

建立改良型粒子群演算法求解多目標複雜系統 非完美預防維修模式

蔡勝旺^{1*} 王春和²

^{1*}國防大學理工學院國防科學研究所

²國防大學理工學院動力及系統工程學系

摘要

本研究建構一個多目標非完美預防維修模式，同時決定系統中個別次系統的維修週期與維修活動，以同時最佳化系統平均可用度與維修總成本。此外，發展一個改良型粒子群演算法，其中採用柏拉圖為基的技術，結合非凌駕解與基因演算法之進化機制概念，經由時變機制引導粒子的搜尋方向，並提出一調整機制，處理粒子落入不可行解區域的問題，進而有效求解所建構的維修模式，以獲得多樣化的維修方案，決策者可以根據任務需求與維修資源的限制，選取最適合的方案。本研究導入反應曲面法，決定搜尋參數的最佳設定值，最後以一個文獻的案例，驗證所提出方法的有效性。

關鍵字：非完美預防維修，粒子群演算法、多目標最佳化

Optimizing the Multi-Objective Preventive Maintenance Model for Complex Systems Using a Proposed IPSO Algorithm

Sheng-Wang Tsai^{1*} and Chung-Ho Wang²

^{1*}Graduate School of Defense Science, Chung Cheng Institute of Technology, National Defense University

²Department of Power Vehicle and Systems Engineering, Chung Cheng Institute of Technology, National Defense University

ABSTRACT

This study aims to optimize a multi-objective imperfect preventive maintenance model for complex systems. Two objectives including the total maintenance cost and the mean system availability are optimized by determining the maintenance period and maintenance activities regarding each component simultaneously. To efficiently solve the established model, this study proposes an improved particle swarm optimization (IPSO) algorithm. The non-dominated solutions from the idea behind Pareto optimization is designed to determine the superior particles. Furthermore, time-varying mechanisms associated with search parameters of the IPSO are utilized to enhance the particles search capability. An adjustment mechanism is developed to deal with the problem particles falling into the infeasible area. Optimizing the established model using the proposed IPSO can obtain diversified multi-objective solutions efficiently. Decision makers can easily determine the most appropriate maintenance alternative to constitute a maintenance strategy. A case from past study verifies the effectiveness of the IPSO algorithm in optimizing the established BOIPM model.

Keywords: Imperfect preventive maintenance, PSO, Multi-objective optimization

文稿收件日期 101.7.12; 文稿修正後接受日期 102.7.25; *通訊作者
Manuscript received July 12, 2012; revised July 25, 2013; *Corresponding author

一、研究背景及目的

求解預防性維修最佳化 (preventive maintenance optimization) 模式是一個相當困難的問題，求解過程中往往需消耗大量演算時間[1]，而建立一限制最佳化模式 (constrained optimization models)，在實務上可以更滿足管理者對系統性能的多項基本要求，故隨著欲處理的元件增加、系統結構擴增或處理問題的複雜度提升，例如：同時最佳化串並聯系統各元件的維修時間與維修活動，將大幅增加求解的複雜度，導致傳統的數學方法無法在有效的時間內求得確切最佳解，因此，為簡化預防維修的數學模式，多數文獻僅探討固定週期下，決定元件最佳維修活動組合[2-3]或在固定維修活動下，決定元件最佳維修週期[4-5]，且僅考量單一最佳化目標，例如：維修成本最小化或系統可靠度值最大化等，來規劃串並聯系統之維修策略，僅提供決策者有限的維修策略資訊，而建立多目標維修策略模式，有助益於管理者對系統設備的需求，同時最佳化多個維修績效指標，更可提供具差異性的多目標非凌駕解 (non-dominated solutions) 之可行方案，決策者可依實際資源的限制或對系統性能的要求，從中選取最適合的方案。

由於求解預防性維修最佳化問題的高度複雜性，萬用啟發式演算法 (meta-heuristic algorithms)，已經廣泛地用來求解此類最佳化問題並獲得良好的成效，例如：可靠度系統結構設計、複聯配置 (redundancy allocation) 問題[6]及可靠度分析[7]等，期望有效求解預防性維修最佳化問題。另外，針對求解限制最佳化的問題模式，雖然萬用啟發式演算法的隨機搜尋機制，可促使演算法跳脫區域位置，以利逼近全域最佳解，但亦導致搜尋過程中易落入不可行解區域，而大幅限制演算法的求解成效，而預防維修模式最佳化問題，則需要考量求解模式限制條件的特性，例如：系統容許最低可靠度限制、維修成本與時間等資源限制，發展一個有效的調整機制，來處理演算法陷入不可行解的問題[8-10]。粒子群最佳化 (PSO, particle swarm optimization) 演算法為 Kennedy 與 Eberhart[11]於 1995 年提出，典型 PSO 僅適用於處理連續型最佳化問題，若考量一個同時決定維修週期與維修活動的預防維修策略

問題，由於維修週期為連續型變數，維修活動係屬於離散型變數，因此運用 PSO 於求解這類型維修策略最佳化問題時，必須要克服典型 PSO 限制，建構一個亦適用於求解離散型變數的 PSO，來拓展 PSO 的實務應用性。

本研究目的乃針對非完美複雜系統，建構一個同時最佳化維修總成本與系統平均可用度的多目標週期性預防維修最佳化模式，並建立適當的限制條件，以滿足實務上對系統性能的基本需求，其中維修策略的制定將同時決定系統中個別次系統最適的維修週期與每一個維修時間點上最適的維修活動，所考量的維修活動包括：保養、維修及置換，另外當次系統發生失效時，則實施最小修復 (minimal repair) 的矯正性維修，使次系統功能回復至失效前的狀態，從而建立一個非完美維修最佳化模式，來決定最適的維修策略。此外，本研究以 PSO 演算法具有概念簡單、實作容易且搜尋速度快等優點的基礎下，建立一個可以同時求解維修週期與維修活動的維修策略之改良型粒子群演算法 (IPSO, improved PSO)，其中結合多目標非凌駕解與基因演算法 (GA, genetic algorithm) 中「適者生存，不適者淘汰」之進化機制概念，並導入所建構的 IPSO 演算法的搜尋機制中，來有效求解所建構的維修模式，以獲得具多樣性的最適維修策略方案。此外，本研究導入實驗設計法中的反應曲面法 (RSM, response surface methodology)，經由有系統的實驗規劃與實驗數據解析，決定 IPSO 搜尋參數的最佳設定值，進而活化粒子的搜尋能力，以提升求解成效。

二、文獻回顧

2.1 非完美維修

預防維修策略依維修時間間隔可區分為週期預防維修策略與非週期預防維修策略，由於週期預防維修策略易於管理與實施，為實務上最廣泛使用的維修策略，而串並聯系統的週期預防維修策略，更能夠適切地反應一個系統於元件維修後的可靠度，當系統完成維修之後，其狀況通常介於全新與原來舊系統性能之間，此稱為非完美矯正性或預防性維修[12]，實施預防維修可增加設備的壽命和降低設備

於任務執行中失效的機率[13]，Zequeira 與 Bérenguer[2]利用改善因子法，以成本最小化為目標，建立一非完美維修模型，來決定最佳預防維修策略；Tsai 等人[3]針對具磨耗及老化特性之機械元件，以改善因子法建立動態可靠度(dynamic reliability)之非完美維修模型，其中以單位成本壽命(unit-cost life)最大化為目標函數，系統可靠度為限制條件，首先利用維修利益獲得最佳維修週期，再以基因演算法求解不同維修活動包括：不實施維修、執行簡單性預防維修或實施預防性更換等，其單位維修成本所能夠延長元件壽命的增益，決定元件於維修週期時間點上最適的維修活動；Leou[5]以發電廠為研究案例，以總維修成本最小化為目標，建立維修策略模式，結合基因演算法與模擬退火法，求解維修週期最佳化的問題；Castro[14]以非齊一性之 poisson 過程，來建構系統中元件的失效模式，其中系統元件包括可維修和不可維修兩種，可維修模式假設可維修元件之失效率相依於不可維修元件之總數，以系統成本最小化為目標，求解系統元件無法再經由預防維修回復至系統最低容許性能，必須執行置換的這段期間之最佳的維修策略，包括預防維修次數及維修週期；Nakagawa 與 Mizutani[15]考量有限時間範圍之維修策略，相較於無限時間範圍的維修策略，較能符合實務維修的情況，因此建立一個非完美預防維修模型，納入週期更換-最小維修、部分更換及簡單更換，決定任務時間內的最佳維修活動，以最小化維修總成本；Liao 等人[16]提出一個可靠度為中心的連續監測退化系統之預防性維修模型，藉由定期維修確保系統的可靠度，由於使用率的增加和系統的年齡惡化，當系統的可靠度達到最低容許可靠度值，即實施非完美維修以恢復系統性能，此預防維修模型乃在求解最低容許可靠度值和預防性維修的週期，期使系統的操作成本最小化；Tsai 等學者[17]考量保養、維修及置換等三種預防維修活動，利用 AGREE 方法(Advisory Group on the Reliability of Electronic Equipment method)[18]，評估複雜系統的可靠度，公式如下：

$$R_s(t) = \prod_{i=1}^k \{1 - \alpha_i [1 - R_i(t)]\} \quad (1)$$

其中參數 $R_s(t)$ 表示系統在 t 時間點的可靠度，參數 α_i 為第 i 個次系統失效而使系統失效的機率， α_i 值介於 0 與 1 之間，當 $\alpha_i=1$ ，表示次系統間組合為一串聯系統，參數 k 表示次系統的數量，參數 $R_i(t)$ 表示次系統 i 在 t 時間點的可靠度。Tsai 等學者[17]以此公式建立一個非完美預防維修模型，首先以系統可用度最大化為目標函數，從而計算個別次系統的維修週期，並從中選取最小的維修週期作為系統中所有次系統的維修週期，接著利用維修利益分析模式，分別求出各次系統於每一個維修週期點，實施保養、維修及置換等三種預防維修活動之維修利益值，從中選取其維修利益值最大的維修活動，為此次系統在此一維修週期點上之預防維修活動，重複決定維修利益值最大的分析程序，決定個別次系統於任務時間內之各維修週期點上的最佳預防維修活動。

2.2 多目標最佳化

處理多個目標函數需同時最佳化之問題時，這些函數間往往存在著衝突性，如何尋求一個最佳的妥協解(compromise solution)是需要解決的問題，一般利用柏拉圖最佳化前緣(pareto-optimal front)呈現多目標之間的相互衝突性[19]，最佳化多目標解的求解程序中，除了希望逼近多目標的效率前緣解外，維持最佳解的多樣性亦為一個求解的重要目標。Busacca 等人[20]以核能電廠為研究對象，針對冷卻系統之高壓噴射設備的系統安全問題，建立一個多目標維修策略模式，包括：以平均可用度(mean availability)最大化、維修與檢查成本最小化與工人暴露於輻射時間最小化，並將多目標非凌駕解概念，導入基因演算法的搜尋機制中，求解最佳維修與檢查週期；Nosoohi 與 Hejazi[21]考量實際問題的需求，將置換維修作業納入預防維修模式，以 ε -constraint 法為基礎，發展一多目標演算法求解，從而決定任務時間內最佳的維修策略；Tian 等人[22]提出了雙目標為基礎的維修模式，其中包括可靠度最大化及維修成本最小化，其開發了一個物理規劃逼近法，取代以目標權重調整來獲致折衷方案的傳統方法，使決策者能有效率的達成目標；Ray 與 Liew[23]

結合柏拉圖解，即進化粒子群的概念，以評估解集合鄰近粒子的密度，以產生多樣性解的多目標解；Toscano 與 Coello[24]引用柏拉圖非凌駕解的概念，來決定粒子飛行的方向，首先以分群的技術將粒子分成數個群體，每個群體均有各自的領導粒子(非凌駕解)，在迭代的過程中，迫使各群體彼此交換訊息以達到解的多樣化。

衡量多目標最佳化演算法求解品質優劣的指標，包括多目標解集合的接近度[25]、離散度[26]與展開度[27]三個指標，接近度是衡量多目標解集合與柏拉圖前緣的接近程度，離散度則是衡量多目標解集合中，其個別解的分散程度，展開度則為評估多目標解集合的廣度，理想的多目標解集合是期望所求的解集合能夠均勻地分佈在柏拉圖前緣上。

2.3 粒子群演算法簡介

2.3.1 粒子群演算法介紹

粒子群最佳化演算法由 Kennedy 與 Eberhart[11]於 1995 年提出，其概念源自群體行為理論，啟發自觀察鳥群或魚群行動時，能透過個體間特別的訊息傳遞方式，使整個團體朝同一方向與目標移動。因此 PSO 具有記憶性並強調粒子間訊息的溝通，其優點為概念簡單、實作容易且搜尋速度快。粒子的移動速度與移動位置，如公式(2)與(3)所示：

$$\mathbf{V}_i^{new} = \omega \cdot \mathbf{V}_i^{old} + c_1 \cdot rand_1 \cdot (\mathbf{P}_i - \mathbf{X}_i^{old}) + c_2 \cdot rand_2 \cdot (\mathbf{P}_g - \mathbf{X}_i^{old}) \quad (2)$$

$$\mathbf{X}_i^{new} = \mathbf{X}_i^{old} + \mathbf{V}_i^{new} \quad (3)$$

其中 \mathbf{X}_i^{old} 為每個粒子現在的位置矩陣； \mathbf{V}_i^{old} 為每個粒子現在的速度向量矩陣； $\mathbf{P}_i - \mathbf{X}_i^{old}$ 為粒子現在位置矩陣和目前區域最佳值粒子間位置矩陣的距離； $\mathbf{P}_g - \mathbf{X}_i^{old}$ 為粒子現在位置矩陣和目前全域最佳值粒子間位置矩陣的距離； \mathbf{X}_i^{new} 為每個粒子更新後的位置矩陣； \mathbf{V}_i^{new} 為每個粒子更新後的速度向量矩陣； ω 為慣性權重的參數值； c_1 與 c_2 為學習因子的參數值； $rand_1$ 和 $rand_2$ 為介於 0 和 1 之間的均勻隨機變數

(uniform random variable)。經由上述不斷更新速度與位置的迭代過程，當演算法停止條件到達時，即停止演算並輸出目前最佳適應函數值與其相對應的粒子位置。

另外針對 PSO 演算法於求解限制最佳化問題，El-Gallad 等人[8]提出一旦粒子落於不可行解區域，則將此粒子回復至前一迭代可行解之狀態，使粒子保持在可行解區域，此方法雖簡單，卻限制粒子的搜尋空間，降低 PSO 的求解效能；Hu 與 Eberhart[9] 則提出僅保留可行解粒子至下一代，此方法使演算迭代過程中可行解粒子愈來愈少，使得求解成效不佳；Parsopoul 與 Vrahatis[10]則提出一懲罰函數，將限制最佳化問題轉換為非限制最佳化問題再求解之，然此方法之缺點在於懲罰係數難於決定。此外，PSO 最初的設計理念是用以求解連續型最佳化問題，透過明確的數學式來表達粒子於連續空間中的位置與速度向量，近年來有些研究提出以 PSO 求解離散型最佳化問題，如 Chen 等人[28]利用所發展的離散型 PSO 演算法，求解有關物理設計中之具多目標特性的超大規模積分 (VLSI, very large scale integrated)最佳化模式，目標式為最小化的佈局面積及最小化總互連導線長度，其所發展的離散型 PSO 演算法係將粒子以整數序列編碼，每個數字代表一個模塊，並引用基因演算法中交配及突變的概念，經由迭代，找出多目標非凌駕解；Gao 等人[29]提出一種改良的離散型二進制 PSO 演算法，求解研究合作夥伴選擇的最佳化問題，此類問題通常是一個組合最佳化問題，包括運行成本，反應時間和失敗的風險等關鍵因素，此研究發展一種位置更新公式來降低粒子落入區域最佳解的機率，其方法為給一個具有隨迭代而改變的時變係數，據此將粒子的速度分成三個區域，並根據落入該區域的粒子，決定粒子的位置保持不變或移動幅度的大小，由於時變係數隨著迭代增加而遞減，所以這三個區域可以適時地改變範圍，有效往全域最佳解逼近；Yare 等人[30]以離散型粒子群演算法(DPSO, discrete PSO)可有效應用於解決大規模的多目標最佳化問題，並在電力系統中得到了廣泛應用之特點，以一種改進的離散型粒子群演算法(MDPSO, modified DPSO)來求解最佳的預防性維修計劃，以使機組的電力系統運作的成本及可靠度最佳化，其

中必須要同時滿足系統負載需求和人員的限制，MDPSO 乃把 GA 中的突變率引入 DPSO，藉以修正位置向量，主要目的為增加族群的多樣性，避免粒子間過於接近而陷入區域最佳解，因而提升 DPSO 在全域空間的搜索效能，最後並以 MDPSO 來求解研究案例，結果均較以 GA 及 DPSO 求解所獲得的結果優異；Yare 與 Venayagamoorthy[31]以多種群體改進的離散型粒子群演算法 (MS-MDPSO, multiple swarms-MDPSO) 求解最佳預防維修計畫，以解決發電機組檢修計畫 (GMS, generator maintenance scheduling) 的問題，並滿足系統的負載需求、允許的維修窗口及人員和資源限制，以提高電力系統的經濟效益及保證運行的可靠性，此研究以多種初始族群分別進行個群體的最佳值運算，利用線性時變慣性權重帶入 MDPSO 之速度更新公式，再把 GA 中的突變率引入 MDPSO，藉以修正全域最佳解向量，再由多群體中找出全域最佳解，決定最佳的預防維修計畫。

2.3.2 粒子群演算法的改善機制

PSO 被廣泛應用於解決複雜數學最佳化問題，典型 PSO 之搜尋參數皆為一固定常數，Shi 與 Eberhart[32]及 Suganthan[33]針對 PSO 的搜尋參數，提出線性時變機制 (linear time-varying mechanism)，以提升演算效果，說明如下：

一、線性時變慣性權重

線性時變慣性權重公式如下[32]：

$$\omega(k) = \omega_{\max} - \frac{(\omega_{\max} - \omega_{\min})}{k_{\max}} \times k \quad (4)$$

其中 $\omega(k)$ 為第 k 次迭代時的慣性權重值， k 為當時迭代次數， k_{\max} 為演算法最大迭代次數， ω_{\max} 、 ω_{\min} 為慣性權重參數的最大值及最小值，隨著迭代數的增加而權重值 ω 也將會線性遞減；當慣性權重值 ω 較大時，有利於粒子於廣泛空間中搜尋較佳解，而較小的慣性權重值有利於演算法收斂與提高粒子的搜尋精度。

二、線性時變學習因子

線性時變學習因子公式如下[33]：

$$c_1(k) = c_{1\max} - \frac{(c_{1\max} - c_{1\min})}{k_{\max}} \times k \quad (5)$$

$$c_2(k) = c_{2\min} + \frac{(c_{2\max} - c_{2\min})}{k_{\max}} \times k \quad (6)$$

其中 $c_1(k)$ 為個體學習因子於第 k 次迭代時的值， $c_2(k)$ 為群體學習因子於第 k 次迭代時的值， k_{\max} 為演算法最大迭代次數， $c_{1\max}$ 、 $c_{1\min}$ 及 $c_{2\max}$ 、 $c_{2\min}$ 為時變學習因子參數的最大值及最小值，隨著迭代次數的增加， c_1 值會線性遞減， c_2 值會線性遞增； c_1 值初期較高可使粒子廣泛搜尋其周圍區域， c_2 值初期較低可使粒子探索移動時不偏重群體最佳解位置，隨迭代增加， c_1 值遞減及 c_2 值遞增讓所有粒子能朝向群體最佳解位置搜尋，此機制可減少 PSO 陷入區域最佳解之機率[34]。Hajinejad 等人[35]及 Kuo 等人[36]應用時變機制有效地求解排程最佳化問題，Chaturvedi 等人[37]則用於處理能源管理系統的經濟調度問題。

2.4 反應曲面法

反應曲面法為一結合實驗設計、數學應用與統計分析之技術，探討多個獨立變數與某一個反應變數之間的數學模式關係，經由實驗設計使實驗者在所關切的實驗區域內 (Interest of Experimental Region)，以有系統的方式進行實驗並蒐集實驗所需的反應值與變數值的資料，從而有效率地建立多個獨立變數與某一個反應變數之間的數學模式，並根據反應值的特性 (望大或望小) 決定反應曲面中獨立變數的最佳值。Myers 和 Carter[38]提出雙反應曲面法 (DRSM, double response surface methodology) 處理具有兩個反應變數同時需最佳化的問題，DRSM 將考量之兩個反應變數依其重要性區別為主要的反應變數 (y_p , primary response) 與次要或限制性的反應變數 (y_s , constraint response)，並分別適配二次反應曲面模式，如下所示：

$$y_p = \beta_0 + \sum_{i=1}^k \beta_i x_i + \sum_{i=1}^k \beta_{ii} x_i^2 + \sum_{i < j}^k \beta_{ij} x_i x_j + \varepsilon_p \quad (7)$$

$$y_s = \gamma_0 + \sum_{i=1}^k \gamma_i x_i + \sum_{i=1}^k \gamma_{ii} x_i^2 + \sum_{i < j}^k \gamma_{ij} x_i x_j + \varepsilon_s \quad (8)$$

其中 $\beta's$ 與 $\gamma's$ 表示未知的係數， ε_p 與 ε_s 表示隨機誤差，並依循平均值為零的常態分配，主要反應變數預測值 \hat{y}_p 與次要反應變數預測值 \hat{y}_s 可以矩陣的方式表達如下：

$$\hat{y}_p = b_0 + \mathbf{x}'\mathbf{b} + \mathbf{x}'\mathbf{B}\mathbf{x} \quad (9)$$

$$\hat{y}_s = c_0 + \mathbf{x}'\mathbf{c} + \mathbf{x}'\mathbf{C}\mathbf{x} \quad (10)$$

其中 $\mathbf{x} = (x_1, \dots, x_k)'$ 表示由獨立變數所組成的向量、 $b_0 = \hat{\beta}_0$ 、 $c_0 = \hat{\gamma}_0$ 、 $\mathbf{b} = (\hat{\beta}_1, \dots, \hat{\beta}_k)'$ 、 $\mathbf{c} = (\hat{\gamma}_1, \dots, \hat{\gamma}_k)'$ ，且

$$\mathbf{B} = \begin{bmatrix} \hat{\beta}_{11} & \hat{\beta}_{12}/2 & \dots & \hat{\beta}_{1k}/2 \\ & \hat{\beta}_{22} & \dots & \hat{\beta}_{2k}/2 \\ & & \ddots & \\ \text{sym.} & & & \hat{\beta}_{kk} \end{bmatrix} \quad \text{及}$$

$$\mathbf{C} = \begin{bmatrix} \hat{\gamma}_{11} & \hat{\gamma}_{12}/2 & \dots & \hat{\gamma}_{1k}/2 \\ & \hat{\gamma}_{22} & \dots & \hat{\gamma}_{2k}/2 \\ & & \ddots & \\ \text{sym.} & & & \hat{\gamma}_{kk} \end{bmatrix}。$$

DRSM 最佳化的程序為在滿足 $\hat{y}_s = c$ 的前提下，其中 c 為常數，決定矩陣 \mathbf{x} 值來最佳化 \hat{y}_p 值。此外，Myers 與 Carter[38]建議將限制式 $\mathbf{x}'\mathbf{x} = \rho^2$ 納入 DRSM 模式中，以確保最佳化之 $\mathbf{x} = (x_1, \dots, x_k)'$ 值，落在獨立變數可能的範圍內，其中 ρ 值可以依據工程實務上的需求來決定之。

2.5 文獻總結

根據前面小節所述之相關文獻內容，總結如下：

- 一、大部份文獻均探討特定維修活動下，在符合相關維修成本、可用度或可靠度條件下，探討維修週期最佳化問題，或在既有的維修週期上，探討最佳的維修活動，卻大幅限制目標值的求解成效，或雖同時考

量維修排程與維修活動的最佳化，但採二階段的解法，雖可簡化求解的複雜度，但亦限制求解成效，因此，建立一個同時求解維修週期與維修活動的數學模式，可以在全域的可行解區間內，獲得最有利的目標值，然必須克服求解複雜度增加的困難。

- 二、求解維修週期屬連續型最佳化問題，求解維修活動問題則屬離散型組合最佳化問題，而典型 PSO 演算法較適合求解連續型問題，本研究針對所建構的維修模式，發展一 IPSO 演算法，使 PSO 能夠求解連續型之維修週期與離散型之維修活動同時最佳化問題。

三、研究方法

3.1 模式的基本假設

本研究建構之維修模式，包括週期性預防維修與矯正性維修，基本假設如下：

- 一、週期性預防維修活動包括：
 - 1.保養(a)：次系統實施保養後，無法降低次系統之失效率(hazard rate)，僅能使次系統惡化速度趨緩。
 - 2.維修(b)：次系統實施維修後，可降低次系統在維修時間點的失效率，並減緩次系統的惡化速度。
 - 3.置換(c)：次系統實施置換後，回復至新且好的狀態。
- 二、矯正性維修活動係只當次系統失效時，即實施最小修理，使次系統回復至失效前狀態。

3.2 模式建構

本研究引用 Tsai 等人[17]所提評估一複雜系統的可靠度公式，並以改善因子法，評估個別次系統實施維修活動後可靠度回復程度，從而建構一個同時使維修總成本最小化與系統平均可用度最大化的多目標預防維修模式，其中限制條件為系統在任務時間的系統可靠度不得低於其容許最低可靠度值，模型建構如下：

目標式 1：系統維修總成本最小化

$$C_{sys} = \sum_{k=1}^K \sum_{i=1}^{L_k} \sum_{j=1}^{m_{k,i}} \left[C_{pm,k,i,j} + C_{cm,k,i} \cdot t_{cm,k,i} \cdot \int_{t_{j-1}}^{t_j} h_{k,i,j}(t) dt \right] \quad (11)$$

目標式 2：系統平均可用度最大化

$$A_{mean} = \frac{tp_{k,i} - t_{cm,k,i} \cdot \int_{t_{j-1}}^{t_j} h_{k,i,j}(t) dt}{tp_{k,i} + \sum_i^n t_{pm,k,i}} \quad (12)$$

限制式：

$$R_s(t) \geq R_0 \quad (13)$$

$$R_s(t) = \prod_{k=1}^K \left[1 - \prod_{i=1}^{L_k} (1 - R_{k,i}(t)) \right] \quad (14)$$

$$R_{k,i,j(a)}(t) = R_{int,k,i,j(a)} \cdot R \left(\frac{1}{s_{1,k,i}} (t - (j-1) \cdot tp_{k,i}) \right); \quad (15)$$

$$(j-1) \cdot tp_{k,i} \leq t \leq j \cdot tp_{k,i}$$

$$R_{int,k,i,j(a)} = R_{f,k,i,j-1} \quad (16)$$

$$R_{k,i,j(b)}(t) = R_{int,k,i,j(b)} \cdot R \left(\frac{1}{s_{1,k,i}} (t - (j-1) \cdot tp_{k,i}) \right); \quad (17)$$

$$(j-1) \cdot tp_{k,i} \leq t \leq j \cdot tp_{k,i}$$

$$R_{int,k,i,j(b)} = R_{f,k,i,j-1} + s_{2,k,i} (R_{int,k,i,j-1(c)} - R_{f,k,i,j-1}) \quad (18)$$

$$R_{k,i,j(c)}(t) = R_{int,k,i,j(c)} \cdot R(t - (j-1) \cdot tp_{k,i}); \quad (19)$$

$$(j-1) \cdot tp_{k,i} \leq t \leq j \cdot tp_{k,i}$$

$$R_{int,k,i,j(c)} = R_{int,k,i} \quad (20)$$

$$R_{k,i,j}(t) = e^{-\int_0^t h_{k,i,j}(t) dt} \quad (21)$$

其中 C_{sys} 表示系統維修總成本； K 表示並聯次系統的數量； L_k 表示第 k 個並聯次系統中次系統的數量； k 為並聯次系統編號； i 為次系統編號； j 表示第 j 次實施週期性預防維修； $m_{k,i}$ 為第 k 個並聯次系統中第 i 個次系統在任務時間內實施週期性預防維修的次數； $C_{pm,k,i,j}$ 為第 k 個並聯次系統中第 i 個次系統第 j 次實施任一種預防維修活動的維修成本； $C_{cm,k,i}$ 為第 k 個並聯次系統中第 i 個次系統實施矯正性維修的單位時間之維修成本； $t_{cm,k,i}$ 為第 k 個並聯次系統中第 i 個次系統實施矯正性維修所花費時間； $h_{k,i,j}(t)$ 為第 k 個並聯次系統中第 i 個次系

統在 t 時間點實施第 j 次預防維修活動後的失效率； A_{mean} 表示系統在任務時間的系統平均可用度； $t_{pm,k,i}$ 為第 k 個並聯次系統中第 i 個次系統實施預防維修活動所花費時間； $R_s(t)$ 表示系統在 t 時間點的可靠度； T 表示任務時間； $R_{k,i}(t)$ 表示第 k 個並聯次系統中第 i 個次系統在 t 時間點的可靠度； R_0 表示系統容許最低可靠度； $R_{k,i,j(a)}(t)$ 、 $R_{k,i,j(b)}(t)$ 及 $R_{k,i,j(c)}(t)$ 分別為第 k 個並聯次系統中第 i 個次系統第 j 次實施保養、維修及置換活動後，在 t 時間點之可靠度； $s_{1,k,i}$ 及 $s_{2,k,i}$ 為衡量第 k 個並聯次系統中第 i 個次系統實施非完美維修後，對其可靠度恢復程度影響之改善因子，其值介於 0 與 1 之間， $s_{1,k,i}$ 值的設定乃反應第 k 個並聯次系統中第 i 個次系統維修後，可靠度隨時間下降延緩的趨勢， $s_{2,k,i}$ 值的設定乃反應第 k 個並聯次系統中第 i 個次系統於維修後，可靠度回升的程度，通常改善因子設定值係依專家判斷及估計得出[12]； $R_{int,k,i,j(a)}$ 、 $R_{int,k,i,j(b)}$ 及 $R_{int,k,i,j(c)}$ 分別為第 k 個並聯次系統中第 i 個次系統在第 j 次維修週期初始點實施保養、維修及置換活動後之可靠度值； $R_{f,k,i,j-1}$ 為第 k 個並聯次系統中第 i 個次系統在第 $j-1$ 次維修週期結束點之可靠度值； $R_{int,k,i,j-1(c)}$ 為第 k 個並聯次系統中第 i 個次系統在第 $j-1$ 次維修週期初始點，實施預防維修活動後的可靠度值； $R_{int,k,i}$ 為第 k 個並聯次系統中第 i 個次系統之初始可靠度值，其值通常設定為 0.999； $tp_{k,i}$ 為第 k 個並聯次系統中第 i 個次系統的維修週期，為決策變數。

3.3 建立改良型粒子群最佳化演算法

本研究為改良典型 PSO 僅適用於求解連續型最佳化問題，使 PSO 能夠同時求解連續型之維修週期與離散型之維修活動的最佳化問題，建立 IPSO 演算法，其中引入線性時變參數及採用柏拉圖為基的技術，並提出調整機制，處理粒子落入不可行解區域的問題，本研究建立的 IPSO 演算法共分二階段，分述如下：

階段一：進行粒子編碼

根據求解變數的型態，本研究建立一個混合型粒子，包括：「維修週期編碼」與「維修活動編碼」，其中維修週期編碼部份採連續型

編碼，每個粒子中維修週期的編碼值代表每一次系統的維修週期，若系統中包含 n 個次系統，則以實數編碼產生 n 個編碼值表示維修週期。另外，在維修活動部份採離散型編碼 [28]，每一個粒子中離散型編碼部份的個別編碼值，對應於系統中個別次系統於任務時間的維修活動，所考量的預防維修活動包括：置換、維修、保養及不實施預防維修活動四種，其中置換成本最高，依序為維修與保養，而不實施預防維修活動則無須耗費維修成本，分別以符號 0 表示不實施預防維修活動、1 表示保養、2 表示維修、3 表示置換進行維修活動的編碼，來表示四種不同的維修活動，編碼值愈小表示所需耗費的維修成本愈低，經由隨機方式，可獲得多個不同組合的維修活動編碼，最後合併維修週期編碼與維修活動編碼，即完成求解所建構週期性預防維修模式的一個混合型粒子編碼。

階段二：最佳化維修週期及預防維修活動

步驟 1：建立初始粒子族群

本研究以隨機方式共產生 100 個粒子，分成二個初始粒子族群，其中 50 個粒子用來最小化維修總成本，另外 50 個粒子用來最大化系統平均可用度，以進行粒子的搜尋機制。

步驟 2：計算適應函數值

由於本研究所建構的維修模式，乃是同時最小化維修總成本及最大化系統平均可用度，因此，將每一粒子編碼所對應的預防維修模式解，代入公式(11)-(21)中，分別計算維修總成本與系統平均可用度，形成 IPSO 中的二個適應函數值。

步驟 3：執行混合型粒子的移動機制

由於維修週期屬於連續型變數，因此將公式(4)-(6)之時變參數 [29][31] 設定代入公式(2)中，決定粒子於每一迭代的權重與學習因子的設定值，進而執行粒子移動機制，其中參考 Shi 和 Eberhart [32] 及 Ratnaweera 等人 [39] 所建議之時變機制調整策略，將時變權重的下限值 ω_{\min} 及時變學習因子 $c_{1\min}$ 及 $c_{2\min}$ 下限值訂為 0.4，而時變權重上限值 ω_{\max} 及時變學習因子上限值 $c_{1\max}$ 與 $c_{2\max}$ ，則經由反應曲面法決定最佳的設定值。另外，維修活動為離散型變數，本研究區分維修總成本最小化及系統平均可用度最大化來考量，以維修總成本最小化之粒子族群來看，考量維修活動的編碼值愈小，維

修成本愈低的編碼特性，建立粒子中離散型維修活動編碼的移動機制，經由比較當代粒子於每一次系統個別維修時間點的維修活動編碼值與全域最佳解粒子之維修活動編碼值，若全域最佳解粒子於維修活動編碼值較當代粒子編碼值小，表示維修成本較低，此時使每一代粒子維修活動編碼值往全域最佳解維修活動編碼值方向移動，可以降低系統維修總成本，故該粒子所對應之維修活動編碼值減 1，若全域最佳解粒子於維修活動編碼值，大於或等於當代粒子的編碼值，則該粒子所對應之維修活動編碼值不變動，執行完成維修活動的移動機制後，即完成當代混合型粒子的移動機制；另一系統平均可用度最大化族群亦以相對方式進行混合型粒子的移動機制。此外，針對系統可靠度低於最低容許可靠度值而落入不可行解區域之粒子，所發展的不可行解調整機制，包括 2 步驟，說明如下：

<步驟 1>：找出系統可靠度最低點之時間點

根據粒子移動後所獲得預防維修模式解的系統可靠度曲線，找出系統可靠度最低的時間點，並計算出此時間點相對於各次系統之維修週期及該維修週期所實施的維修活動，經由逐步增加該維修活動編碼值，表示實施較高階的維修活動，以提升次系統之可靠度，若此維修活動為置換，即為編碼值 3，表示無法再實施較高階的維修活動，則縮小此次系統之維修週期，使該次系統於任務時間內之維修次數變多，以提升次系統可靠度，進而提升系統可靠度。

<步驟 2>：判定粒子是否移動至可行解區域

依據 <步驟 1> 所求得之新的粒子編碼值，判定經調整後之系統可靠度在任務時間內是否均大於最低容許可靠度值，若沒有，則重複上述 <步驟 1> 及 <步驟 2>，直到此粒子滿足限制條件，移至可行解區域為止。

步驟 4：決定區域最佳解及全域最佳解的粒子

本研究係以維修總成本最小化之粒子族群及系統平均可用度最大化之粒子族群，分別朝向各自最佳化目標進行 IPSO 演算法的搜尋機制，在求解維修總成本最小化之粒子族群中，取當代粒子中最小維修總成本的粒子，為此族群目前區域最佳解的粒子，取歷次迭代中，具最小維修總成本值的區域最佳解粒子，為此族群目前全域最佳解的粒子，另外，在求

解系統平均可用度最大化粒子族群中，取當代粒子中最大系統平均可用度的粒子，為此族群目前區域最佳解的粒子，取歷次迭代中，具最大系統平均可用度的區域最佳解粒子，為此族群目前全域最佳解的粒子。

步驟 5：執行進化機制，產生優良粒子群子代

由於二個粒子族群分別朝向維修總成本最小化與系統平均可用度最大化搜尋，可快速逼近個別目標最佳解，卻導致所獲得的柏拉圖解集合朝向兩極端目標值處分佈，而失去解的多樣性，故本研究所建構的 IPSO 演算法結合柏拉圖前緣之多目標非凌駕解的觀念，合併維修總成本與系統平均可用度二個初始粒子族群，導入基因演算法中，染色體演化之「適者生存，不適者淘汰」的「進化機制」，篩選出非凌駕解集合，以進行粒子的進化機制，使所獲得之多目標解能夠均勻地分佈在柏拉圖前緣上，呈現多樣化的可行方案，方法如下：

<步驟 1>：汰除不良粒子

針對維修總成本粒子族群，挑選出 P 個適應值(fitness value)排序較差的粒子及針對系統平均可靠度粒子族群亦挑選出 P 個適應值排序較差的粒子，二族群合計 $2 \times P$ 個粒子為淘汰粒子。

<步驟 2>：產生多樣化的優良粒子

以二個粒子族群所產生之非凌駕解集合為基礎，從中隨機選取優良粒子共計 $2 \times P$ 個粒子補足淘汰粒子個數，以維持原來二個粒子族群的粒子數，再代入演算法步驟 2-5，以進行後續迭代運算，求解多樣性的多目標解集合。

步驟 6：終止條件

本研究訂定演算法的終止條件為適應函數值在連續 N 代內無改善，即停止演算並輸出求解的多目標非凌駕解，包括串並聯系統在任務時間內各次系統的維修週期與維修活動，從而決定多個具多樣性的預防維修方案。

本研究利用 RSM[40]決定慣性權重上限值 ω_{\max} 、學習因子上限值 $c_{1\max}$ 與 $c_{2\max}$ 及汰除粒子個數 P 的實施步驟，說明如下：

<步驟 1>：規劃反應曲面實驗

以慣性權重上限值 ω_{\max} 、學習因子上限值 $c_{1\max}$ 、 $c_{2\max}$ 及汰除粒子個數 P 為四個實驗因子，反應變數為評量多目標解集合優劣的接近度、離散度及展開度等三個指標，利用面心立

方中心混成設計(FCCD, faced center cube central composite design)規劃反應曲面實驗，共產生 30 個實驗設計點，包括：8 個端點，16 個軸點以及 6 個中心點的設計。

<步驟 2>：執行實驗並蒐集實驗數據

根據<步驟 1>之實驗配置的設計點，在不同搜尋參數組合下，以 IPSO 最佳化所建構之預防維修模式，經由獲得的維修總成本與系統平均可靠度兩個解，計算接近度、離散度及展開度為實驗的反應變數。

<步驟 3>：建立反應曲面模式

本研究分別適配接近度、離散度及展開度與慣性權重上限值 ω_{\max} 、學習因子上限值 $c_{1\max}$ 與 $c_{2\max}$ 及汰除粒子個數 P 間的反應曲面模式，若二次反應曲面模式為適配，其數學式可表示如下：

$$\begin{aligned}
 y_i = & \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 \\
 & + \beta_{12} x_1 x_2 + \beta_{13} x_1 x_3 + \beta_{14} x_1 x_4 \\
 & + \beta_{23} x_2 x_3 + \beta_{24} x_2 x_4 + \beta_{34} x_3 x_4 \quad (22) \\
 & + \beta_{11} x_1^2 + \beta_{22} x_2^2 + \beta_{33} x_3^2 + \beta_{44} x_4^2 + \varepsilon \\
 & i = 1, 2, 3
 \end{aligned}$$

其中 y_1 為接近度； y_2 為離散度； y_3 為展開度； x_1 、 x_2 、 x_3 及 x_4 分別為慣性權重上限值 ω_{\max} 、學習因子上限值 $c_{1\max}$ 、 $c_{2\max}$ 及汰除粒子個數 P 對反應變數的線性效應； $x_1 x_2$ 、 $x_1 x_3$ 、 $x_1 x_4$ 、 $x_2 x_3$ 、 $x_2 x_4$ 、 $x_3 x_4$ 表示慣性權重上限值 ω_{\max} 、學習因子上限值 $c_{1\max}$ 、 $c_{2\max}$ 及汰除粒子個數 P 之間對反應變數的交互作用效應； x_1^2 、 x_2^2 、 x_3^2 與 x_4^2 分別為慣性權重上限值 ω_{\max} 、學習因子上限值 $c_{1\max}$ 、 $c_{2\max}$ 及汰除粒子個數 P 對於反應變數的二次項效應； β_0 、 β_i 、 β_{ij} 、 β_{ji} 為迴歸模式參數； ε 表示隨機的殘差項。當模式適缺度(lack of fit test)檢定下的 p 值(p-value)大於顯著水準 $\alpha = 0.05$ ，判定該模式適配，從而決定最佳的搜尋參數設定值。

<步驟 4>：決定最佳設定值

本研究引用望想函數(desirability function)[41]來評估多目標解集合中接近度、離散度及展開度三個指標的優劣，以決定搜尋參數的最佳設定值。望想函數是指品質特性之

反應值對於其目標值的渴望程度所建構之函數，望想值介於 0 與 1 之間，廣泛地應用於工業界處理多品質特性最佳化問題。

四、有效性驗證

Tsai 等學者[17]以 AGREE 方法[18]，經由參數 α_i 值，來評估次系統失效導致系統失效的機率，據此評估一個複雜系統的可靠度，進而建立一個系統預防維修模式， α_i 值介於 0 與 1 之間，當 $\alpha_i=1$ ，表示次系統間組合為一串聯系統，所建立之系統包含五個獨立之次系統，次系統一與次系統五的 α_i 參數值為 0.5，次系統二、次系統三與次系統四的 α_i 參數值為 0.6，另外以 Weibull 分配模擬五個次系統的失效機率模式，次系統之尺度參數 θ 、形狀參數 β 、改善因子等參數及其維修成本等參數值如表 1 所示，系統任務時間為 5000 小時，限制條件設定為系統可靠度於任務時間內必須高於最低容許可靠度值 0.6，所考量的預防維修活動，包括：不做預防維修動作、保養、維修及置換，其中利用改善因子法，建立非完美維修模式，另外當次系統失效時，則實施最小維修之矯正性維修策略，使次系統回復至失效前狀態。為簡化求解複雜度，Tsai 等學者[17]建構一個二階段的最佳化求解策略，以公式(1)評估系統可靠度，所獲得的系統平均可用度值為 0.76，預防性維修成本為 4846、矯正性維修成本為 1872，維修總成本合計為 6718。

表 1. 次系統參數表[17]

	次系統 1	次系統 2	次系統 3	次系統 4	次系統 5
尺度參數 θ (h)	1300	2400	2600	3800	2000
形狀參數 β	1.8	2.5	3.2	3.1	3.1
改善因子 s_1	0.8	0.8	0.9	0.8	0.8
改善因子 s_2	0.8	0.8	0.9	0.8	0.8
α_i 值	0.5	0.6	0.6	0.6	0.5
保養成本(\$)	54	72	120	96	78
維修成本(\$)	108	144	240	192	156
置換成本(\$)	180	240	400	320	260
矯正性維修成本(\$)	114	152	253.33	202.67	164.67

本研究根據 Tsai 等學者[17]所提之系統失

效模型的參數，建立一個包含五個次系統的複雜系統，進而建立一個複雜系統之多目標預防維修模式，再以所建構的 IPSO 演算法最佳化各次系統之維修週期及個別維修時間點的維修活動，其中適應函數值在迭代次數連續 50 代無變化，即停止 IPSO 運算，現以下面二階段來說明最佳化程序與結果。

階段一：進行粒子編碼

首先隨機產生五個次系統之維修週期，進而形成維修週期編碼，並經由計算任務時間 5000 小時與各次系統維修週期之比值，可求出各次系統在任務時間內實施預防維修活動的次數，進而以隨機方式產生個別次系統於維修時間點所實施的維修活動編碼，合併維修週期編碼與維修活動編碼，即完成求解此案例的一個混合型粒子編碼。

階段二：最佳化維修週期及預防維修活動

首先，根據 RSM 決定 IPSO 演算法中慣性權重上限值 $\omega_{\max}=0.4$ 、學習因子上限值 $c_{1\max}=1.83$ 及 $c_{2\max}=0.66$ 、汰除粒子個數 $P=15$ ，從而執行 IPSO 的演算機制，使有效地朝多目標最佳解的搜尋方向逼近，同時使系統總維修成本最小化及系統平均可用度最大化，共獲得包含 5 個非凌駕解的柏拉圖逼近解集合，如圖 1 所示，其接近度為 0.9613、離散度為 0.0364、展開度為 0.7165，表示非凌駕解彼此之間分布廣且均勻，本研究以此 5 個解，作為此案例之維修週期可行方案，提供決策者作參考，並與 Tsai 等學者[17]的求解結果相比較，彙整如表 2 所示。根據表 2 得知，本研究所獲得的非凌駕解之所有方案，其維修總成本及系統平均可用度，均優於 Tsai 等學者[17]的求解結果。若選擇第一方案，能以較低的維修總成本完成任務，但系統平均可用度亦相對低一些；若選擇第五方案，則會有較高之系統平均可用度，但卻會造成維修總成本大幅增加，故若選擇第三方案則可提供較為平衡的選擇，決策者可根據實際任務的需求與資源的限制性，從中選取最適的方案。由上述分析結果得知本研究所建構之 IPSO 演算法確可用於複雜系統預防維修模式中，同時有效地求解個別次系統維修週期與維修時間點上的維修活動。

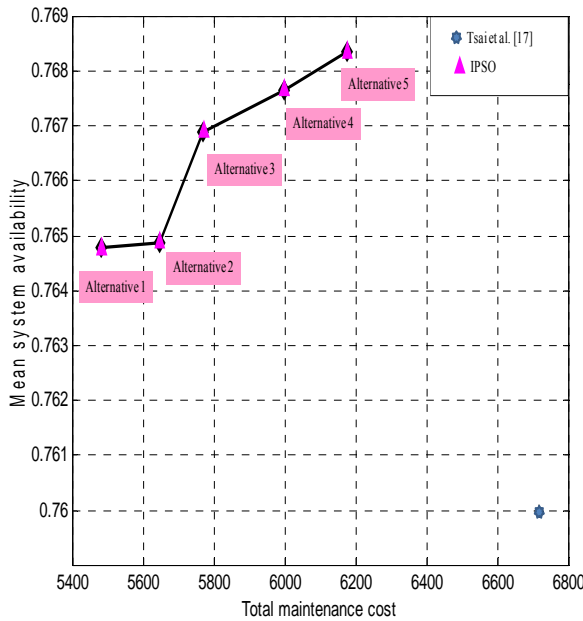


圖 1. 維修方案之多目標柏拉圖。

表 2. 最佳逼近解求解結果比較表

	次系統編號	維修週期 (h)	維修活動	維修總成本 (\$)	系統平均可用度	
Tsai 等人 [17]	1	761	3,3,3,3,3	6718	0.76	
	2	761	1,2,3,1,2,3			
	3	761	0,3,0,3,0,3			
	4	761	0,0,3,0,0,3			
	5	761	1,3,1,3,1,3			
本研究	方案一	1	728	3,2,3,2,3,3	5483	0.7648
		2	728	1,3,0,3,0,3		
		3	728	0,2,0,2,2,0		
		4	728	0,3,0,2,0,1		
		5	728	1,2,3,1,3,1		
	方案二	1	874	3,2,3,3,2	5645	0.7649
		2	874	2,3,2,2,2		
		3	874	1,3,1,1,2		
		4	874	0,3,0,2,1		
		5	874	2,3,2,2,1		
	方案三	1	887	3,2,3,3,2	5769	0.7669
		2	887	2,3,3,2,1		
		3	887	2,3,1,2,1		
		4	887	1,3,0,2,1		
		5	887	2,3,2,2,1		
	方案四	1	686	3,2,3,2,3,3,2	5997	0.7676
		2	686	1,3,0,3,0,3,2		
		3	686	0,3,0,3,0,0,1		
		4	686	0,3,0,3,0,2,0		
		5	686	0,2,3,0,3,1,1		
方案五	1	694	3,2,3,3,3,3,2	6176	0.7684	
	2	694	1,3,0,3,0,3,2			
	3	694	0,3,0,3,2,0,1			
	4	694	0,3,0,3,0,2,0			
	5	694	0,2,3,1,3,1,1			

本案例以反應曲面法決定搜尋參數值的過程，說明如下：

步驟 1：規劃反應曲面實驗

實驗因子水準配置如表 3 所示。

表 3. 實驗因子水準配置表

實驗因子	低水準	高水準
慣性權重上限值 ω_{\max}	0.4	0.8
學習因子上限值 $c_{1\max}$	0.4	2
學習因子上限值 $c_{2\max}$	0.4	2
汰除粒子個數 P	5	15

步驟 2：執行實驗並蒐集實驗數據

在不同搜尋參數值組合下，以 IPSO 求解所建構之複雜系統非完美週期預防維修模式，得到 30 個系統平均可靠度與維修總成本二個目標的柏拉圖前緣解，再分別計算多目標解集合接近度、離散度與展開度，歸納如表 4。

表 4. 實驗規劃及反應變數值

實驗編號	慣性權重上限值 ω_{\max}	學習因子上限值 $c_{1\max}$	學習因子上限值 $c_{2\max}$	汰除粒子個數 P	接近度	離散度	展開度
1	0.60	1.20	0.40	10.00	0.6243	0.1083	0.8677
2	0.40	0.40	2.00	5.00	0.6198	0.1195	0.8930
3	0.80	1.20	1.20	10.00	0.5923	0.1221	0.9028
	⋮						
28	0.80	0.40	2.00	15.00	0.5727	0.1380	0.8868
29	0.40	2.00	0.40	5.00	0.6487	0.1580	0.9199
30	0.80	0.40	0.40	15.00	0.6905	0.0891	0.8252

步驟 3：建立反應曲面模式

經由適缺度檢定分別建立接近度、離散度、展開度與慣性權重上限值 ω_{\max} 、學習因子上限值 $c_{1\max}$ 與 $c_{2\max}$ 及汰除粒子個數 P 間之反應曲面模式，結果如下：

$$\hat{y}_1 = 0.58$$

$$\begin{aligned} & -0.018 \times \text{慣性權重上限值 } \omega_{\max} \\ & -0.003594 \times \text{學習因子上限值 } c_{1\max} \\ & -0.017 \times \text{學習因子上限值 } c_{2\max} \\ & -0.001333 \times \text{汰除粒子個數 } P \\ & -0.016 \times \text{慣性權重上限值 } \omega_{\max} \times \text{學習因子上限值 } c_{1\max} \\ & +0.0093 \times \text{慣性權重上限值 } \omega_{\max} \times \text{學習因子上限值 } c_{2\max} \\ & -0.003112 \times \text{慣性權重上限值 } \omega_{\max} \times \text{汰除粒子個數 } P \\ & +0.005075 \times \text{學習因子上限值 } c_{1\max} \times \text{學習因子上限值 } c_{2\max} \\ & -0.003562 \times \text{學習因子上限值 } c_{1\max} \times \text{汰除粒子個數 } P \\ & -0.027 \times \text{學習因子上限值 } c_{2\max} \times \text{汰除粒子個數 } P \\ & +0.021 \times \text{慣性權重上限值 } \omega_{\max}^2 \\ & -0.022 \times \text{學習因子上限值 } c_{1\max}^2 \\ & +0.015 \times \text{學習因子上限值 } c_{2\max}^2 \\ & +0.034 \times \text{汰除粒子個數 } P^2 \end{aligned}$$

$$\hat{y}_2 = 0.11$$

$$\begin{aligned} & +0.0008389 \times \text{慣性權重上限值 } \omega_{\max} \\ & +0.004872 \times \text{學習因子上限值 } c_{1\max} \\ & +0.003728 \times \text{學習因子上限值 } c_{2\max} \\ & -0.001017 \times \text{汰除粒子個數 } P \\ & +0.012 \times \text{慣性權重上限值 } \omega_{\max} \times \text{學習因子上限值 } c_{1\max} \\ & +0.017 \times \text{慣性權重上限值 } \omega_{\max} \times \text{學習因子上限值 } c_{2\max} \\ & +0.006094 \times \text{慣性權重上限值 } \omega_{\max} \times \text{汰除粒子個數 } P \\ & +0.006694 \times \text{學習因子上限值 } c_{1\max} \times \text{學習因子上限值 } c_{2\max} \\ & +0.002169 \times \text{學習因子上限值 } c_{1\max} \times \text{汰除粒子個數 } P \\ & +0.018 \times \text{學習因子上限值 } c_{2\max} \times \text{汰除粒子個數 } P \\ & +0.013 \times \text{慣性權重上限值 } \omega_{\max}^2 \\ & -0.027 \times \text{學習因子上限值 } c_{1\max}^2 \\ & -0.004005 \times \text{學習因子上限值 } c_{2\max}^2 \\ & +0.035 \times \text{汰除粒子個數 } P^2 \end{aligned}$$

$$\hat{y}_3 = 0.90$$

$$\begin{aligned} & -0.001528 \times \text{慣性權重上限值 } \omega_{\max} \\ & +0.009361 \times \text{學習因子上限值 } c_{1\max} \\ & +0.005133 \times \text{學習因子上限值 } c_{2\max} \\ & -0.005172 \times \text{汰除粒子個數 } P \\ & +0.015 \times \text{慣性權重上限值 } \omega_{\max} \times \text{學習因子上限值 } c_{1\max} \\ & +0.004094 \times \text{慣性權重上限值 } \omega_{\max} \times \text{學習因子上限值 } c_{2\max} \\ & -0.004656 \times \text{慣性權重上限值 } \omega_{\max} \times \text{汰除粒子個數 } P \\ & -0.002456 \times \text{學習因子上限值 } c_{1\max} \times \text{學習因子上限值 } c_{2\max} \\ & +0.002994 \times \text{學習因子上限值 } c_{1\max} \times \text{汰除粒子個數 } P \\ & +0.019 \times \text{學習因子上限值 } c_{2\max} \times \text{汰除粒子個數 } P \\ & +0.003854 \times \text{慣性權重上限值 } \omega_{\max}^2 \\ & -0.003546 \times \text{學習因子上限值 } c_{1\max}^2 \\ & -0.023 \times \text{學習因子上限值 } c_{2\max}^2 \\ & +0.015 \times \text{汰除粒子個數 } P^2 \end{aligned}$$

其中 \hat{y}_1 、 \hat{y}_2 及 \hat{y}_3 分別表示接近度、離散度與展開度之預測值。

步驟 4：決定最佳搜尋參數值

經由最大化望想函數值得到最佳實驗因子參數值為慣性權重上限值 $\omega_{\max} = 0.4$ 、學習因子上限值 $c_{1\max} = 1.83$ 及 $c_{2\max} = 0.66$ 、汰除粒子個數 $P = 15$ ，其望想值為 0.709。

五、結論

本研究針對可維修之複雜系統，建構一個「複雜系統之非完美週期預防維修模式」，以系統維修總成本最小化及平均可用度最大化為最佳化目標，此外，亦建立一個 IPSO 演算法，最佳化系統中個別次系統之維修週期及維修時間點的維修活動，從研究結果可得到以下幾點結論：

- 一、本研究建構的 IPSO 演算法，同時求解複雜系統非完美預防維修模式之維修週期與維修活動，求解過程中考量了維修週期與維修活動間交互效應對維修總成本與系統平均可用度的影響，在可行解的全域空間內，利用粒子具方向性之特性，有效逼近全域最佳解，獲得較低的系統維修總成本及較高的系統平均可用度。
- 二、本研究發展一個混合型粒子編碼，使典型的 PSO 演算法適合於求解最佳化模型中，同時包含連續型變數與離散型變數最佳化問題，拓展了 PSO 演算法的實務應用性。
- 三、本研究針對所建構之複雜系統預防維修模式的限制條件，發展一個不可行解調整機制，使每個粒子皆可移動至可行解區域，以利搜尋並逼近全域最佳解，可提升所建構 IPSO 演算法的求解成效。
- 四、導入實驗設計之反應曲面方法，有系統地分析與決定 IPSO 演算法中的最佳搜尋參數值，可活化粒子的搜尋機制，以利搜尋機制中有效逼近多目標之柏拉圖最佳解。

參考文獻

- [1] Budai, G., Huisman, D., and Dekker, R., "Scheduling preventive railway maintenance activities," Journal of the Operational

- Research Society, Vol. 57 (9), pp.1035-1044, 2006.
- [2] Zequeira, R. I. and Bérenguer, C., "Periodic imperfect preventive maintenance with two categories of competing failure modes," *Reliability Engineering and System Safety*, Vol. 91, pp.460-468, 2006.
- [3] Tsai, Y. T., Wang, K. S., and Teng, H. Y., "Optimizing preventive maintenance for mechanical components using genetic algorithms," *Reliability Engineering & System Safety*, Vol. 74, pp. 89-97, 2001.
- [4] Marseguerra, M. and Zio, E., "Optimizing maintenance and repair policies via a combination of genetic algorithms and Monte Carlo simulation," *Reliability Engineering & System Safety*, Vol. 68(1), pp.69-83, 2000.
- [5] Leou, R. C., "A new method for unit maintenance scheduling considering reliability and operation expense," *Electrical Power & Energy Systems*, Vol. 28, pp.471-481, 2006.
- [6] Tavakkoli-Moghaddam, R., Safari, J., and Sassani, F., "Reliability optimization of series-parallel systems with a choice of redundancy strategies using a genetic algorithm," *Reliability Engineering and System Safety*, Vol. 93, pp.550-556, 2008.
- [7] Bris, R., Châtelet, E., and Yalaoui, F., "New method to minimize the preventive maintenance cost of series-parallel systems," *Reliability Engineering and System Safety*, Vol. 82, pp.247-255, 2003.
- [8] El-Gallad A. I., El-Hawary M. E., and Sallam A. A. "Swarming of intelligent particles for solving the nonlinear constrained optimization problem," *Engineering Intelligent Systems for Electrical Engineering and Communications*, Vol. 9(3), pp.155-163, 2001.
- [9] Hu, X. and Eberhart, R. "Solving constrained nonlinear optimization problems with particle swarm optimization," *Proceedings of the Sixth World Multiconference on Systemics, Cybernetics and Informatics*, pp.203-206, 2002.
- [10] Parsopoulos, K. E. and Vrahatis, M. N. "Particle swarm optimization method for constrained optimization problems," *Proceedings of the 2nd Euro-International Symposium on Computational Intelligence*, pp.214-220, 2002.
- [11] Kennedy, J. and Eberhart, R., "Particle Swarm Optimization," *Proceedings of the IEEE International Conference on Neural Networks*, Vol. 4, pp.1942-1948, 27 Nov.-1 Dec.,1995.
- [12] Pham, H. and Wang, H. Z., "Imperfect Maintenance," *European Journal of Operational Research*, Vol. 94, pp. 425-438, 1996.
- [13] Pham, H. and Wang, H. Z., "Optimal imperfect maintenance models," In: H. Pham, Editor, *Handbook of reliability engineering*, London: Springer, pp. 397-414, 2003.
- [14] Castro, I. T., "A model of imperfect preventive maintenance with dependent failure modes," *European Journal of Operational Research*, Vol. 196, pp. 217-224, 2009.
- [15] Nakagawa, T. and Mizutani, S. "A summary of maintenance policies for a finite interval," *Reliability Engineering and System Safety*, Vol. 94, pp.89-96, 2009.
- [16] Liao, W., Pan, E., and Xi, L., "Preventive maintenance scheduling for repairable system with deterioration," *Journal of Intelligent Manufacturing*, Vol. 21(6), pp. 875-884, 2010.
- [17] Tsai, Y. T., Wang, K. S., and Tsai, L. C., "A study of availability-centered preventive maintenance for multi-component systems," *Reliability Engineering & System Safety*, Vol. 84, pp.261-270, 2004.
- [18] Rao, S. S., *Reliability-base design*. McGraw-Hill, New York, 1993.
- [19] Pahng, F., Senin, N., and Wallace, D., "Distribution Modeling and Evaluation of Product Design Problems," *Computer Aided Design*, Vol. 30(6), pp. 411-424, 1998.
- [20] Busacca, P., Marseguerra, M., and Zio, E., "Multi-objective optimization by genetic algorithms: application to safety systems," *Reliability Engineering & System Safety*, Vol. 72, pp.59-74, 2001.
- [21] Nosoohi, I. and Hejazi, S. R., "A multi-objective approach to simultaneous determination of spare part numbers and

- preventive replacement times,” *Applied Mathematical Modelling*, Vol. 35, pp. 1157-1166, 2011.
- [22] Tian, Z., Lin, D., and Wu, B., “Condition based maintenance optimization considering multiple objectives,” *Journal of Intelligent Manufacturing*, Vol. 23(2), pp. 333-340, 2012.
- [23] Ray, T. and Liew, K., “A Swarm Metaphor for Multiobjective Design Optimization,” *Engineering Optimization*, Vol. 34(2), pp. 141-153, 2002.
- [24] Pulido, G. and Coello, C., “Using Clustering Techniques to Improve the Performance of a Multi-objective Particle Swarm Optimizer,” *Lecture Notes in Computer Science*, pp. 225-237, 2004.
- [25] Deb, K., *Multi-objective Optimization Using Evolutionary Algorithms*. MA: Wiley, pp. 324-337, 2001.
- [26] Wang, C. H., Lu, J. Z., and Wu, C. J., “Optimization of a Multi-Objective Transportation Model during War for Military,” *The Journal of Chung Cheng Institute of Technology*, Vol. 37(2), pp. 10-29, 2009.
- [27] Zitzler, E., Deb, K., and Thiele, L. “Comparison of multiobjective evolutionary algorithms: Empirical results,” *Evolutionary computation*, Vol. 8(2), pp. 173-195, 2000.
- [28] Chen, J., Chen, G., and Guo, W., “A Discrete PSO for Multi-objective Optimization in VLSI Floor planning,” *Advances in Computation and Intelligence*, Vol. 5821, pp. 400-410, 2009.
- [29] Gao, F., Cui, G., Zhao, Q., and Liu, H., “Application of Improved Discrete Particle Swarm Algorithm in Partner Selection of Virtual Enterprise,” *International Journal of Computer Science and Network Security*, Vol. 6(3), pp. 208-212, 2006.
- [30] Yare, Y., Venayagamoorthy, G. K., and Aliyu, U. O., “Optimal generator maintenance scheduling using a modified discrete PSO,” *IET Generation, Transmission & Distribution*, Vol. 2(6), pp. 834 -846, 2008.
- [31] Yare, Y. and Venayagamoorthy, G. K., “Optimal maintenance scheduling of generators using multiple swarms-MDPSO framework,” *Engineering Applications of Artificial Intelligence*, Vol. 23(6), pp. 895-910, 2010.
- [32] Shi, Y., and Eberhart, R., “Empirical Study of Particle Swarm Optimization,” in *Proceedings of the IEEE Int. Congress Evolutionary Computation*, Vol. 3, pp. 1958-1962, 1999.
- [33] Suganthan, P. N., “Particle Swarm Optimization with Neighborhood Operator,” in *Proceedings of the IEEE Int. Congress Evolutionary Computation*, pp. 101-106, 1999.
- [34] Clerc, M., “The Swarm and the Queen: Towards a Deterministic and Adaptive Particle Swarm Optimization,” in *Proceedings of the IEEE Int. Congress Evolutionary Computation*, pp. 1951-1957, 1999.
- [35] Hajinejad, D., Salmasi, N., and Mokhtari, R., “A fast hybrid particle swarm optimization algorithm for flow shop sequence dependent group scheduling problem,” *Scientia Iranica*, Vol. 18(3), pp. 759-764, 2011.
- [36] Kuo, I. H., Horng, S. J., Kao, T. W., Lin, T. L., Lee, C. L., Terano, T., and Pan, Y., “An efficient flow-shop scheduling algorithm based on a hybrid particle swarm optimization model,” *Expert Systems with Applications*, Vol. 36(3), pp. 7027-7032, 2009.
- [37] Chaturvedi, K, T., Pandit, M., and Srivastava, L., “Particle Swarm Optimization with Time Varying Acceleration Coefficients for Non-convex Economic Power Dispatch,” *International Journal of Electrical Power & Energy Systems*, Vol. 31(6), pp. 249-257, 2009.
- [38] Myers, R. and Carter Jr, W., “Response Surface Techniques for Dual Response Systems,” *Technometrics*, Vol. 15(2), pp. 301-317, 1973.
- [39] Ratnaweera, A., Halgamuge, S. K., and Watson, H. C., “Self-organizing hierarchical particle swarm optimizer with time-varying axxeleration coefficients,” *IEEE Transactions On Evolutionary Computation*, Vol. 8(3), pp. 240-255, 2004.
- [40] Montgomery, D. C., *Design and Analysis of Experiments 6th Edition*, Wiley, Danvers,

- MA, U.S.A., 2005.
- [41] Harrington, E., "The Desirability Function,"
Industrial Quality Control, Vol. 21(10), pp.
494-498, 1965.

