成為液態冷媒的場所。	
膨脹閥	膨脹閥裝於蒸發器入口處，具有減低冷媒之壓力，且調節冷媒流入蒸發器之流速率。	
主 元 件 設 備	機械裝置	傳統讀取電力資訊設備。
	數位裝置(智慧電表)	可將資料無線傳輸至遠端電腦進行監控。
	電子觸控面板	觸控面板可即時掌握監測之溫度、壓力數據及電力趨勢。
	開關裝置	控制設備運轉及監測設備開關之裝置。
控 制 設 備	機械裝置	傳統讀取電力資訊設備。
	數位裝置(智慧電表)	可將資料無線傳輸至遠端電腦進行監控。
	電子觸控面板	觸控面板可即時掌握監測之溫度、壓力數據及電力趨勢。
	開關裝置	控制設備運轉及監測設備開關之裝置。

表 4、監測點位置對照表

AI 類比訊號 (溫度)	
T1：壓縮機吐出口溫度	T9：膨脹閥入口溫度
T2：油分離器入口溫度	T10：蒸發器冷媒入口溫度
T3：油分離器出口溫度	T11：蒸發器回風口
T4：冷凝器冷媒入口溫度	T12：蒸發器出風口
T5：冷凝器入風溫度	T13：蒸發器溫度
T6：冷凝器出風溫度	T14：蒸發器冷媒出口溫度
T7：冷凝器冷媒出口溫度	T15：室外溫度
T8：庫內溫度	T16：壓縮機冷媒入口溫度
AI 類比訊號 (壓力)	
P1：壓縮機冷媒入口壓力	P3：冷凝器出口冷媒壓力
P2：壓縮機冷媒吐出壓力	P4：蒸發器出口冷媒壓力

4-4-2 智慧電表監測系統

智慧電表監測冷凍設備系統架構如圖 9，量測之數據資料，可傳輸至類比或數位訊號之數位電表，再經由觸控式資料顯示及控制單元將讀取之數據資料透過網路傳輸及電腦傳輸介面 Universal Serial Bus

(USB)傳送至遠端專用資料蒐集系統提供遠端即時監控或於近端利用電腦進行即時性分析。

本研究採用之網路型數位電表(圖 10)，具有多項電力資訊測量和網路傳輸的功能，適用於量測單相二線、單相三線、三相三線或三相四線式電力，具

有寬量程全數位電能電量測量功能，並可透過網際網路網頁查詢即時電力資訊及歷史資料，獲取用電訊息。

智慧電表具有以下功能及優點：

1. 測量功能：可測量資訊包括實功、虛功、實功率、虛功率及需量等，亦能測量各相電壓(V)、電流(A)及視在功率(電壓與電流有效值之乘積；VA)、功率因素(PF)等資訊，達到電力使用過程，全程監控和紀錄的目的。
2. 通訊功能：具有 Transmission Control Protocol (TCP) Internet Protocol (IP)網路介面、可使用 Dynamic Host Configuration Protocol (DHCP)自動取得 IP 連線上網或利用 Point-to-Point Over Ethernet (PPPOE)連線上網，使用者除可查詢最近一分鐘之即時電力資訊之外，更可查詢歷史資料並繪製圖表掌握用電資訊，達到節能管理或其他應用之目的。
3. 高解析度：能測量極小的電力至 0.1W 與極小的電能至 0.001KWH。
4. 高準確度：電能(KWH)測量準確度 $\pm 0.5\%$ (在 PF=1.0，額定電流下；電力(W)測量準確度 $\pm 0.5\%$ (在 PF=1.0，額定電流下)。
5. 體積小：尺寸 10.8cm(W) \times 15.2cm(H) \times 6cm(D)。

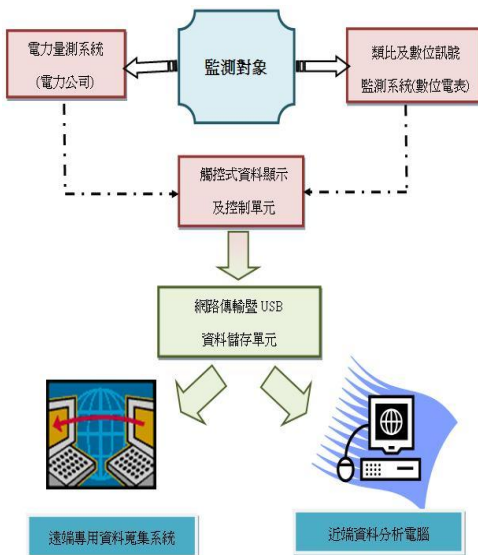


圖 9、冷凍設備監測系統架構圖



圖 10、網路型數位電表

五、資料收集與模型建立

5-1 資料蒐集及前處理

5-1-1 資料蒐集

本研究之實驗數據為不同冷媒量(6kg 依序逐次下降至 1kg)狀況下之液態冷媒洩漏與氣態冷媒洩漏之電力資訊、溫度(16 監測點位)及壓力(4 監測點位)值。所量測之資訊包含：設備運轉分鐘數、瞬間耗電量、視在功率、虛功率、功因、瓦時、壓縮機吐出口溫度(T1)、油分離器入口溫度(T2)、油分離器出口溫度(T3)、冷凝器冷媒入口溫度(T4)、冷凝器入風溫度(T5)、冷凝器出風溫度(T6)、冷凝器冷媒出口溫度(T7)、庫內溫度(T8)、膨脹閥入口溫度(T9)、蒸發器冷媒入口溫度(T10)、蒸發器回風口(T11)、蒸發器出風口(T12)、蒸發器溫度(T13)、蒸發器冷媒出口溫度(T14)、室外溫度(T15)、壓縮機冷媒入口溫度(T16)、壓縮機冷媒吐出壓力(P2)、凝結器出口冷媒壓力(P3)、蒸發器出口冷媒壓力(P4)。

實驗過程配合智慧電表同時讀取數值，將監測之電力、溫度、壓力值經 Excel 公式轉換成一般可讀取模式，階段性蒐集之資料筆數，液態冷媒洩漏試驗共 578 筆數據；氣態冷媒洩漏試驗共 245 筆數據。

5-1-2 資料前處理

資料前處理部份，主要為刪除監測過程中裁取之異常值，本實驗之數據異常值造成原因可歸納為以下兩點：

1. 運轉初始階段：設備趨於不穩定狀態所致；
2. 設備運轉中：智慧電表連線訊號異常所致。

故本研究依循此兩點異常導致原因及經詢問職訓單位專家意見後，排除數據異常值，方進行後續資料探勘分析。排除異常值後資料筆數分別為：液態冷媒洩漏試驗 528 筆；氣態冷媒洩漏試驗 217 筆。將刪除異常值後之資料數據匯入 Clementine12.0 軟體進行後續分析研究。

接著採用 SPSS 12.0 Statistics 對資料庫做敘述性統計分析，並利用 Pearson 相關係數進行屬性的篩選，皮爾森相關係數 r 之公式如式(27)：

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{(n-1)S_x S_y} \quad (27)$$

其中， n 為樣本數， x_i 、 y_i 為變數值； \bar{x} 、 \bar{y} 為變數平均數； S_x 為 x 變數標準差； S_y 為 y 變數標準差； r 描述的是兩個變量間線性相關強弱的程度； r 的絕對值越大代表其相關性越強。

Pearson 相關係數 $|r| > 0.8$ 代表其相關程度極高； $0.6 < |r| < 0.8$ ，相關程度高； $0.4 < |r| < 0.6$ ，相關程度

普通； $0.2 < |r| < 0.4$ ，相關程度低； $|r| < 0.2$ ，相關程度極低。

本研究分別將液態冷媒洩漏、氣態冷媒洩漏值進行雙變數統計 Pearson 相關係數分析，並篩選相關係數 $|r|$ 大於 0 至 0.9 以上之屬性，為後續資料探勘分析之輸入屬性。液態、氣態冷媒洩漏試驗屬性篩選結果如表 5，屬性數值範圍列於圖 11。

智慧電表所監測之電力資訊、溫度資訊、壓力資訊皆為數值型態，故後續資料探勘分析將採數值分析模型：有人工類神經網路(ANNs)、支援向量機(SVMs)、分類迴歸樹(CART)、卡方自動交叉驗證(CHAD)、多重迴歸(MR)、廣義線性迴歸(GLR)。但因各屬性之數值範圍級距過大，可能造成建立之模型屬性間之影響權重不夠顯著，故為使模型預測更為準確，本研究將原始之資料數據做正規化，方進行後續交叉驗證分析研究。

表 5、液、氣態冷媒 Pearson 相關係數篩選屬性表

	r >0		r >0.1		r >0.2		r >0.3		r >0.4		r >0.5		r >0.6		r >0.7		r >0.8		r >0.9	
設備運轉分鐘數	L	V	L	V	L	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V
功率	L	V	L	V	L	V	L	V	V	V	V	V	V	V	V	V	V	V	V	V
運轉時冷媒量 kg	L	V	L	V	L	V	L	V	L	V	L	V	L	V	V	V	V	V	V	L
視在功率	L	V	L	V	L	V	L	V	L	V	L	V	L	V	V	V	V	V	V	V
虛功率	L	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V
功因	L	V	L	V	L	V	L	V	L	V	L	V	V	V	V	V	V	V	V	V
瓦時	L	V	L	V	L	V	L	V	L	V	L	V	L	V	L	V	V	V	V	V
T1	L	V	L	V	L	V	L	V	L	V	L	V	V	V	V	V	V	V	V	V
T2	L	V	L	V	L	V	L	V	L	V	V	V	V	V	V	V	V	V	V	V
T3	L	V	L	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V
T4	L	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V	V
T5	L	V	L	V	L	V	V	V	V	V	V	V	V	V	V	V	V	V	V	L
T6	L	V	L	V	L	V	L	V	L	L	L	L	L	L	L	L	L	L	L	L
T7	L	V	L	V	L	V	L	V	L	V	L	V	L	L	L	L	L	L	L	L
T8	L	V	L	V	L	V	L	V	L	V	L	V	L	V	L	V	L	V	L	L

表 5、液、氣態冷媒 Pearson 相關係數篩選屬性表(續)

	r >0	r >0.1	r >0.2	r >0.3	r >0.4	r >0.5	r >0.6	r >0.7	r >0.8	r >0.9
T9	L	V	L	V	V	V				
T10	L	V	L	V	L	V	L			
T11	L	V	L	V	L	V	L	V	L	V
T12	L	V	L	V	L	V	L	V	L	V
T13	L	V	L	V	L	V	L	V	L	V
T14	L	V	L	V	L	V	L	V	L	V
T15	L	V	L	V	L	V	L	V	V	V
T16	L	V	L	V	L	V	L	V	L	V
P1	L	V	L	V	L	V	V			
P2	L	V	L	V	L	V	V			
P3	L	V	L	V	L	V	L	V	L	
P4	L	V	L	V	L	V	L	V	L	
屬性數目	27	27	25	27	23	27	21	26	17	23
	16	17	11	16	8	15	5	9	1	3

L：為液態冷媒洩漏試驗符合篩選值之屬性

V：為氣態冷媒洩漏試驗符合篩選值之屬性

	單位/代號	液態冷媒洩漏			氣態冷媒洩漏			
		Min.	Max.	Average	Min.	Max.	Average	
電力資訊	設備運轉分鐘數	Min.	0.87	31.78	10.80	1.08	61.87	20.25
	運轉時冷媒量	Kg	1.00	6.00	3.50	1.00	6.00	3.50
	瞬間耗電量	KW	1.70	4.22	2.52	2.00	3.94	2.43
	視在功率	VA	0.00	4.92	2.89	2.94	4.60	3.29
	虛功率	VAR	2.17	2.54	2.26	2.12	2.45	2.24
	功因	PF	608.50	865.40	731.46	670.60	863.50	731.18
	瓦時	HH_HL	36.32	40.94	38.87	41.47	54.33	45.64
溫度資訊	壓縮機吐出口溫度	T1	32.20	55.60	47.61	27.70	58.00	49.07
	油分離器入口溫度	T2	28.30	38.30	35.66	23.35	40.90	36.17
	油分離器出口溫度	T3	28.40	37.90	35.72	22.40	41.20	36.44
	冷凝器冷媒入口溫度	T4	23.20	32.20	30.17	18.70	36.80	31.59
	冷凝器入風溫度	T5	16.50	17.10	16.75	14.60	18.20	16.55
	冷凝器出風溫度	T6	19.00	24.30	21.09	18.20	21.90	20.45
	冷凝器冷媒出口溫度	T7	20.60	25.70	23.27	16.30	24.00	22.57
	庫內溫度	T8	-20.00	15.00	-2.63	-20.60	15.90	1.95
	膨脹閥入口溫度	T9	0.90	24.40	16.18	0.90	22.00	14.38
	蒸發器冷媒入口溫度	T10	-23.50	9.60	-11.25	-21.20	4.80	-13.28
	蒸發器回風口	T11	-17.80	16.70	-0.70	-18.40	17.70	3.81
蒸發器出風口	T12	-20.90	14.80	-3.91	-21.60	15.40	0.94	
蒸發器溫度	T13	-21.90	15.00	-4.25	-22.00	15.80	1.14	
蒸發器冷媒出口溫度	T14	-15.70	15.30	1.52	-16.20	17.20	5.44	
室外溫度	T15	17.90	18.30	18.13	16.30	19.10	17.83	
壓縮機冷媒入口溫度	T16	-13.20	16.20	5.50	-4.90	18.60	9.46	
壓力資訊	壓縮機冷媒壓力	P1	9.10	58.70	23.71	14.70	54.80	22.14
	壓縮機冷媒吐出壓力	P2	157.00	318.50	207.05	175.40	294.80	199.95
	凝結器出口冷媒壓力	P3	143.30	220.60	169.00	153.40	200.80	164.41
	蒸發器出口冷媒壓力	P4	56.00	57.30	56.55	18.60	66.80	27.31

圖 11、液態氣態冷媒洩漏數值範圍

5-2 模型建立與交叉驗證

研究實驗數據為冷媒量 6k 洩降至 1kg、蒸發器庫內溫度+20°C 降至-20°C 之所有電力資訊、各監測點位溫度值與壓力值，共計 27 個屬性。實驗監測之數據分為兩大部份(液態冷媒洩漏實驗及氣態冷媒洩漏實驗)進行建模與交叉驗證分析。

本文將不同相關係數 $|r|$ 分析之各模型交叉驗證結果，計算預測值與實際值間之 MAPE、MAE、RMSE 及 \bar{R} 值(\bar{R} 為 $1-R$)之值，便於後續計算統計誤差之平均值。此外，本研究將四種統計誤差方法加入屬性數目欄位，正規化後加總取其平均數，並將該值定義為綜合性評估指標(Synthesis Index, S.I.)。

液態冷媒洩漏試驗建模：液態冷媒洩漏試驗數據共計 528 筆，建模前先將電力資料庫進行分組，表 6 為液態冷媒洩漏試驗交叉驗證分組，前八組各有 53 筆資料，其餘兩組各有 52 筆資料。輪流將不同組帶入訓練組及測試組。另外，依照 Pearson 相關係數 $|r|$ ，將各組交叉驗證模型再分為十組，如表 7，分別為 $|r|>0$ 至 $|r|>0.9$ 。

氣態冷媒洩漏試驗建模：氣態冷媒洩漏試驗數據共計 217 筆，分組方式如同液態冷媒洩漏試驗所述，表 8 顯示氣態冷媒洩漏試驗交叉驗證分組前七組各有 22 筆資料，其餘三組各有 21 筆資料。依循

Pearson 相關係數 $|r|$ ，亦將各組模型再分為十類，表 9 則為氣態冷媒洩漏試驗 Pearson 相關係數篩選後屬性數目。

利用 Pearson 相關係數篩選屬性結果發現，以相關係數 $|r|>0.6$ 為分界，氣態冷媒洩漏試驗之屬性計有 16 個，液態冷媒洩漏試驗屬性篩選結果卻只有 11 個，其原因為前述當冷媒以氣態方式充填時，其組成比例會因充填率而有些微變化，致使氣態冷媒洩漏試驗影響設備性能的屬性較多。後續資料探勘之建模如圖 12，建模過程分為下列五大步驟：

步驟一：選擇 Clementine12.0 軟體進行數值分析之模型(ANNs, SVMs, CHAID, CART, MR, GLR)。

步驟二：選擇資料庫來源(本實驗之監測數值以 excel 檔型式輸出)。

步驟三：選擇不同相關係數 $|r|$ 下之輸入屬性及輸出屬性 C.O.P.。

步驟四：將分組資料進行交叉驗證。

步驟五：模型結果輸出。

最後，將液態冷媒洩漏試驗及氣態冷媒洩漏試驗預測 C.O.P.之交叉驗證結果，依據不同相關係數 $|r|>0$ 至 $|r|>0.9$ ，分別計算其 MAPE、MAE、RMSE、 \bar{R} 之十組平均值。

表 6、液態冷媒洩漏試驗交叉驗證分組

K-fold	1	2	3	4	5	6	7	8	9	10
資料筆數	53	53	53	53	53	53	53	53	52	52

表 7、液態冷媒洩漏試驗 Pearson 相關係數篩選後屬性數目

屬性	$ r >0.9$	$ r >0.8$	$ r >0.7$	$ r >0.6$	$ r >0.5$	$ r >0.5$	$ r >0.4$	$ r >0.3$	$ r >0.2$	$ r >0.1$
符合數目	1	5	8	11	16	17	21	23	25	27

表 8、氣態冷媒洩漏試驗交叉驗證分組

K-fold	1	2	3	4	5	6	7	8	9	10
資料筆數	22	22	22	22	22	22	22	21	21	21

表 9、氣態冷媒洩漏試驗 Pearson 相關係數篩選後屬性數目

屬性	$ r >0.9$	$ r >0.8$	$ r >0.7$	$ r >0.6$	$ r >0.5$	$ r >0.5$	$ r >0.4$	$ r >0.3$	$ r >0.2$	$ r >0.1$
符合數目	3	9	15	16	17	23	26	27	27	27

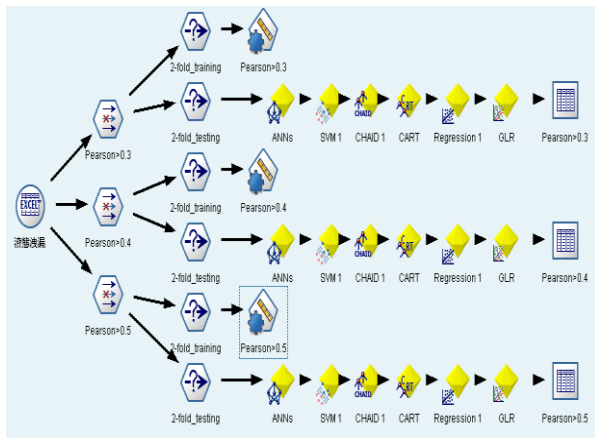


圖 12、數值分析模型

5-3 分析結果與討論

本研究使用 $\bar{R}(1 - \text{相關係數}R)$ 、MAPE(平均絕對誤差率)、MAE(平均絕對誤差)、RMSE(均方根誤差)為交叉驗證後模式表現評估依據。並將 \bar{R} 、MAPE、MAE、RMSE，採用屬性數目之結果各自進行數值正規化後取平均，計算綜合性指標(S.I.)值，S.I.值愈小代表其模型的整體表現愈佳，準確度越高。在四種誤差計算方法指標中，MAPE 為最普遍判斷模型誤率之指標，故本研究分析主要以 MAPE 及 S.I.為主。

除求得模式誤差率外，同時評估不同相關係數下採用之屬性數目。屬性數目越少，代表未來使用感測器監測的數量也能減少，如此一來，可減少監測的成本及作業。綜觀驗證結果發現，不論是液態冷媒洩漏試驗亦或氣態冷媒洩漏試驗，使用不同的相關係數 $|r|$ 分析其模型適配度值(R^2)之結果，幾乎皆達 0.95 以上。

液態及氣態冷媒洩漏試驗之 MAPE 綜合比較結果如表 10，液態冷媒洩漏試驗當中，MAPE 值前五名模型分別為 L57、L51、L55、L49、L31，其值分別為 6.637%、6.659%、7.109%、7.372%、7.666%；而氣態冷媒洩漏試驗當中，MAPE 值前五名模型分別為 V33、V24、V30、V39、V45，其值分別為 10.545%、10.665%、10.742%、10.888%、10.899%，如圖 13 及圖 14。

而若以綜合性指標 S.I.值為評定標準，則異於 MAPE 值之評估結果，液態氣態綜合比較如表 11。液態冷媒洩漏試驗中，誤差率最小之數值分析模型

為 ANNs，其中又以 $|r|>0$ 時之 ANNs 模型 L55 為誤差率最小之模型，如圖 15。但為考量節省監測成本因素，需同時考量誤差率低及採用屬性少之模型，故就液態冷媒洩漏試驗而言，最佳模型應為相關係數 $|r|>0.6$ 時之L19的 ANNs 模型，MAPE 值為 8.257%，S.I.值為 0.027。其 ANNs 模型設定為 Quick method；Alpha=0.9；Initial Eta=0.3；Eta decay=30；High Eta=0.1；Low Eta=0.01。相關係數 $|r|>0.6$ 之屬性共有 11 個，分別為：冷媒量、瓦時、冷凝器冷媒出口溫度(T7)、庫內溫度(T8)、蒸發器回風口溫度(T11)、蒸發器出口風口溫度(T12)、蒸發器溫度(T13)、蒸發器冷媒出口溫度(T14)、室外溫度(T15)、壓縮機冷媒入口溫度(T16)、蒸發器出口冷媒壓力(P4)。

表 10、液、氣態冷媒洩漏試驗 MAPE 分析結果綜合比較

液態冷媒洩漏試驗			
代號	模型	相關係數	MAPE
L57	CHAID	$ r >0$	6.637%
L51	CHAID	$ r >0.1$	6.659%
L55	CHAID	$ r >0$	7.109%
L49	ANNs	$ r >0.1$	7.372%
L31	ANNs	$ r >0.4$	7.666%
氣態冷媒洩漏試驗			
代號	模型	相關係數	MAPE
V33	CHAID	$ r >0.4$	10.545%
V24	GLR	$ r >0.6$	10.665%
V30	GLR	$ r >0.5$	10.742%
V39	CHAID	$ r >0.3$	10.888%
V45	CHAID	$ r >0.2$	10.899%




圖 13、液態冷媒洩漏試驗 MAPE 分析

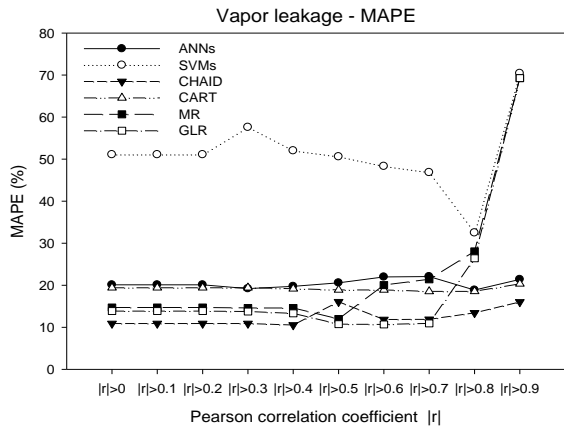


圖 14、氣態冷媒洩漏試驗 MAPE 分析

表 11、液態氣態冷媒洩漏試驗 S.I.分析結果綜合比較

液態冷媒洩漏試驗			
代號	模型	相關係數	S.I.
L55	ANNs	$ r >0$	0.005
L31	ANNs	$ r >0.4$	0.008
L25	ANNs	$ r >0.5$	0.011
L19	ANNs	$ r >0.6$	0.027
L43	ANNs	$ r >0.2$	0.027
氣態冷媒洩漏試驗			
代號	模型	相關係數	S.I.
V24	GLR	$ r >0.6$	0.001
V30	GLR	$ r >0.5$	0.002
V36	GLR	$ r >0.4$	0.016
V42	GLR	$ r >0.3$	0.023
V48	GLR	$ r >0.2$	0.025




圖 15、液態冷媒洩漏試驗綜合性指標(S.I.)分析

於氣態冷媒洩漏試驗中，最佳模型從 V33($|r|>0.4$) 的 CHAID 模型變為相關係數 $|r|>0.6$ 時之 GLR 模型 V24。屬性共有 16 個，分別為：設備運轉分鐘數、冷媒量、功因、瓦時、壓縮機吐出口溫度(T1)、油分離器入口溫度(T2)、油分離器出口溫度(T3)、冷凝器

冷媒入口溫度(T4)、冷凝器入風溫度(T5)、庫內溫度(T8)、蒸發器回風口溫度(T11)、蒸發器出風口溫度(T12)、蒸發器溫度(T13)、蒸發器冷媒出口溫度(T14)、室外溫度(T15)、壓縮機冷媒入口溫度(T16)，如圖 16。

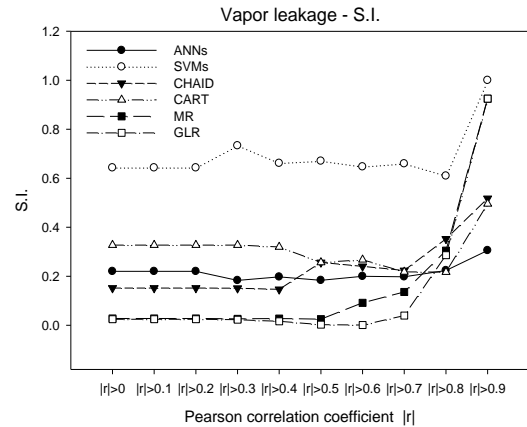


圖 16、氣態冷媒洩漏試驗綜合性指標(S.I.)分析

為結合資料探勘技術與冷凍產業界判斷之性能依據，本研究接續分析液態及氣態冷媒洩漏試驗結果最佳模型預測之性能係數 C.O.P.與冷凍能力間之關係。本文計算之冷凍能力(kJ/kg)定義為：蒸發器冷媒出口溫度對應之焓值減去蒸發器冷媒入口溫度對應之焓值所得。液態冷媒洩漏試驗最準確模型為 ANNs 方法的 L19 模型，圖 17 為不同冷媒量對液態冷媒洩漏之冷凍能力與性能係數之影響，圖中可知當液態冷媒洩漏至 1kg 時，其冷凍能力僅從 200 上升至 205，代表冷媒量為 1kg 時，設備運轉為非穩態狀態，已無冷凍能力，故僅針對冷媒量 6kg-2kg 討論。




圖 17、ANNs 模型(L19)性能係數與冷凍能力分析 (6kg-1kg)

圖 18 為 6kg-2kg 冷媒量對液態冷媒洩漏之冷凍能力與性能係數影響之關係圖。由圖可知，當冷媒量降為 2kg 時，雖然其冷凍能力及性能係數值高，但其降溫速度慢，而當冷凍能力值為 177 以下，設備運轉進入穩態，而冷媒量為 6kg 時之降溫速度快但其性能並不若 3kg 至 6kg 佳。實驗結果發現，考慮相同冷凍能力之液態冷媒充填量為 3kg 時之性能狀態為最佳。




圖 18、ANNs 模型(L19)性能係數與冷凍能力分析 (6kg-2kg)

氣態冷媒洩漏試驗最準確模型為 GLR 方法的 V24 模型，其參數設定：Distribution 為 Normal、Parameter for negative binomial 設定為 1.0、Link function 設定為 Identity；在 Parameter estimation，方法為 Hybrid·Maximum fisher scoring iterations 設為 1、Scale parameter method 設定為 Maximum likelihood estimate、Value 為 1.0。圖 19 為不同冷媒量對氣態冷媒洩漏之冷凍能力與性能係數之影響，類似的情況當氣態冷媒洩漏至 1kg 時，設備運轉為非穩態狀態，並無冷凍能力，故亦僅針對冷媒量 6kg 至 2kg 討論。由氣態冷媒不同充填量對冷凍能力及性能係數影響圖(圖 20)來看，當冷媒填充量為 2kg 時和 1kg 一樣，無冷凍能力，原因為抽取氣態冷媒，使蒸發器無法吸熱，無法正常運作所造成。再者，氣態冷媒洩漏趨勢不似液態冷媒洩漏一樣，係因當冷媒由液態轉為氣態時，會有不穩定狀態發生。由此可知，氣態冷媒洩漏對於冷凍設備冷凍能力及性能係數影響較大，故探討如何將氣態冷媒洩漏對系統影響程度降低，可為後續研究方向之一。

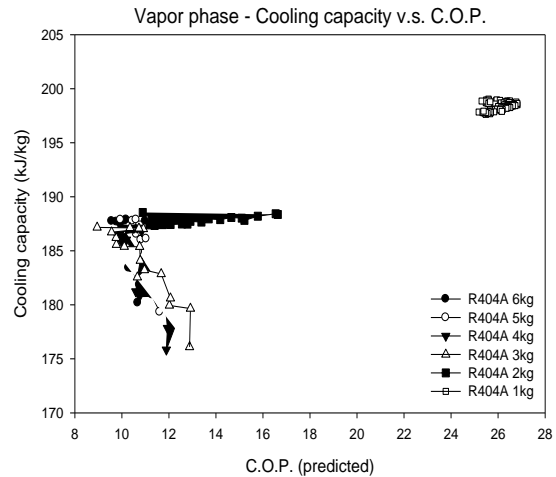


圖 19、GLR 模型(V24)性能係數與冷凍能力分析 (6kg-1kg)




圖 20、GLR 模型(V24)性能係數與冷凍能力分析 (6kg-2kg)

六、結論與建議

本研究的實驗對象為冷凍設備，試驗分為兩部份：液態冷媒洩漏以及氣態冷媒洩漏。研究目的為應用六種資料探勘技術預測不同冷媒量之冷凍設備性能係數 C.O.P.，性能係數能協助業界判別設備性能是否出現異常，提早做預防措施。本研究著重於分析監測屬性與性能係數間之關係，及應用資料探勘技術建模達到預測之目的。再者，為結合冷凍產業界判斷性能方法，分析液態、氣態不同冷媒充填量，對設備運轉之冷凍能力及性能係數之影響，綜合以下結論：

1. 液態冷媒洩漏試驗結果顯示，不同相關係數 r 分析當中，最能準確預測冷凍設備性能係數者為類神經網路模型。其中又以相關係數 $|r|>0.6$ 時之類神經網路模型(L19)最能精準預測設備性能係數(C.O.P.)，

MAPE 值為 8.257%，採用預測屬性數目共 11 個，包含：冷媒量、瓦時、冷凝器冷媒出口溫度(T7)、庫內溫度(T8)、蒸發器回風口溫度(T11)、蒸發器出風口溫度(T12)、蒸發器溫度(T13)、蒸發器冷媒出口溫度(T14)、室外溫度(T15)、壓縮機冷媒入口溫度(T16)、蒸發器出口冷媒壓力(P4)。

2. 氣態冷媒洩漏試驗而言，最能準確預測性能係數模型為廣義線性迴歸模型(GLR)，相關係數為 $|r| > 0.6$ ，MAPE 為 10.665%，採用預測屬性數目共 16 個，包含：設備運轉分鐘數、冷媒量、功因、瓦時、壓縮機吐出口溫度(T1)、油分離器入口溫度(T2)、油分離器出口溫度(T3)、冷凝器冷媒入口溫度(T4)、冷凝器入風溫度(T5)、庫內溫度(T8)、蒸發器回風口溫度(T11)、蒸發器出風口溫度(T12)、蒸發器溫度(T13)、蒸發器冷媒出口溫度(T14)、室外溫度(T15)、壓縮機冷媒入口溫度(T16)。
3. 經由資料探勘分析可知，利用較少之屬性即可於相當程度下準確預測性能係數(C.O.P.)值，藉此可減少感測點安裝數量及監測成本。其中又以蒸發器出風口溫度(T12)、蒸發器溫度(T13)、蒸發器冷媒出口溫度(T14)、壓縮機冷媒入口溫度(T16)、蒸發器冷媒出口壓力(P4)影響氣態及液態之冷媒洩漏為甚(表 5)。
4. 冷凍設備之冷媒充填量與冷凍能力及性能係數相關，故在判斷設備性能好壞時，需同時考慮其降溫速度及冷凍能力，方能選擇最佳的冷媒充填量，不致造成設備冷媒不足或過量情況，達到擷節成本與節能減碳的目標。
5. 就本實驗設備面積 3.24 M² 的組合式冷凍(藏)庫、5 馬力壓縮機，及不考慮外在環境因素、冷凍庫循環系統無負載運轉、庫內溫度在 15 分鐘內由 +20℃ 下降至 -20℃ 等條件下；由實驗數據資料分析：冷媒填充量為 3kg 時，可使冷凍設備運轉之性能狀態達到最佳的效果；且氣態冷媒洩漏異常對冷凍庫之運轉性能的影響程度，較液態冷媒為甚。

本研究分析結果希望能提供業界參考，準確判斷量測電能屬性間之相關性，於重要設備出入口安裝

感測器即可預測設備性能係數，進而節省不必要之成本花費。

後續研究可探討不同冷媒量下之性能係數對設備造成異常之可能原因，建構設備異常與相關性之特徵資料庫，透過遠端監測系統分析設備訊號及特徵，建立異常反應機制點與處理作業流程，並量測排除異常對耗(節)能之影響。此外，可依資料倉儲非時變性資料庫建立冷凍時的耗電量反應預測模式，判讀用電行為，提出節能策略。

七、誌謝

本研究承蒙行政院國家科學委員會多年期研究計畫「智慧電網監測資料探勘技術流程建構與用電異常預測即時反應系統開發」及行政院勞委會職訓局桃園職業訓練中心於研究執行期間的支持與協助，特此致謝。

八、參考文獻

1. Ammar Ahmeda, A., Korresb, N. E., Ploennigsc, P., Elhadid, H. and Karsten Menzela, 2011, "Mining building performance data for energy-efficient operation," *Advanced Engineering Informatics*, Vol. 25, No. 2, pp. 341-354.
2. Al-Saba, T. and El-Amin, I., 1999, "Artificial neural networks as applied to long-term demand forecasting," *Artificial Intelligence in Engineering*, Vol. 13, No. 2, pp. 189-197.
3. Arcaklioglu, E., Eriş en, A. and Yilmaz, R., 2004, "Artificial neural network analysis of heat pumps using refrigerant mixtures," *Energy Conversion and Management*, Vol. 45, No. 11-12, pp. 1917-1929.
4. Breiman, L., Friedman, J. H., Olshen, R. A. and Stone, C. J., 1984, *Classification and Regression Trees*. New York, Chapman and Hall/CRC.
5. Chen, C. S., Tzeng, Y. M., and Hwang, J. C., 1996, "The application of artificial neural networks to substation load forecasting," *Electric Power Systems Research*, Vol. 38, No. 2, pp. 153-160.

6. Chou, J. S., Y. Tai, Y. and Chang, L. J., 2010, "Predicting the development cost of TFT-LCD manufacturing equipment with artificial intelligence models," *International Journal of Production Economics*, Vol. 128, No. 1, pp. 339-350.
7. Haykin, S., 1999, *Neural networks: a comprehensive foundation*, 2nd Edition, Prentice Hall.
8. Kao, W. K., Chen, H. M. and Chou, J.S., 2011, "Aseismic ability estimation of school building using predictive data mining models," *Expert Systems with Applications*, Vol. 38, No. 8, pp. 10252-10263.
9. Li, T.-Y., Chen, Y., Yang, M., Mu X.-W., 2008, "Data mining model based on improved fuzzy k-means algorithm and neural network algorithm," *Dalian Haishi Daxue Xuebao/Journal of Dalian Maritime University*, Vol. 34, No. 4, pp. 37-40+44.
10. Liu, C. and Yi, H., 2011, Research on power system load forecasting model based on data mining technology, 2010 International Conference on Intelligent System Design and Engineering Application, No. 2, pp. 240-243.
11. Liu, D., Yuan, Y., and Liao, S., 2009, "Artificial neural network vs. nonlinear regression for gold content estimation in pyrometallurgy," *Expert Systems with Applications*, Vol. 36, No. 7, pp. 10397-10400.
12. Lo, S. C. and Lin, C. C., 2009, Applying back propagation neural network and sequential pattern mining to construct corporation crisis prediction model - A case of Taiwan' s Electronic Industry, *IEEE Toronto International Conference - Science and Technology for Humanity, TIC-STH 2009*, pp. 409-414.
13. Mandal, P., Senjyu, T. and Funabashi, T., 2006, "Neural networks approach to forecast several hour ahead electricity prices and loads in deregulated market," *Energy Conversion and Management*, Vol. 47, No. 15-16, pp. 2128-2142.
14. Orenstein, T., Kohavi, Z. and Pomeranz, I., 1995, "An optimal algorithm for cycle breaking in directed graphs," *Journal of Electronic Testing*, Vol. 7, No. 1-2, pp. 71-81.
15. Park, J. H., Park, Y. M. and Lee, K.Y., 1991, "Composite modeling for adaptive short-term load forecasting," *IEEE Transactions on Power Systems*, Vol. 6, No. 2, pp. 450-457.
16. Pitt, B. D. and Kirschen, D. S., 1999, "Application of data mining techniques to load profiling," *IEEE Power Industry Computer Applications Conference*, pp. 131-136.
17. Saab, S., Badr, E. and Nasr, G., 2001, "Univariate modeling and forecasting of energy consumption: The case of electricity in Lebanon," *Energy*, Vol. 26, No. 1, pp. 1-14.
18. Ş ahin, A. T., 2011, "Performance analysis of single-stage refrigeration system with internal heat exchanger using neural network and neuro-fuzzy," *Renewable Energy*, Vol. 36, No. 10, pp. 2747-2752.
19. Salzberg, S. L., 1997, "On comparing classifiers: Pitfalls to avoid and a recommended approach," *Data Mining and Knowledge Discovery*, Vol. 1, No. 3, pp. 317-328.
20. Samanta, B., Bird, G.L., Kuijpers, M., Zimmerman, R.A., Jarvik, G.P., Wernovsky, G., Clancy, R.R., Licht, D.J., Gaynor, J.W. and Nataraj, C., 2009, "Prediction of periventricular leukomalacia. Part I: Selection of hemodynamic features using logistic regression and decision tree algorithms," *Artificial Intelligence in Medicine*, Vol. 46, No. 3, pp. 201-215.
21. Scheetz, L.J., Zhang, J. and Kolassa, J., 2009, "Classification tree modeling to identify severe and moderate vehicular injuries in young and

- middle-aged adults,” *Artificial Intelligence in Medicine*, Vol. 45, No. 1, pp. 1-10.
22. Ş encan, A., 2007, “Modeling of thermodynamic properties of refrigerant/absorbent couples using data mining process,” *Energy Conversion and Management*, Vol. 48, No. 2, pp. 470-480.
23. Ş encan, A., 2007, “Modeling of thermodynamic properties of refrigerant/absorbent couples using data mining process,” *Energy Conversion and Management*, Vol. 48, No. 2, pp. 470-480.
24. Shmueli, G., Patel, N.R. and Bruce P.C., 2007, *Data Mining for Business Intelligence: Concepts, Techniques, and Applications in Microsoft Office Excel with XLMiner*, John Wiley and Sons, New Jersey.
25. SPSS, 2007, *Clementine 12.0 Algorithms Guide SPSS*.
26. Swider, D. J., 2003, “A comparison of empirically based steady-state models for vapor-compression liquid chillers,” *Applied Thermal Engineering*, Vol. 23, No. 5, pp. 539-556.
27. Taylor, J. W. and Buizza, R., 2003, “Using weather ensemble predictions in electricity demand forecasting,” *International Journal of Forecasting*, Vol. 19, No. 1, pp. 57-70.
28. Tso, G. K. F. and Yau, K. K. W., 2007, “Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks,” *Energy*, Vol. 32, No.9, pp. 1761-1768.
29. Ye, B., Guo, C., and Cao, Y., 2004, Short-term load forecasting using a new fuzzy modeling strategy. *The 5th World Congress on Intelligent control and Automation*, Hangzhou, P.R. China.
30. Yezioro, A., Dong, B. and Leite, F., 2008, “An applied artificial intelligence approach towards assessing building performance simulation tools,” *Energy and Buildings*, Vol. 40, No. 4, pp. 612-620.
31. Ying, L. C. and Pan, M. C., 2008, “Using adaptive network based fuzzy inference system to forecast regional electricity loads,” *Energy Conversion and Management*, Vol. 49, No. 2, pp. 205-211.
32. 李涵茵，2011，「低電價、深省思」，經濟部能源局能源報導，2011年2月，第35-38頁。
33. 湯政仁，2010，「智慧電表國內發展現況」，經濟部能源局能源報導，2010年5月，第26-29頁。

投稿日期：2012/10/03。

送審日期：2012/10/06。

審畢日期：2012/10/29。

修改日期：2012/11/01。

接受日期：2012/11/03。