



國立臺灣大學工學院工業工程學研究所

碩士論文

Graduate Institute of Industrial Engineering

College of Engineering

National Taiwan University

Master Thesis

考慮使用者移動行為之無線網路需求規劃及資源分配：

以 RNC 配置為例

Demand Planning Based on User Mobility Behavior for Wireless  
Network Capacity Allocation

呂栢頤

Po-Yi Lu

指導教授：陳正剛博士

Advisor: Argon Chen, Ph.D.

中華民國 104 年 7 月

July, 2015

## 誌謝



能完成這篇論文，首先要感謝指導教授陳正剛老師，兩年來您的諄諄教誨讓我了解自己在學術、工作上的不足，處理事情的步驟與負責的態度，雖然幾度想逃避、放棄，我很慶幸最後仍是 Argon group 的一份子。也感謝張時中老師、藍俊宏老師與洪一薰老師，百忙之餘閱讀我的拙作，並給予口試與指導及諸多的鼓勵。以及所上的老師們與助理們，謝謝你們各式的幫助及聊天，讓我釋放不少撰寫論文時的壓力。

也感謝兩年來同為 Argon group 的上峰與煥澤，還有碩一的三位學妹們，能夠一起歡笑一起在這個實驗室打拼，真的非常的快樂。還有所上的同學們：承翰、源懋、博瀚、小歐、怡州、捷哥、魏綱與大瑋，兩年來的時光我們參與很多活動，也一起唸書、分享知識，感謝大家讓我有這麼充實的碩士生活，也希望之後在工作時，有時間可以常聚聚。

以及要感謝一直持續照顧、關懷我的家人，不但幫我修稿、處理許多學術相關的文件，並不斷鼓勵、忍受我的任性、無助，適時的給我鼓勵與安慰，使得我可以在每一次的崩潰後，重拾站起來的力量，非常的謝謝你們。

另外是仲瑋，妳的意見與體貼，在我這麼忙碌時，不時的為我打氣，給我許多精闢的建議，也撥出時間陪伴我，帶給我無數的歡笑。希望妳明年也加油，這次就換我陪妳啦。

最後的致謝是寫給我的摯友 Will，從大二到現在，幾乎每次的報告、程式與唸書，都仰賴你的幫忙，我能夠完成這份論文的架構與研究，是因為背後有你的協助，謝謝你！希望你在 C.J group 下可以札實的度過碩士生活，未來找到好的工作。

要感謝的人不勝枚舉，所以謝謝曾幫助我的每一個人，希望在不遠的未來，我們會再次相見。



## 中文摘要

隨著智慧型手機與穿戴式電子產品裝置的發展日新月異，行動通訊服務產業也跟著興起，使用者對無線網路的需求因而與日俱增，如何滿足使用者網路及服務產業的發展需求，同時可以使網路環境的控管更有效率是本研究的主軸。

無線網路需求量的不確定性除了來自時間與地區性的差異，也受到使用者移動性的影響，因此難以做出準確預測，這也是進行網路資源規劃策略上的難題；但有近期文獻指出使用者的移動性在一定的範圍下是可以被預測的，基此，本研究利用使用者的移動行為建立需求模式，並依所建立之需求模式進行無線網路資源規劃策略。

本研究利用統計探勘技巧，從資料中建立模式描述用戶移動性，我們以 1 小時為單位為例描述所有使用者一天中的網路需求，並利用跨越不同時段的使用者以建立轉移矩陣模型描述用戶的移動模式。再依據不同的指標與相關變數等性質及貪婪式、階層式、啟發式與基因演算法等的最佳化方法，發展多個分群與優化演算法，以進行需求規劃策略達到無線網路資源的優化。

研究最後以改善無線網路控制中心(RNC)管理基地台模式為例，希望達到提升不同管理中心的網路服務率與降低無線網路控制中心間的轉移率，該方法亦可應用於未來基地台的配置；本研究亦評估各個演算法之規劃品質及其計算效率，並比較現有的管理方式，以驗證了所提出方法的效率。

**關鍵字：**使用者移動行為、無線網路需求規劃、分群演算法、啟發式演算法

# ABSTRACT



With the booming use of smart phones and wearables, the mobile service industry is also in a thriving development pace. It also causes mobile users' increasing network demand. Our question is how to satisfy their network demand, and improve the network control and planning efficiency at the same time.

The uncertainty of wireless network demand is not only from the spatial and temporal variations, but also effected by user mobility behavior. The problem is how to manage and plan the network capacity to satisfy the highly volatile demand. Recent research has shown that the user mobility can be predicted to a certain degree of accuracy. For this reason, we propose to build a model of user transition pattern to describe the user spatial and temporal mobility behavior. With the model built, the network capacity planning is optimized accordingly.

This research uses statistical data mining techniques to construct the transition matrix to describe the users' aggregated mobility behavior. The wireless network demand series is collected from all users' daily network activity in hourly basis. The transition count between each region is also collected by selecting the user activities observed across two consecutive time intervals, based on which the transition matrix is estimated. We then develop heuristic aggregation strategies based on clustering algorithm and optimization techniques, such as hierarchical clustering, k-means, greedy and genetic algorithms according to performance surrogates and objective functions. These strategies are then used to improve the efficiency of wireless network resource planning.

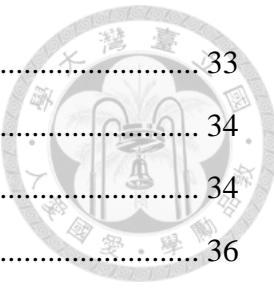
Last, we use the example of base station (BS) control by the radio network control (RNC) to demonstrate the planning methods proposed by this research though the proposed method can be also applied in small cells allocation or fog computing resource allocation problems. The planning quality and the computing efficiency of the algorithms are also evaluated by comparing the performance among the RNC allocations planned by the proposed methods and the current allocation plan.

**Key word:** user mobility behavior, wireless network capacity planning, clustering algorithm, heuristic algorithm

# CONTENTS



誌謝 .....	1
中文摘要 .....	2
ABSTRACT .....	3
CONTENTS .....	4
LIST OF FIGURES .....	6
LIST OF TABLES .....	9
Chapter 1 緒論 .....	1
1.1 研究背景與動機 .....	1
1.2 問題描述與研究目標 .....	2
1.3 論文架構 .....	4
Chapter 2 文獻回顧 .....	6
2.1 手機使用者移動行為與網路規劃 .....	6
2.2 轉移矩陣模型的估計 .....	7
2.3 組合最佳化與分群方法 .....	8
Chapter 3 資料前處理與建模 .....	11
3.1 資料處理 .....	11
3.2 轉移矩陣之估計 .....	17
3.3 使用 Micro data 重新估計 Macro data .....	18
Chapter 4 無線網路資源分配之需求規劃方法 .....	20
4.1 聚合指標 .....	22
4.1.1 需求變異相關指標 .....	22
4.1.2 使用者移動相關指標 .....	24
4.2 問題建模 .....	24
4.3 性質探討：surrogate approach .....	25
4.4 資源分配策略規劃方法 .....	29
4.4.1 貪婪式規劃方法 .....	30
4.4.2 階層式規劃方法 .....	31
4.4.3 K 區域規劃方法 .....	32



4.4.4 基因演算法規劃方法 .....	33
Chapter 5 實際資料分析 .....	34
5.1 資料分析與轉移矩陣模型 .....	34
5.2 RNC 之需求規劃分析 .....	36
5.3 規劃策略結果比較 .....	40
5.4 無線網路資源分配結果 .....	50
Chapter 6 結果討論 .....	51
6.1 結果分析與建議 .....	51
6.2 未來研究方向 .....	51
REFERENCE .....	52
APPENDIX .....	53
Appendix 1. 轉移次數聚合方法 .....	53
Appendix 2. 不同時段下的網路需求分布 .....	54
Appendix 3. Macro data and micro data 之規劃策略結果 .....	56
Appendix 4. Micro data 估計之 macro data and micro data 之規劃策略結果 .....	70

## LIST OF FIGURES

Fig.1-1 : UTRAN 架構 .....	2
Fig.1-2 : 網路環境架構 .....	3
Fig.1-3 : 研究目標示意圖 .....	4
Fig.1-4 : 研究架構 .....	5
Fig.1-5 : 需求規劃策略及資源分配流程圖 .....	5
Fig.3-1 : 無線網路需求資料立方體 .....	12
Fig.3-2 : 當地行政區 .....	13
Fig.3-3 : 使用者在不同時段的移動情形之萃取方式 .....	14
Fig.3-4 : 時間觀點之層級關係 .....	14
Fig.3-5 : 不同類型之屬性關係 .....	15
Fig.3-6 : 根據時間解析與根據 RNC 解析之資料 .....	16
Fig.3-7 : $\text{Time}_{\text{week}\cdot\text{day}\cdot\text{hour}} \times \text{Region}_{\text{administrative region}} \times \text{Type}_{\text{All}}$ (Macro data) 資料萃取方法 .....	16
Fig.3-8 : Micro data 之抽樣方法 .....	17
Fig.4-1 : 49 個區域分派給 K 群 .....	20
Fig.4-2 : 需求增加造成變異數增大 .....	22
Fig.4-3 : 2 完全負相關需求數列與其聚合後之結果 .....	26
Fig.4-4 : 兩種區域可能的聚合結果 .....	27
Fig.4-5 : 三種區域可能的聚合結果 .....	28
Fig.4-6 : 規劃方法 .....	30
Fig.4-7 : 規劃方法流程圖 .....	30
Fig.5-1 : Macro data 之需求數列 .....	34
Fig.5-2 : 使用者移動情形(a)使用者停留的地點數 (b)使用者轉移的點數 .....	35
Fig.5-3 : 人口分布圖與轉移矩陣熱圖 .....	35
Fig.5-4 : RNC 分布情形 .....	37
Fig.5-5 : 7 個 RNC 之需求數列 .....	37
Fig.5-6 : 7 個 RNC 之轉移矩陣 .....	38
Fig.5-7 : 三種 linkage 的結果比較 .....	39
Fig.6-1 : 網路需求分布 .....	55



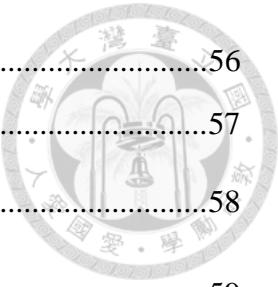


Fig.6-2 : 貪婪式規劃法 : WCV .....	56
Fig.6-3 : 貪婪式規劃法 : SCV .....	57
Fig.6-4 : 貪婪式規劃法 : $\ \check{\mathbf{Q}}\ _F$ .....	58
Fig.6-5 : 貪婪式規劃法 : $\ \check{\mathbf{M}}\ _F$ .....	59
Fig.6-6 : 階層式規劃法 : correlation matrix .....	60
Fig.6-7 : 階層式規劃法 : transition matrix .....	61
Fig.6-8 : 階層式規劃法 : transition count .....	62
Fig.6-9 : K 區域規劃法 : correlation matrix .....	63
Fig.6-10 : K 區域規劃法 : transition matrix .....	64
Fig.6-11 : K 區域規劃法 : transition count .....	65
Fig.6-12 : 基因演算規劃法 : WCV .....	66
Fig.6-13 : 基因演算規劃法 : SCV .....	67
Fig.6-14 : 基因演算規劃法 : $\ \check{\mathbf{Q}}\ _F$ .....	68
Fig.6-15 : 基因演算規劃法 : $\ \check{\mathbf{M}}\ _F$ .....	69
Fig.6-16 : Micro data 下 貪婪式規劃方法 : WCV .....	70
Fig.6-17 : Micro data 下 貪婪式規劃方法 : SCV .....	71
Fig.6-18 : Micro data 下 貪婪式規劃方法 : $\ \check{\mathbf{Q}}\ _F$ .....	72
Fig.6-19 : Micro data 下 貪婪式規劃方法 : $\ \check{\mathbf{M}}\ _F$ .....	73
Fig.6-20 : Micro data 下 階層式規劃方法 : correlation matrix .....	74
Fig.6-21 : Micro data 下 階層式規劃方法 : transition matrix .....	75
Fig.6-22 : Micro data 下 階層式規劃方法 : transition count .....	76
Fig.6-23 : Micro data 下 K 區域規劃方法 : correlation matrix .....	77
Fig.6-24 : Micro data 下 K 區域規劃方法 : transition matrix .....	78
Fig.6-25 : Micro data 下 K 區域規劃方法 : transition count .....	79
Fig.6-26 : Micro data 下 基因演算規劃方法 : WCV .....	80
Fig.6-27 : Micro data 下 基因演算規劃方法 : SCV .....	81

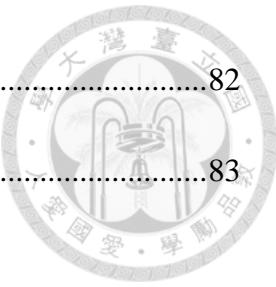


Fig.6-28 : Micro data 下基因演算規劃方法 :  $\|\check{\mathbf{Q}}\|_F$  ..... 82

Fig.6-29 : Micro data 下基因演算規劃方法 :  $\|\check{\mathbf{M}}\|_F$  ..... 83



## LIST OF TABLES

Table 1 : 資料欄位與範例 .....	11
Table 2 : 不合理的事件記錄資訊 .....	12
Table 3 : 使用者在不同時段的移動情形 .....	13
Table 4 : Time <sub>week•day•hour</sub> × Region <sub>administrative region</sub> × Type <sub>All</sub> (Macro data)之結果 .....	17
Table 5 : 符號定義 .....	21
Table 6 : 不同規劃策略在 macro data 與 micro data 之結果比較.....	43
Table 7 : 不同規劃策略在 micro data 估計之 macro data 與 micro data 之結果比較	44
Table 8 : 不同規劃策略之程式運行速度 .....	45
Table 9 : Day 4 , macro data 與 micro data 之結果比較 .....	46
Table 10 : K 區域規劃方法 : transition matrix 之無線網路資源分配 .....	50



# Chapter 1 緒論

## 1.1 研究背景與動機

手機使用者的移動行為在過去是較少人去研究探討的，但由於近年來行動通訊服務的普及，使用者的連線資訊可透過 3G 或 4G 基地台(Base Station, BS)的連線記錄而得知，使用者移動行為甚至可以從前述資訊進一步被預測。使用者的移動影響整個城市運作，建設一個現代化城市，使其生活機能符合居住者的要求，資訊化的環境建設是有其必要的。從日常的活動，例如通勤、逛街購物、景點觀光等這些人們移動的腳步，也隱含著人潮的流向，這樣的資訊化生活可以為整個城市帶來創新的商業價值如適地性技術服務(Location-Based Service)就是配合著穿戴式裝置而崛起的新興網路服務，這讓行動使用者在不同的環境與條件下，可以規劃自己所需的食、衣、住、行、育、樂等。因此，移動行為逐漸變成一個研究的主流，從探討使用者移動的可預測性，使用者移動軌跡的探勘到建立使用者一天下來的移動模式，使用者的移動行為除了可以有效的被預測及歸類外，綜合城市中所有使用者的移動模式也可提供決策者做更好的控管及規劃，諸如交通流量控制、醫療衛生管理、緊急災害處理及都市建設規劃等。

網路資源是在某個時段中可提供網路服務的容量上限，因為穿戴式裝置與行動應用軟體與日俱增，使用者隨時隨地都有上網的需求。所有的資訊都是由通訊環境中的伺服器所提供，使用者不管其背後的連線通訊機制，只在乎快速的收到大量的資訊。因此，電信營運商須對網路資源的配置妥善管理以便滿足所有使用者的網路需求。由於網路需求來自行動使用者，其移動的行為模式將會影響不同地區基地台的網路服務，從整體使用者的行動裝置與基地台的連線可以得知不同時段下的網路需求量，其量通常隨著不同時間、地區而有不同，在如此不穩定又複雜的狀態下，無線網路資源如何獲得妥善分配是本研究的動機。

綜上所述，本研究係考慮使用者的移動性對網路需求的影響，進而發展系統性無線網路需求規劃方法。決策者可從使用者移動瞭解不同地區的需求趨勢與變化，決定未來如何佈建基地台或是網路運算中心以達到最佳的無線網路資源分配。

本研究以無線網路控制中心(Radio Network Controller, RNC)為例，決定哪些

RNC 應該要控制哪些基地台(Base Station, BS)，這個方法未來可以應用於小型基地台的網路資源配置；抑或是 Google 提出的 loon project 中，藉由氣球型基地台的概念，隨著氣流變化移動至所需的地點提供網路傳輸的連接服務；以及 fog computing 的佈署，fog computing 相比於 clouding computing (雲計算)更強調於快速的在地處理使用者的網路需求，減少傳回資料中心(Data center)或是核心網路的傳輸成本，提高更快速、高品質的傳輸服務。上述例子皆需要了解使用者網路需求量隨著時間與空間的變化，進而得到妥善的網路資源配置問題。

## 1.2 問題描述與研究目標

本研究參考的網路架構為 UMTS Terrestrial Radio Access Network, UTRAN，其介紹如下：不同的基地台服務需要網路連線的區域，當使用者一進入基地台的覆蓋範圍，其通訊裝置同時也會和基地台相連，當使用者移動至其他基地台時，基地台之間就會有換手(handover)的動作，使用者可以在不斷線的狀態下，保持其網路連線的品質。數個基地台又由 1 個無線網路控制中心(RNC)控管，RNC 有 3 個功能(function)：Radio Resource Management(RRM)、Mobility management 與加密(encryption)，RRM 的目的是可以有效的規劃移動通訊系統的無線網路基礎設施，實現最佳的資源利用率，Mobility management 是追蹤使用者設備的位置，以便於通知使用者來電。在通話建立之後，負責維持使用者通話過程中移動的網路穩定性，避免通話在使用者移動過程中無故斷線。在使用者發出網路需求後會在 RNC 處理的過程中進行加密。本研究的主軸在 RRM，也就是根據使用者的移動與網路行為如何有效的規劃移動通訊設備，並分派適當的資源以提供該地區的網路服務。

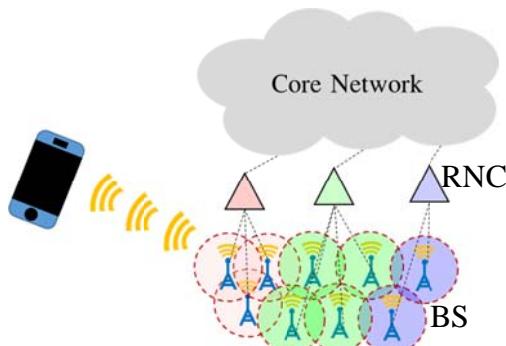


Fig.1-1 : UTRAN 架構

如果在一個時段下需求變化劇烈的話，RNC 會不易控管這些基地台的網路服務資源；另外如果多數使用者在不同 RNC 下有大量的流動現象的話，會造成不同 RNC 之間的基地台發生的換手現象增加，這也會使 RNC 產生傳輸上的負荷增加，如下圖 Fig.1-2，RNC 之間的換手需要將資料傳輸至有線核心網路(core network)，這樣連線延遲的情況就可能發生。

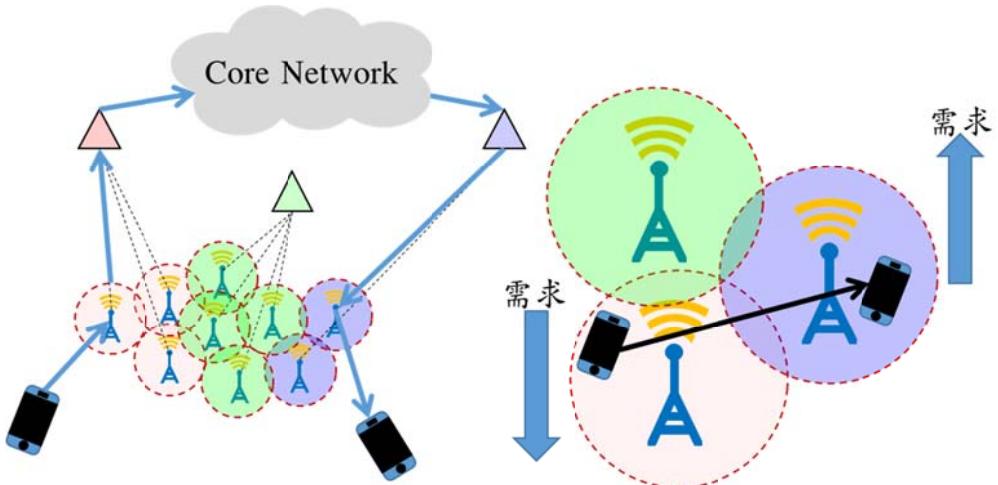


Fig.1-2：網路環境架構

在傳統的通訊環境中，可以將所有的資料配置在不同的伺服器內，其優點是不花費任何通訊成本就可以快速地建立連線所需的資料，卻會造成大量的建構成本，有些資料也並非使用者所需要的，這也造成無謂的浪費，因此需發展系統性的無線網路需求規劃方法，將數個基地台適當的由同個 RNC 管理。這樣做的好處是甚麼？舉個例子：如果使用者所要求的資料正好儲存在該 RNC 中，RNC 就可以直接將資料傳送給使用者，否則就須經由核心網路傳送給其他 RNC 才得以取得，這樣就會耗費通訊成本與傳輸時間。

不同的基地台在不同的時間、地區，所負擔的網路需求量也不盡相同，這樣可能會使決策者在規劃無線網路資源時有所困難，但是，如果將多個基地台彙整成同個 RNC 管理時，網路需求的變化可能會較為穩定，更進一步，如果可以將不同趨勢的區域進行整合，利用 RNC 做有效的控管的話，就會有截長補短的效果，提高各個基地台的網路使用率。

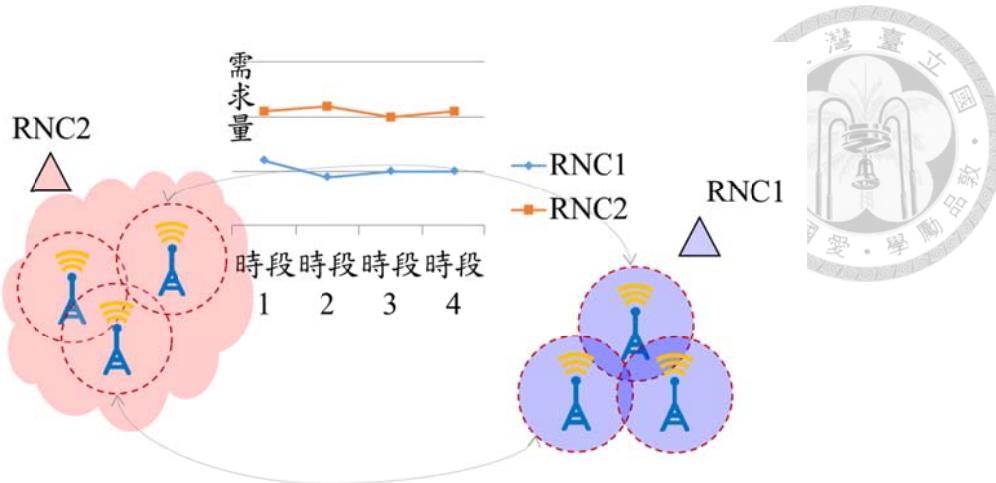


Fig.1-3：研究目標示意圖

本研究以 RNC 的配置計畫為例，初始建立整體使用者的流動模型，該模型的結果闡釋所有使用者在城市內的移動現象，再利用此模型配合不同時段下的網路需求，進行不同區域基地台的控管計畫，意即，哪些基地台該由哪個 RNC 負責控管，我們期待同個 RNC 下的網路需求隨著時間呈現穩定的狀態，這可以使網路使用率增加；另外不同 RNC 間的人口轉移數希望可以越少越好，使得 RNC 可以各司其職，減少因為建立連線通道而造成的效果。

### 1.3 論文架構

本研究的章節安排如下：從問題描述，第二章文獻回顧描述手機使用者行動行為及網路資料分配的相關研究、馬可夫轉移矩陣模型、組合最佳化方法等。第三章描述本研究所獲得之資料，進行的資料處理方式與使用者在地區間之行動模式建立。第四章針對探討的議題建立無線網路資源分配之需求規劃模型，並介紹其指標與方法構想。第五章進行實際資料的驗證並比較結果，並分析不同狀況下適宜的方法，以利決策者進行決策。最後，在第六章做結論以及探討未來可以研究的方向。下圖 Fig.1-4 為論文架構：

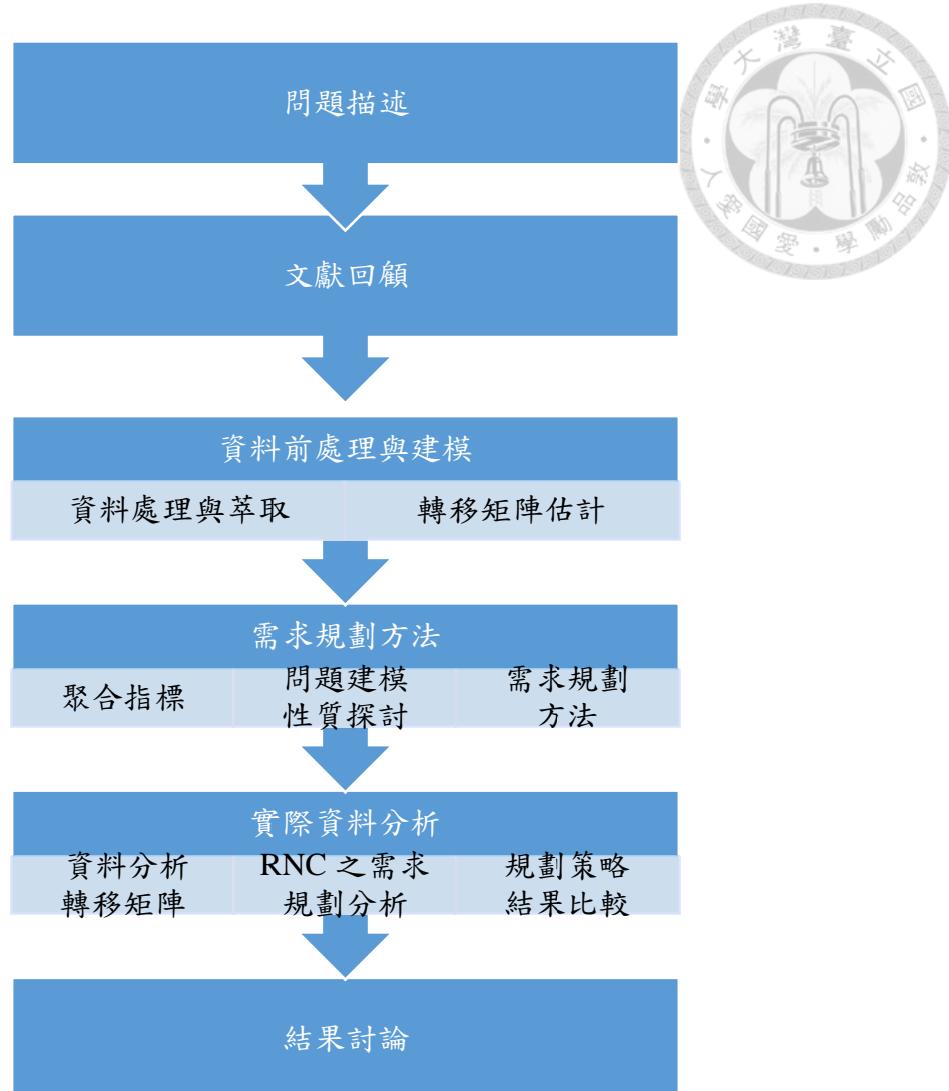


Fig.1-4：研究架構

本研究的成果在於發展一套無線網路需求規劃及資源分配的系統，其運作流程如下：

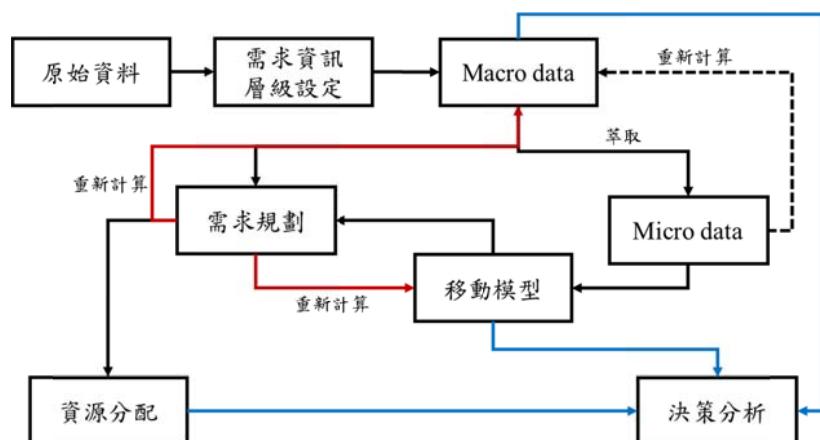


Fig.1-5：需求規劃策略及資源分配流程圖



## Chapter 2 文獻回顧

本章文獻回顧分為三個部分依序為：1.手機使用者行動行為及網路資料分配的相關研究、2.馬可夫轉移矩陣模型的估計、3.組合最佳化與分群方法等。

### 2.1 手機使用者移動行為與網路規劃

在 Song (2010)[1]的論文指出：人類的移動具有一定的可預測性，以 1 小時為單位，探討手機使用者在城市裡的移動模式所呈現的情形。該研究定義機率  $\Pi$ ：使用適當的演算法可以預測使用者未來移動的準確度。也提出  $\Pi^{\max}$  表示預測使用者移動性的一個限制，從數據中得到的結果是：在適當的演算法下，使用者有高達 93% 的可預測性，而  $\Pi^{\max}$  的分配也有高集中趨勢，推論大多數的使用者雖然移動的軌跡看似隨機，但是分析歷史數據收集到一天的移動行為，其移動性是可以被預測的。另外也定義使用者規律性 regularity  $R$ ：一天 24 小時中，找到某位使用者在他最常拜訪的地點的機率， $R$  代表  $\Pi$  的下界，其不考慮時間與使用者移動的關係，研究顯示  $R$  在一週內有明顯的規律性，而在每天不同時段中，使用者拜訪不同地點的數量在不同的時段的多寡，與  $R$  有負向關係，意即，使用者拜訪的地點數越高，其規律性就會減少。

在 Schneider (2013)[2]文中，除了呼應 Song 提出的使用者移動的可預測性外，該研究定義 daily human mobility motifs：一個隨機的網路系統可能由數種不同的子網路構成，如果其子網路是頻繁的出現或是為一個顯著的模式，就可稱之為 motifs。該研究以一天為範圍，並以 motifs 的方式表示所有使用者可能的行動模式。而研究也驗證使用者一天的移動模式有 90% 可以被限制在 17 種不同的 motifs 當中，即使在不同的城市，也可以用這些 motifs 顯示使用者的類似的移動行為。通常幾個月內使用者的移動模式呈現穩定的狀態。

網路資料分配的相關研究，可以追溯 Peng (2005)[3]根據所有使用者的移動行為進行單一性及全域性的資料分配，單一性指得是如何在伺服器中存取符合單一使用者所需要的資料，全域性指的是考量整體使用者的情況[4]，進行最適當的資料分配方式，該文章也根據上述兩種情況發展不同的演算法，並發展指標去計算使用者之間移動的共通性，作為判斷演算法好壞的依據。

上述文獻是使用者的移動性及網路資源分配的相關研究，可以發現使用者的移動行為成為近期研究的重要方向，如何從新的觀點考量使用者移動對網路環境的影響，進而優化網路環境？是本研究主要研究項目。



## 2.2 轉移矩陣模型的估計

離散馬可夫模型之定義[5]：令  $\{X_n, n=0,1,2,\dots\}$  為一個隨機過程， $X_n \in S, \forall n$  來自有限狀態空間  $S$ ， $X_n = i$  表示時間  $n$  下的狀態為  $i$ 。如果滿足馬可夫性質，意即  $\Pr(X_{n+1} = j | X_n = i, X_{n-1} = i_{n-1}, \dots, X_0 = i_0) = \Pr(X_{n+1} = j | X_n = i)$ 。如果此機率不會隨著時間而改變(time-stationary Markov chain)，就可以表示為  $\Pr(X_{n+1} = j | X_n = i) = P_{ij}$  又稱穩定馬可夫鏈。離散馬可夫模型表示未來的狀態  $X_{n+1}$  只與目前的狀態  $X_n$  有關。

有限狀態下的馬可夫鏈，可以將所有的狀態轉移機率寫成矩陣的形式  $\mathbf{P}$ ：

$$\mathbf{P} = \begin{bmatrix} P_{00} & P_{01} & \cdots & P_{0m} \\ P_{10} & P_{11} & \cdots & P_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ P_{m0} & P_{m1} & \cdots & P_{mm} \end{bmatrix}_{m \times m}$$

其中，因為機率值介於  $[0,1]$  區間，而且所有可能的狀態都會發生於狀態空間內，可以得到：

$$P_{ij} \geq 0, \quad \forall i, j \geq 0$$

$$\sum_{j=0}^m P_{ij} = 1, \quad \forall i = 0, 1, \dots, m$$

令  $\Pr(X_n = j) = p_j^{(n)}$  為經過  $n$  次轉移後停留在狀態  $j$  之機率， $p^{(n)}$  為一組機率列向量表示所有狀態下之  $p_j^{(n)}$ ，馬可夫矩陣有一些基本性質如下：

$$p^{(n)} = p^{(n-1)} \mathbf{P}$$

$n$ -step 馬可夫轉移機率  $P_{ij}^n$ ：從 Chapman-Kolmogorov 方程式我們可以得到

$$\mathbf{P}^{(n)} = \mathbf{P}^n \text{ 與 } p^{(n)} = p^{(0)} \mathbf{P}^{(n)}$$

也就是  $n$ -step 馬可夫轉移相當於 1 階馬可夫矩陣的  $n$  次方。



考慮目前有  $m$  個狀態之馬可夫鏈，從中觀察  $n$  次轉移而得到觀察值，如下：

	1	2	...	$m$	
1	$n_{11}$	$n_{12}$	...	$n_{1m}$	$n_1$
2	$n_{21}$	$n_{22}$	...	$n_{2m}$	$n_2$
...	...	...	...	...	...
$m$	$n_{m1}$	$n_{m2}$	...	$n_{mm}$	$n_m$
					$n$

現在假設此穩定馬可夫鏈形式為

$$\mathbf{P} = \begin{bmatrix} P_{00} & P_{01} & \cdots & P_{0m} \\ P_{10} & P_{11} & \cdots & P_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ P_{m0} & P_{m1} & \cdots & P_{mm} \end{bmatrix}_{m \times m}$$

其最大概似估計量(MLE estimator)為

$$\hat{P}_{ij} = \frac{n_{ij}}{n_i}, \quad i, j = 1, 2, \dots, m \quad \text{其中 } n_i = \sum_{j=1}^m n_{ij}$$

Goodman & Anderson (1957)[6]證明其估計式為 MLE 的解且為有一致性但有偏誤的估計量。

本研究利用轉移矩陣模型的估計概念，對整體區域的人口移動建立轉移次數矩陣(transition count matrix)與轉移矩陣(transition matrix)，該轉移矩陣可以描述連續時段內，不同區域間的使用者轉移比例，這個模型可以應用於後續的網路資源規劃。

### 2.3 組合最佳化與分群方法

組合最佳化問題是求取多個離散元素間最佳的排列組合方式，著名的問題有旅行推銷員問題(Traveling Salesperson Problem, TSP)、N 皇后問題(N queens puzzle)、裝箱問題(packing problem)、分群問題(clustering)等。本研究探討的問題種類屬於分群的問題，意即，如何將  $n$  個元素分成  $k$  群，使得群與群之間相似度越高，分群問題可能的組合數：根據(Jain and Dubes, 1988)[7]的文獻，將  $n$  個元素



分給  $k$  群的問題，其可行解的個數如下：

$$S(n,k) = \frac{1}{k!} \sum_{i=1}^k (-1)^{k-i} \binom{k}{i} i^n$$

舉個例子  $S(10,4) = 34105$  、 $S(19,4) \approx 10^{10}$ ，會發現其可行解個數增長劇烈，因為這個原因，實務上的分群方法都是檢視一小部分的可行解，在這麼小的集合中找到最優解，或是至少能找到不錯的次優分割方式是分群問題的目標。以下為相關的分群演算法[8]：

階層式分群法(Hierarchical Clustering)或是階層式聚合分群法(Hierarchical Agglomerative Clustering, HAC)。階層式聚合分群法是先將每個元素都當作是一個群集，根據相似度或是距離矩陣，將最近的合併，由下往上合併。一開始，我們必須去計算出每對群集之間的相似度，常見有 3 種方式：

1. 單一連結法(single-linkage)：在兩群集間，找出最相似或是距離最近的兩個物件，用他們之間的相似度來當作是兩群集間的相似度。
2. 完整連結法(complete-linkage)：在兩群集間，找出最不相似或是距離最遠的兩個物件，用他們之間的相似度來當作是兩群集間的相似度。
3. 平均連結法(average-linkage)：在兩群集間，將群集中每個物件互相配對，求出兩群集中所有物件間的平均相似度，來當作是兩群集間的相似度。

不同的群集距離定義方式會有不同的結果，單一連結法容易造成大群集與小群集間的差異較大，完整連結法則是會平均群集的大小，平均連結法則在 2 者之間。

K-Means (K-Medoids) Clustering 的目的是：把  $n$  個元素分配到  $k$  個群集中，使得每個元素都屬於離他最近的均值對應的群集，以之作為群集的中心點。K-Medoids 算法中，我們將從當前集群中選取一個元素，它到其他所有元素的距離之和最小作為中心點。K-means 和 K-Medoids 之間的差異就類似於一個數據樣本的平均值和中位數之間的差異：前者的取值範圍可以是連續空間中的任意值，而後者只能在樣本給定的資料點裡面選擇。影響上述兩種方法最大的關鍵在於初始值的設定，不好的起始中心容易造成找到區域最優解的發生。

分群的問題是一種有特別結構的組合優化問題，根據元素之間的遠近，以便進行元素的歸類，其目標是希望越相似，也就是距離越近的元素可被分為同一群



集。但是本研究的目的並非單純的將元素依照距離遠近進行聚合，我們有明確的目標函式可進行評估。因此，從不同的角度來看，也可以考慮不同的排列組合對目標函數造成影響，常見的優化方法有下列幾種：

貪婪法(Greedy Method)[9]：某些種類的組合問題可以使用貪婪法解決，以分群問題為例：其方式是每次的聚合時觀察當下的目標值的多寡，如果下降(最小化)或上升(最大化)最多者就以此為基礎做聚合。類似的方式也可應用於工作指派問題：

Objective function:

$$\text{Max} \left\{ W = \sum_{e \in F} w(e) > 0 : F \in I \right\}$$

Define two sets  $S, Y$  :

$$S = \text{set of jobs} : \{s_1, s_2, \dots\}$$

$$Y = \text{set of workers} : \{y_1, y_2, \dots\}$$

該問題描述如何將工人(workers)指派給各個工作(jobs)以達到最大化的利潤 $W$ ，其可行解域 $F$ 可寫成各種 $(s, y)$ ,  $s \in S; y \in Y$ 之組合。貪婪法如果想要求得最佳解的條件是：原問題必須有最優子結構(Optimal substructure)的性質，最優子結構的意思是局部最優解能決定全局最優解。簡單地說，問題能夠分解成子問題來解決，子問題的最優解就能推演到最終問題的最優解。

基因演算法(Genetic Algorithm, GA)[10]，是人類依照生物學中優進廢退說的觀念所發展出來的一種演算法。利用「選擇」、「複製」、「交配」、「突變」等步驟去尋找最適合環境的基因。其常應用於數個組合最優化的問題，像是旅行推銷員、排程問題等，這些問題想要在有限的時間內計算完畢全部可行解幾乎是不太可能的，而基因演算法就是以某種系統性的方式，一次又一次的找到更好的解。基因演算法的染色體、解碼方式皆須要針對特殊的問題而有特殊的設計，此外其結果不一定會是最佳解。

本研究基於上述想法建立資源規劃方法，在不同的目的下，達到一定的優化效果，並輔助決策者進行規劃策略。



## Chapter 3 資料前處理與建模

接下來的小節，我們將介紹原始資料的型態，以及如何從資料萃取出需求規劃所需的資訊：不同區域在不同時段下的行動網路需求分佈，估計轉移矩陣表示區域之間的移動情形。

### 3.1 資料處理

Signaling Event Log Data 來自使用者使用無線網路服務時與基地台建立連線之記錄，該資料記錄某位使用者位於何處、何時，使用了何種項目的網路連線，也記錄所連結到的 RNC 與 CELL ID。資料欄位與資料範例如下表：

User ID	Date	Time	RNC	Cell ID	Type	經度	緯度
1	2014/06/21	10:00:01	1	7821	1	24.5768	30.1221
1	2014/06/21	11:45:08	1	7830	6	24.5801	30.1242
...	...	...	...	...	...	...	...

Table 1：資料欄位與範例

網路連線類型的種類如下：

- Conversational Call：使用者語音對話時留下的紀錄。
- Streaming Call：使用者觀賞影音、網路串流資料時留下的紀錄。
- Interactive Call：使用者瀏覽網頁時留下的紀錄。
- Background Call：使用者進行下載或上傳留下的紀錄。
- MMS：使用者傳送多媒體訊息時留下的紀錄。
- SMS：使用者傳送短訊時留下的紀錄。

不同類型的連線需求所需的資源會不同，舉例來說：語音通話與短訊就需要不同的傳輸品質，語音通話為了確保不斷線，通常會需要較優先的服務品質(Quality of Service, QoS)，短訊則相反。另外串流、互動、背景等資料傳輸是近年來成長劇烈的服務項目，QoS 提供了針對不同資料流採用相應不同的優先等級，保證資料流的效能達到一定的水準。

該區域由 7 個 RNC 所涵蓋，包含 9000 多個 Cells，地理範圍大小為 1100 平方公里，有 200 萬個手機使用者，該資料的時間長度為 7 天(一週)。由某外商公司提供之事件發生時，利用基地台定位估計出實際經緯度位置，其誤差大約 50



公尺，因此我們將單位設定成 100 公尺為 1 個單位，時間單位則是 1 秒。

將原始資料儲存成網路需求資訊：我們所在意的是特定區域、時間中，不同類型的網路需求數量是多少。為解決關聯資料庫的查詢效能瓶頸，提出的資料模型即是資料立方體。以三維結構為例，分析人員可以從時間、類型、地區三種維度組成的立方體來檢視需求數量，在某個時間點的某個地區，特定類型組成的小立方體中，儲存一筆數字表示網路需求，這種結構在翻轉檢視視角時，仍然可以快速反應。本研究將使用者依據其時間、地點與連線類型進行整理，計算相同類型的使用者資料的總和而得到某個特定時段下的網路需求數，如下圖所示：

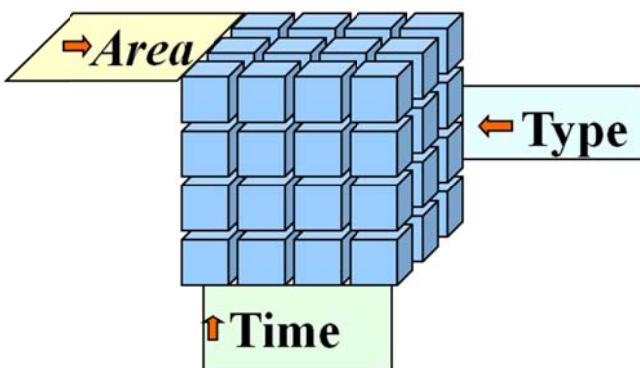


Fig.3-1：無線網路需求資料立方體

本研究將一些不合理的資料做了剔除的動作，判斷的依據是其位置隨著時間的變化，也就是速度，不符合城市移動的最大上限，像是時速 200 公里以上的資料就會刪除後者，如下表：

User ID	Date	Time	RNC	Cell ID	Type	Lng	Lat
8	2014/06/22	10:00:01	1	7821	1	24.5768	30.1221
8	2014/06/22	10:0:07	4	5250	4	25.6000	29.5688
...	...	...	...	...	...	...	...

Table 2：不合理的事件記錄資訊

本研究亦配合當地的市政規劃描繪出其行政區域，行政區域可以被歸類為一種地區 Region 範圍，其劃分方式如下圖所示：

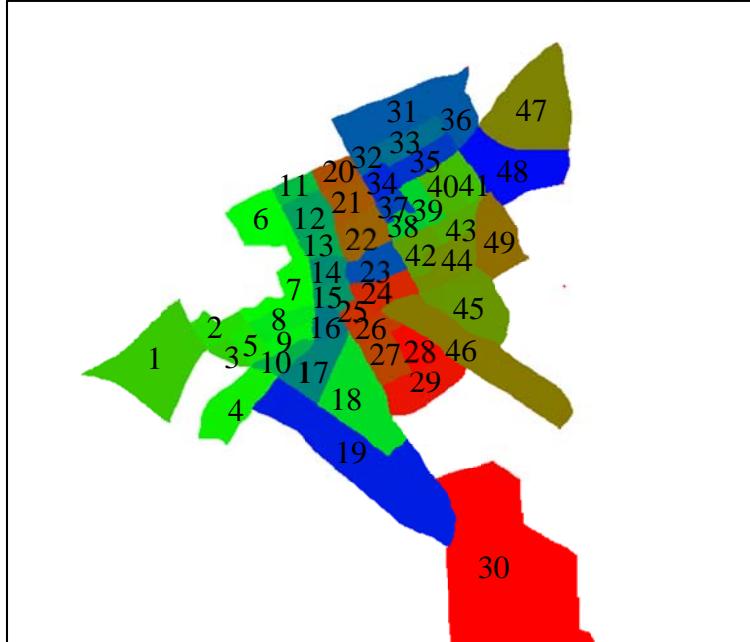


Fig.3-2：當地行政區

以行政地區進行的需求規劃模型，可使政府了解到不同行政區域目前的網路環境，在未來可以做相應的市政規劃。

我們將使用者的經緯度位置對應上述的行政區域進行編號，重新將行政區的資訊加入原始資料中，並以 1 小時為單位，將所有使用者一天下來在何處使用網路的資訊儲存起來，如下表：

Time User ID	00:00-01:00	01:00-02:00	02:00-03:00	...
1	1	2	5	...
2	40	0	0	...
3	39	40	40	...
...	...	...	...	...

Table 3：使用者在不同時段的移動情形

Table 3 表示從使用者觀點，描述使用者一天下來的移動情形(值為區域編號)，0 為該使用者在那個時段沒有使用網路。我們以使用者在某時段中最後使用網路服務的地點表示該用戶在那段時間可能停留的地區，如下圖所示：

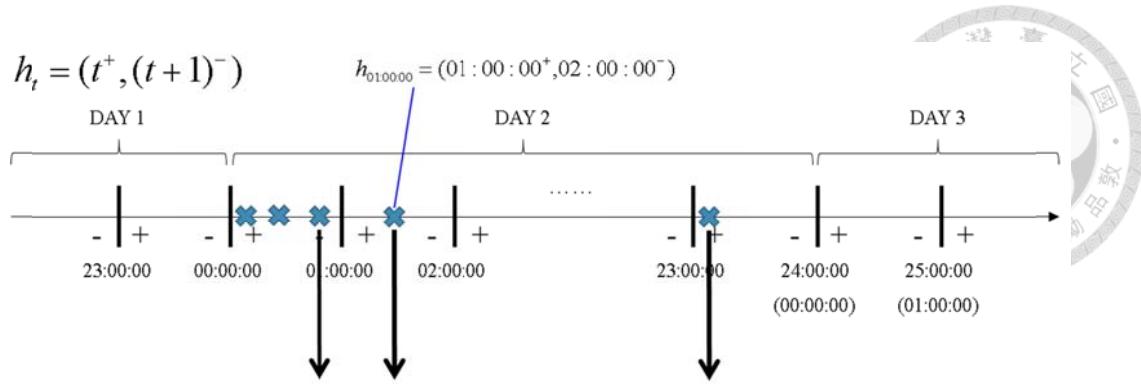


Fig.3-3：使用者在不同時段的移動情形之萃取方式

本研究以  $\text{Time}_{i_0 \cdot i_1 \cdots i_l}$  、  $\text{Region}_{j_0 \cdot j_1 \cdots j_m}$  與  $\text{Type}_{k_0 \times k_1 \cdots \times k_n}$  [11] 表示某個特定時間、地點下，特定幾種連線類型，其網路連線需求數的表達式如下：

$$X_{ijk} = \text{Time}_{i_0 \cdot i_1 \cdots i_l} \times \text{Region}_{j_0 \cdot j_1 \cdots j_m} \times \text{Type}_{k_0 \times k_1 \cdots \times k_n}$$

$i_0 \times i_1$  為不同層級之關係，像是  $\text{Time}_{\text{week} \cdot \text{day} \cdot \text{hour}}$  的層級關係如下圖所示：

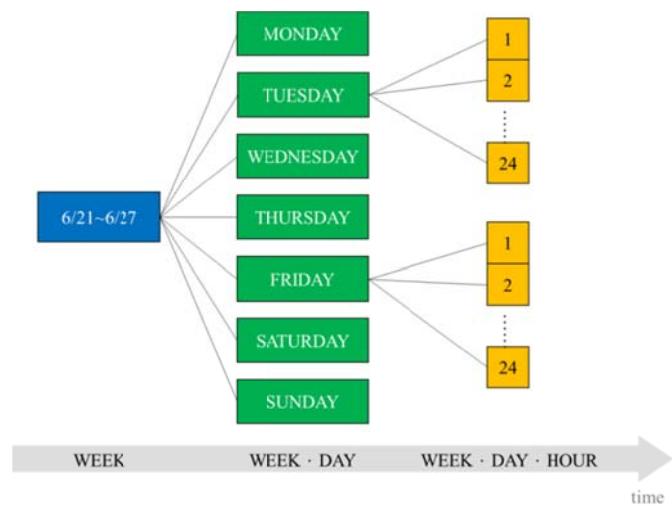


Fig.3-4：時間觀點之層級關係

$k_0 \times k_1$  為不同屬性之關係，像是  $\text{Type}_{\text{conversation} \times \text{sms}}$  的屬性關係如下所示：

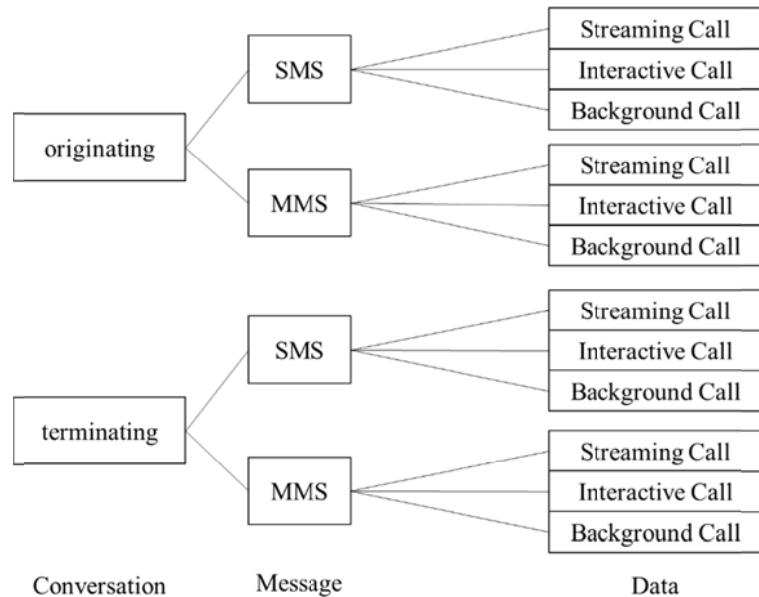


Fig.3-5：不同類型之屬性關係

如果我們只考慮該屬性的最高層級，就以  $X_{\text{All}}$  表示，如  $\text{Type}_{\text{All}}$  表示使用者所有可能的連線種類。

聚合，解析樞紐分析模式的建立：就商業分析而言，大多數檢視資料時，通常需要的資料型態是經過妥善彙整，例如依照月份、季別、年度等加總過的需求數量。聚集符合分析時的實際需求，也能提升檢視時的效能，更有利於 OLAP(On-Line Analytical Processing，線上分析處理)分析時，迅速取得所需數字。樞紐分析是進行 OLAP 分析時常見的分析方式。分析時使用者可以將檢視屬性層級加入到樞紐分析矩陣中，視需要放置在行或列。樞紐分析表之所以得其名，是因為它能對調行、列的位置，靈活調整檢視的角度。現今 OLAP 的樞紐分析表大多支援解析與聚合功能，呈現更為細節的資料面向。本研究以 Python 程式語言進行實作處理，可以輸入所需的屬性層級，快速抓取資訊。

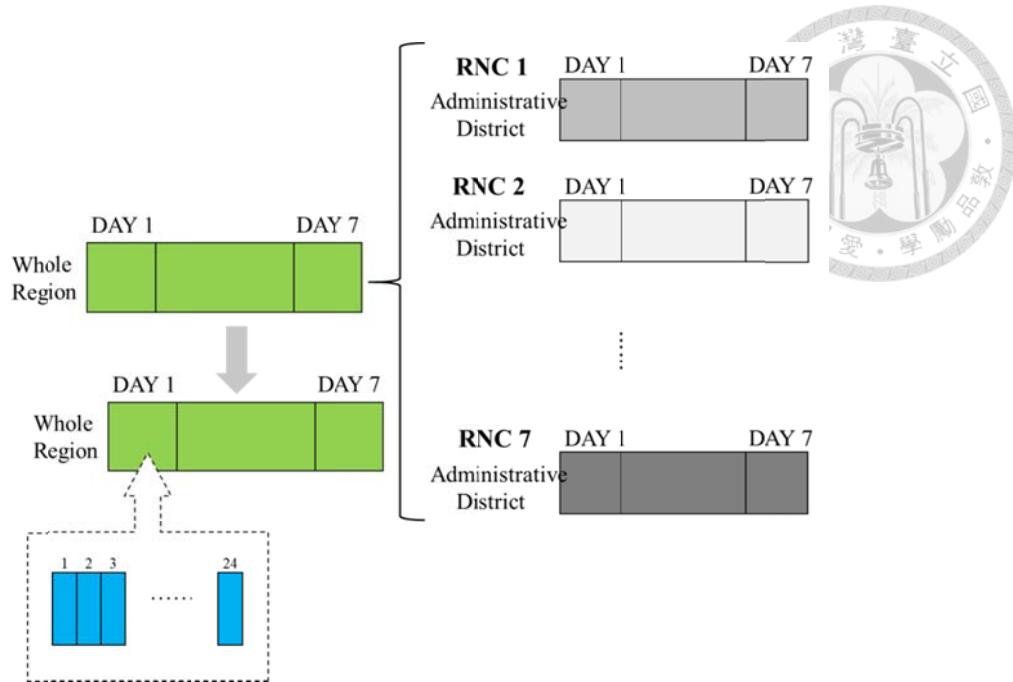


Fig.3-6：根據時間解析與根據 RNC 解析之資料

根據不同層級之網路需求，本研究第一個研究項目是觀察此區域整體使用者移動現象是否可以呈現一個規律的模式。像是依據行政區的劃分，是否可以有效地呈現通勤、人潮流動的現象，以及熱點位置分析，這些訊息可以提供市政府進行有效的都市規劃方法，我們會以不同的圖表及數據呈現網路需求的分佈與變化。

本研究第二個研究項目式網路資源規劃，目前先依據此

$\text{Time}_{\text{week}\cdot\text{day}\cdot\text{hour}} \times \text{Region}_{\text{administrative region}} \times \text{Type}_{\text{All}}$  層級進行區域的聚合，其目的在於如何讓不同的 RNC 去控管不同的地區的網路資源以獲得更好的使用效率。未來可以延伸至不同層級、屬性大小進行不同需求層面的規劃。萃取資料的方法如下圖所示：

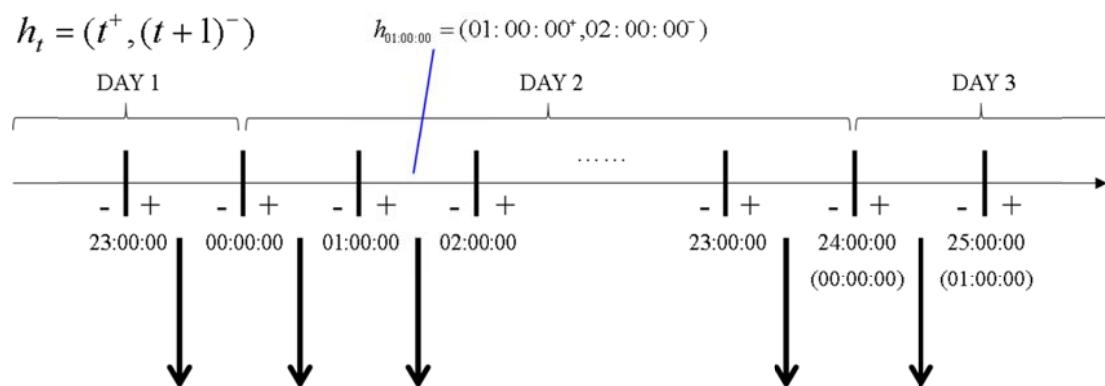
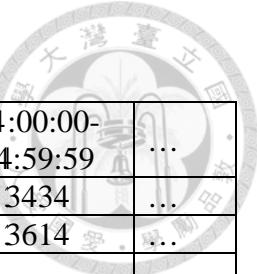


Fig.3-7 :  $\text{Time}_{\text{week}\cdot\text{day}\cdot\text{hour}} \times \text{Region}_{\text{administrative region}} \times \text{Type}_{\text{All}}$  (Macro data) 資料萃取方法



下表是我們萃取出來的結果：

Time RNC	00:00:00- 00:59:59	01:00:00- 01:59:59	02:00:00- 02:59:59	03:00:00- 03:59:59	04:00:00- 04:59:59	...
1	4630	4722	3956	813	3434	...
2	3595	4900	4349	5	3614	...
...	...	...	...	...	...	...

Table 4 : Time<sub>week•day•hour</sub> × Region<sub>administrative region</sub> × Type<sub>All</sub> (Macro data) 之結果

### 3.2 轉移矩陣之估計

從上述的層級中，萃取出來的資料稱之為 Macro data，其描述 49 個區域在 24 小時下的需求變化。更進一步的，本研究欲建立其區域間之流動模式，因此針對 Macro data 進行抽樣以瞭解區域之間的移動事件。移動事件描述使用者在不同區域、不同時段之間的移動，由於本研究之資料並沒有紀錄使用者在基地台之間的換手(handover)，因此以使用者在連續時段間的停留位置變化來表示移動事件。

抽樣的方法如下圖所示：

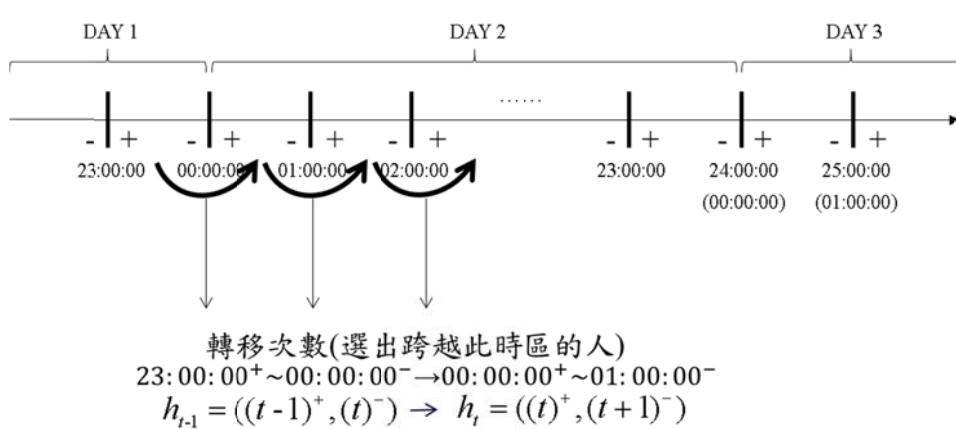


Fig.3-8 : Micro data 之抽樣方法

這樣萃取出的移動事件稱之為 Micro data (N)，其描述連續時段，不同區域使用者的轉移次數，這個資訊可以用來估計轉移矩陣，以表示不同時段間，區域流動的現象為何。

轉移矩陣的估計方法如同前述，本研究以點估計的方式估計轉移機率參數：

$$\hat{P}_{ij}(t) = \frac{N_{ij}(t)}{\sum_j N_{ij}(t)}$$

其中  $N_{ij}(t)$  表示多少使用者在時段  $h_{t-1}$  到時段  $h_t$  間，位於區域  $i$  轉移至區域  $j$  之使



用者數， $P_{ij}(t)$ 代表的意義為區域*i*轉移至區域*j*的比例，而非人口流動的量，看比例的原因是因為人口轉移的數可能不同，像是如果原本人數稀少的*j*區域(可能是因為該區域較小)，與原本較多停留在*i*區域的人數比起來，*j*區域的移動的特性就會被比下，因此看轉移比例的方式可以清楚的顯現區域的流動性。

在時間層面，亦可考量不同時間長度之轉移現象，像是如果以1天做為目前之時間規劃層級，可以聚集不同時段的 $N_{ij}(t)$ ，進而估計1天下來的轉移矩陣，如下式：

$$P_{ij} = \frac{\sum_t N_{ij}(t)}{\sum_j \sum_t N_{ij}(t)}$$

$P_{ij}$ 代表聚集時間層級後，使用者在區域間轉移的比例。

轉移矩陣的建立，可以觀察不同時間長度，區域間人口流動的比例，以都市規劃的角度來看，能夠建立一個模型描述城市內的人潮流動，可以有效的利用這個訊息進行交通流量控管以及都市建設；本研究亦探討人口流動與網路需求之關係，做為網路資源規劃策略評估的一項重要指標。

### 3.3 使用 Micro data 重新估計 Macro data

Micro data 是從有跨越2個時段的使用者取交集下而得到的，其與 Macro data 直接抽取每個時段的使用者記錄是不同的，可想而知的是 Micro data 裡面的使用者較 Macro data 的少，或著也可以說 Micro data 是從 Macro data 抽樣而得到的。因此，我們也去瞭解 Micro data 與 Macro data 之間的差異有多少，利用 Micro data 生成新的 Macro data 的方式。

方法介紹：對於時段 $h_{t-1}$ 到時段 $h_t$ 間的轉移次數 $N_{ij}(t)$ ，加總其下個時段所出現的人數，公式如下：



$t-1$	1	2	...	$m$	
1	$n_{11}$	$n_{12}$	...	$n_{1m}$	$n_1$
2	$n_{21}$	$n_{22}$	...	$n_{2m}$	$n_2$
...	...	...	...	...	...
$m$	$n_{m1}$	$n_{m2}$	...	$n_{mm}$	$n_m$
	$\sum_{i=1}^m n_{i1}$	$\sum_{i=1}^m n_{i2}$	...	$\sum_{i=1}^m n_{im}$	$n$

其中， $\sum_{i=1}^m n_{ij}$  即為從 Micro data 估計出來  $h_t$  時段使用無線網路的使用者數。後續也會比較其與實際 Macro data 的差異。

## Chapter 4 無線網路資源分配之需求規劃方法

本研究問題為如何將  $I = 49$  個行政區域分配至  $K = 7$  個群集可以達到最穩定的需求數以及最小化區域間的轉移比例(或是轉移次數)。這個問題屬於組合優化問題。接下來的小節中，將建立評估規劃策略之 2 項指標，針對指標的分析，將一些 surrogate 性質應用於規劃方法中。優化的方法有四種，從貪婪式、階層式、K-Means 分群與基因演算法的想法而來，其中會詳述初始化、限制式的設定，以及聚集時參考的性質、指標等。

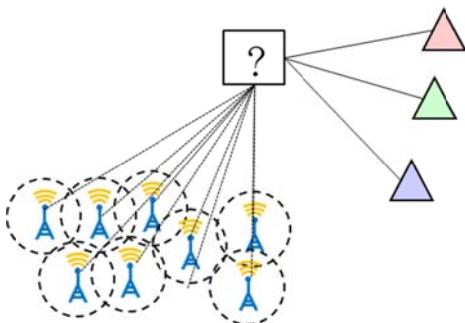


Fig.4-1 : 49 個區域分派給 K 群

以下為本研究定義的符號：

符號	定義
$i$	區域 $i$ , $i = 1, 2, \dots, I$
$k$	集群 $k$ , $k = 1, 2, \dots, K$
$c_{ik} = \begin{cases} 1, \\ 0, \end{cases}$	如果區域 $i$ 分配給集群 $k$ Otherwise
$d_{ih}$	區域 $i$ 在某時段 $h$ 的無線網路需求量
$\mathbf{d}_i$	一天下來區域 $i$ 的無線網路需求量( $d_{ih}$ )
$D$	最大無線網路需求上限
$N_{ij}(t)$	時段 $h_{t-1}$ 至時段 $h_t$ 從區域 $i$ 轉移至區域 $j$ 的使用者轉移量
$\mathbf{N}(t)$	時段 $h_{t-1}$ 至時段 $h_t$ 的轉移總量矩陣，包含所有區域 $i$ 轉移至區域 $j$ 的使用者轉移量( $N_{ij}$ )
$N_{ij}$	一天內從區域 $i$ 轉移至區域 $j$ 的使用者轉移量
$\mathbf{N}$	一天內的轉移總量矩陣，包含所有區域 $i$ 轉移至區域 $j$ 的使用者轉移量( $N_{ij}$ )

$P_{ij}$	從區域 $i$ 轉移至區域 $j$ 的使用者轉移率
$\mathbf{P}$	轉移矩陣，包含所有區域 $i$ 轉移至區域 $j$ 的使用者轉移量 ( $P_{ij}$ )
$M_{kl}$	從集群 $k$ 轉移至集群 $l$ 的使用者轉移量
$\mathbf{M}$	轉移量矩陣，包含所有集群 $k$ 轉移至集群 $l$ 的使用者轉移量 ( $M_{kl}$ )
$Q_{kl}$	從集群 $k$ 轉移至集群 $l$ 的使用者轉移率
$\mathbf{Q}$	轉移矩陣，包含所有集群 $k$ 轉移至集群 $l$ 的使用者轉移率 ( $Q_{kl}$ )
$loc_i = (x_i, y_i)$	區域 $i$ 的需求密度中心位置
$S(loc_i, loc_j)$ $= \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$	區域 $i$ 與區域 $j$ 的中心距離
$\mathbf{Loc}$	包含所有區域中心位置 ( $loc_i$ ) 的集合

Table 5 : 符號定義

接下來為符號的一些性質：

- 一天內的轉移總量之計算： $N_{ij} = \sum_{t=1}^{24} N_{ij}(t)$
- 轉移量矩陣( $\mathbf{N}/\mathbf{M}$ )估計轉移矩陣( $\mathbf{P}/\mathbf{Q}$ )： $P_{ij} = \frac{N_{ij}}{\sum_{j=1}^I N_{ij}}$  ;  $Q_{kl} = \frac{M_{kl}}{\sum_{l=1}^K M_{kl}}$
- 集群  $k$  的每小時需求平均數 ( $\bar{\mathbf{d}}_k$ )： $\bar{\mathbf{d}}_k = \frac{\sum_{h=1}^{24} \sum_{i=1}^I c_{ik} \cdot d_{ih}}{24}$
- 集群  $k$  的每小時網路需求變異數 ( $s_k^2$ )： $s_k^2 = \frac{\sum_{h=1}^{24} \sum_{i=1}^I c_{ik} (d_{ih} - \bar{\mathbf{d}}_k)^2}{23}$
- 集群  $k$  至集群  $l$  的轉移次數： $M_{kl} = \sum_{j=1}^I \sum_{i=1}^I c_{ik} \cdot c_{jl} \cdot N_{ij}$
- 集群  $k$  變異係數 Coefficient of variance ( $CV_k$ )： $CV_k = \frac{s_k}{\bar{\mathbf{d}}_k}$



- 非對角線轉移矩陣( $\check{\mathbf{P}}/\check{\mathbf{Q}}$ )： $\check{\mathbf{P}} = \begin{bmatrix} 0 & P_{12} & \cdots & P_{1n} \\ P_{21} & 0 & \cdots & P_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1} & P_{n2} & \cdots & 0 \end{bmatrix}_{n \times n}$ ；

$$\check{\mathbf{Q}} = \begin{bmatrix} 0 & Q_{12} & \cdots & Q_{1m} \\ Q_{21} & 0 & \cdots & Q_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ Q_{m1} & Q_{m2} & \cdots & 0 \end{bmatrix}_{m \times m}$$

對角線轉移矩陣( $\hat{\mathbf{P}}/\hat{\mathbf{Q}}$ )： $\hat{\mathbf{P}} = \begin{bmatrix} P_{11} & 0 & \cdots & 0 \\ 0 & P_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & P_{nn} \end{bmatrix}_{n \times n}$ ； $\hat{\mathbf{Q}} = \begin{bmatrix} Q_{11} & 0 & \cdots & 0 \\ 0 & Q_{22} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & Q_{mm} \end{bmatrix}_{m \times m}$

## 4.1 聚合指標

行動網路需求資料可以以非常多種聚合群集去檢視，不同的聚合群集需求數量的資料也不盡相同，該如何評估各種聚合群集結果以了解規劃策略的好壞是個重要的議題。本節將探討 2 種指標，第一種指標表示行動網路需求的穩定性；第二種指標表示區域之間的流動性。

### 4.1.1 需求變異相關指標

在過去的研究中，往往都直接以變異數直接描述需求隨著時間的震盪大小，但是在不同聚合中，需求平均數的增加可能會造成變異數的提高，舉例來說：

$\text{Var}(X_1 + X_2 + X_3) = 3\text{Var}(X)$ ，這會使得標準差  $\sigma$  變為原來的  $\sqrt{3}$  倍，如下圖所示：

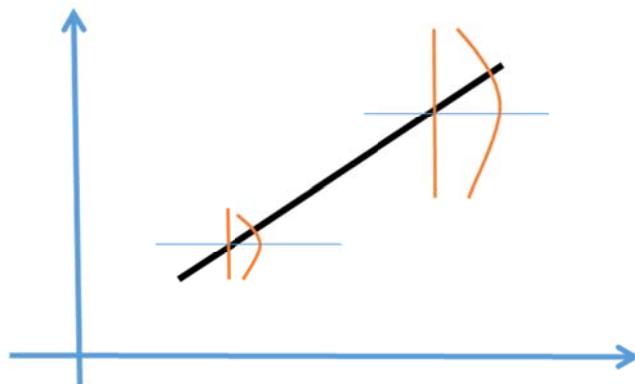


Fig.4-2：需求增加造成變異數增大



這會造成評估不同聚合結果時的困難，為了弭去這個效應，我們以變異係數 CV 作為一個衡量不同聚合群集的標準， $CV = \frac{\sigma}{\mu}$ ，其中， $\mu$  為需求平均、 $\sigma$  為需求標準差，CV 觀察的是當下的變異數與平均數的比例，這種去單位化的方式可以解決因為  $\mu$  造成的變異增加。

然而，不同的規劃策略會有數種聚合群集需要比較，該如何評比兩種策略下的聚合結果呢？這裡採取 2 種方式：簡單平均數(Simple-average CV, SCV)與加權平均數(Weighted-average CV, WCV)的方式計算某種規劃策略下，整體聚合群集的表現為何，公式如下：

$$SCV = \frac{CV_1 + CV_2 + \dots + CV_K}{K}$$

與

$$WCV = CV_1 \frac{\bar{d}_1}{\sum_{k=1}^K \bar{d}_k} + CV_2 \frac{\bar{d}_2}{\sum_{k=1}^K \bar{d}_k} + \dots + CV_K \frac{\bar{d}_K}{\sum_{k=1}^K \bar{d}_k}$$

其中， $k$  為一個聚合群集， $CV_k$  為該聚合群集之 CV， $\bar{d}_k$  為該聚合群集之需求平均數。

依據 CV 之定義，WCV 可以化簡成下式：

$$\begin{aligned} WCV &= \frac{s_1}{\bar{d}_1} \frac{\bar{d}_1}{\sum_{k=1}^K \bar{d}_k} + \frac{s_2}{\bar{d}_2} \frac{\bar{d}_2}{\sum_{k=1}^K \bar{d}_k} + \dots + \frac{s_K}{\bar{d}_K} \frac{\bar{d}_K}{\sum_{k=1}^K \bar{d}_k} \\ &= \frac{s_1}{\sum_{k=1}^K \bar{d}_k} + \frac{s_2}{\sum_{k=1}^K \bar{d}_k} + \dots + \frac{s_K}{\sum_{k=1}^K \bar{d}_k} \\ &= \frac{s_1 + s_2 + \dots + s_K}{\sum_{k=1}^K \bar{d}_k} \\ &= \frac{\sum_{k=1}^K s_k}{\sum_{k=1}^K \bar{d}_k} \end{aligned}$$

可以發現，公式可以簡化成各聚合群集之需求標準差除以需求平均，這可以簡化



繁複的計算加快速度。意義上來說，Simple-average CV 表示不同群集間各自的影响，單純考慮各群集內部的需求穩不穩定；Weighted-average CV 意涵不希望由

同個網路管理中心控制太多的基本台，如果單純看  $CV_k = \frac{s_k}{\bar{d}_k}$  可能會被  $\bar{d}_k$  所主導，進而造成 RNC 控制的基本台的數量不均的問題。目前問題只探討特定的需求規

劃群集，因此上式的分母  $\sum_{k=1}^K \bar{d}_k$  並不會隨著聚合的結果改變，因此使用 WCV 的效果就會變成單純的看分子  $\sum_{k=1}^K s_k$ ，也就是各群集變異數之總合。

除了各個群集內部的需求變化，本研究也會探究不同群集的無線網路資源上限，提供決策者評估當地網路資源分配情形。

#### 4.1.2 使用者移動相關指標

轉移矩陣之對角線值表示人口停留於原來集群的比例，其值越高代表狀態之間的轉移越少，如前述寫成  $\bar{\mathbf{Q}}$ ， $\text{trace}(\bar{\mathbf{Q}})$  為其對角線之加總。亦從另一個角度來看  $\|\bar{\mathbf{Q}}\|_F$  為非對角線的矩陣長度(距離0矩陣之距離)，其意義為整體區域的移動量，

我們希望區域之間的轉移比例越低越好，根據  $K - \text{trace}(\bar{\mathbf{Q}}) = \sum_{k=1}^K \sum_{l=1}^K Q_{kl}$ ,  $\forall k \neq l$  的關係，兩個目標函式之間明顯是負向關係的，但是  $\|\bar{\mathbf{Q}}\|_F = \sqrt{\sum_{k=1}^K \sum_{l=1}^K |Q_{kl}|^2}$ ，會使得

其增減效果較  $\text{trace}(\bar{\mathbf{Q}})$  來得穩定。考慮  $\|\bar{\mathbf{Q}}\|_F$  是因為其可以比較整體區域的移動性，如下例： $\mathbf{Q}_1 = \begin{bmatrix} 0.2 & 0.8 \\ 0.6 & 0.4 \end{bmatrix}$ ;  $\mathbf{Q}_2 = \begin{bmatrix} 0.1 & 0.9 \\ 0.5 & 0.5 \end{bmatrix}$ ，在  $\text{trace}(\bar{\mathbf{Q}})$  中，兩者是相同的，但是

在  $\|\bar{\mathbf{Q}}\|_F$  中，可以發現  $\mathbf{Q}_2$  的 norm 較  $\mathbf{Q}_1$  還要高，其意味  $\mathbf{Q}_2$  的移動性較高。

綜合上述，本研究以 SCV 與 WCV 描述各集群與總體的需求變化情形；以  $\|\bar{\mathbf{M}}\|_F$  與  $\|\bar{\mathbf{Q}}\|_F$  描述各集群實際的人口轉移與人口轉移比例。

## 4.2 問題建模

根據原本的問題，我們可以建立 2 個模型：



### 第一個目標：最穩定之區域網路需求

$$\min \text{SCV} = \frac{\sum_{k=1}^K \text{CV}_k}{K} \quad \text{or} \quad \min \text{WCV} = \frac{\sum_{k=1}^K s_k}{\sum_{k=1}^K \bar{d}_k}$$

decision variable:  $c_{ik}$

s.t :

$$\max_h \sum_{i=1}^n c_{ih} \cdot d_{ih} \leq D, \quad \forall k = 1, 2, \dots, K \quad (1)$$

$$c_{ik} \cdot c_{jk} \cdot S(loc_i, loc_j) \leq \kappa \cdot c_{ik} \cdot c_{gl} \cdot S(loc_i, loc_g), \\ \forall i, j, g = 1, \dots, I; \quad \forall k, l = 1, \dots, K; \quad (2)$$

$\kappa \in [0, 1]$

$$\sum_{k=1}^m c_{ik} = 1, \quad \forall i = 1, 2, \dots, n \quad (3)$$

前者觀察其整體區域的變異係數，後者為各個區域之變異係數直接加總。

其中(1)為 hard constraint，也就是一定要符合之限制式；(2)為 soft constraint，是盡可能滿足之限制式。因為聚合後的管理中心無法管控太多的網路需求；在地理位置上，也盡量希望同中心下的基地台不要相距太遠，因此，我們設定同群內區域距離要小於  $\kappa$  倍不同群區域的距離。

### 第二個目標：最少化區域間的人口轉移比例

$$\min \|\check{\mathbf{M}}\|_F = \sqrt{\sum_{k=1}^K \sum_{l=1}^K |M_{kl}^2|} \quad \text{or} \quad \min \|\check{\mathbf{Q}}\|_F \sqrt{\sum_{k=1}^K \sum_{l=1}^K |Q_{kl}^2|}$$

前者觀察其轉移次數，後者為轉移矩陣，限制式與前述(1)、(2)、(3)相同。

本研究希望可以達到上述兩個目標，同時也期待 RNC 服務的區域不會相隔太遠(soft constraint)，以及 RNC 的網路需求容量有個上限(hard constraint)。由於目前尚無找到一個可以同時衡量這數種指標的一個基準，現階段的考量是利用不同的方式進行各種不同聚合策略，再依據其聚合的效果，像是不同天的聚合結果，最後一併做評比。

## 4.3 性質探討：surrogate approach

在介紹最佳化方法之前，這節先分析這個問題的一些性質。組合最優化問題

是從有限的解集合中找到 1 個最優解，在這樣的問題中，通常窮舉答案的解法通常是不可行的，以本研究探討的問題為例，我們希望將 49 個區域交由 7 個 RNC 來控管，這樣會有  $10^{30}$  種可能，幾乎是無法窮舉處理，雖然 2 個限制式會減少可行解的區域，但是由於其問題結構沒有特殊的規律性，仍然不太可能考慮到所有的狀況。因此，只能從指標的內容中看出一些端倪，接下來將討論需求數列間的相關係數。

從 CV/WCV 的  $s_k$  中，也可以寫成數學式表示如下：

$$s_k^2 = \text{var}(\sum_{i=1}^I c_{ik} \mathbf{d}_i) = \sum_{i=1}^I \text{var}(c_{ik} \mathbf{d}_i) + \sum_{i=1}^I \sum_{j=1}^I \text{cov}(c_{ik} \mathbf{d}_i, c_{jk} \mathbf{d}_j)$$

從這個地方可以發現，如果 2 需求數列的相關性為負，意即  $\text{cov}(\cdot, \cdot) \leq 0$  或是  $\text{corr}(\cdot, \cdot) \leq 0$ ，就可以降低  $s_k^2$  的數值，利用負相關的性質，可以有效的減少 WCV 的數值。如下圖，加總後之需求數列呈現完全穩定的狀態。

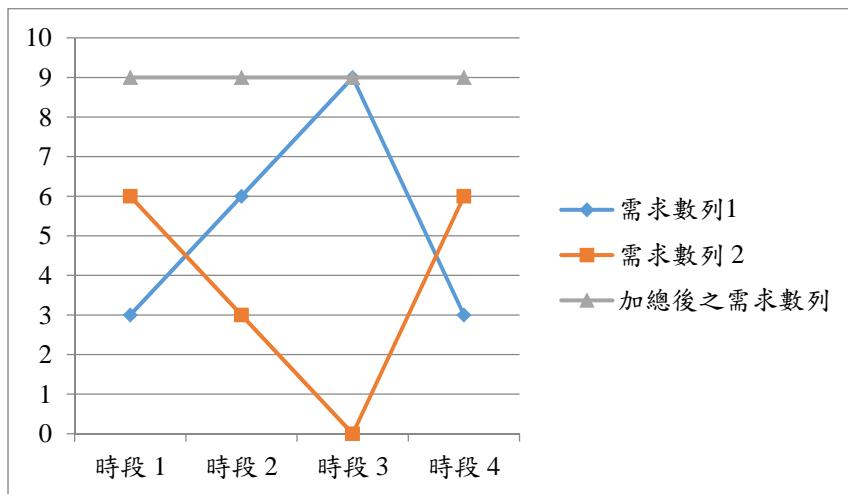


Fig.4-3 : 2 完全負相關需求數列與其聚合後之結果

接著從  $\min \|\check{\mathbf{Q}}\|_F \sqrt{\sum_{k=1}^K \sum_{l=1}^K |Q_{kl}^2|}$  中，由  $Q_{kl} = \frac{M_{kl}}{\sum_l M_{kl}}$  的估計式來觀察，現欲降低

$Q_{kl}^2$ ，將聚合之群集還原成各區域表示：



$$M_{kl} = \sum_{j=1}^I \sum_{i=1}^I c_{ik} \cdot c_{jl} \cdot N_{ij}, Q_{kl} = \frac{\sum_{j=1}^I \sum_{i=1}^I c_{ik} \cdot c_{jl} \cdot N_{ij}}{\sum_{l=1}^K \sum_{j=1}^I \sum_{i=1}^I c_{ik} \cdot c_{jl} \cdot N_{ij}}$$

可以藉由降低分子的方式來達到。

目的，這裡就說明分母與分子的意義：

- 分母： $k$  群集之使用者數量。
- 分子： $k$  群集至  $l$  群集之使用者數量。

如果聚合過程中會選擇高  $N_{ij}$  的區域進行聚合，聚合之後會減少  $N_{ij}$  的轉移次數，同時也使  $k$  群集之網路需求數增幅不要太大，這同時也隱含著同個 RNC 不要控管太多的基地台，除了造成該 RNC 的負擔，也可能使得內部基地台的轉移增加。我們也嘗試直接對高  $N_{ij}$ ，也就是有較高轉移次數的兩個區域進行聚合，觀察其與使用轉移矩陣聚合後的差異。

接下來針對幾種簡單的情形作探討：在不考慮限制式的情況下，

#### Case I. 兩個區域間的聚合分析：

假設現在只有 2 個區域的情況下，探討是否聚合以達到期望的目的：

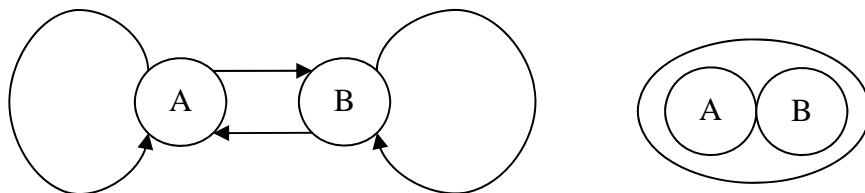


Fig.4-4：兩種區域可能的聚合結果

舉個例子：時段 1、2、3 的轉移人口數

h1h2	A	B	h2h3	A	B	h3h4	A	B
A	10	1	A	12	2	A	10	5
B	9	10	B	8	9	B	15	8

由 3 個時段轉移人口數產生的需求數列：(加總每個時段下的 column 可得)

Demand	h2	h3	h4
A	19	20	25
B	11	11	13

由轉移人口數產生的轉移比例：(加總不同時段間的轉移數，再除以 row 相加)



Probability	A	B
A	0.8	0.2
B	0.542373	0.457627

經過聚合可以發現，(A;B 表示 A 與 B 沒有聚合，A+B 表示聚合)

WCV	A;B	A+B
	0.108105	0.107849

$\ \tilde{\mathbf{Q}}\ _F$	A;B	A+B
	0.578073	0

基本上不論在何種情況，只要符合限制式，A、B 聚合後通常可以下降其需求變異與減少其轉移量。減少轉移量較明顯，而 A、B 聚合後的關係可見下述。

$$WCV_{(A+B)} \leq WCV_{(A;B)}$$

" = " only occur at  $\text{corr}(A, B) = 1$

因此，聚合地區的確可以減少整體變異與區域之間的人口轉移比例。

### Case II. 三個區域間的聚合分析：聚合誰比較好？

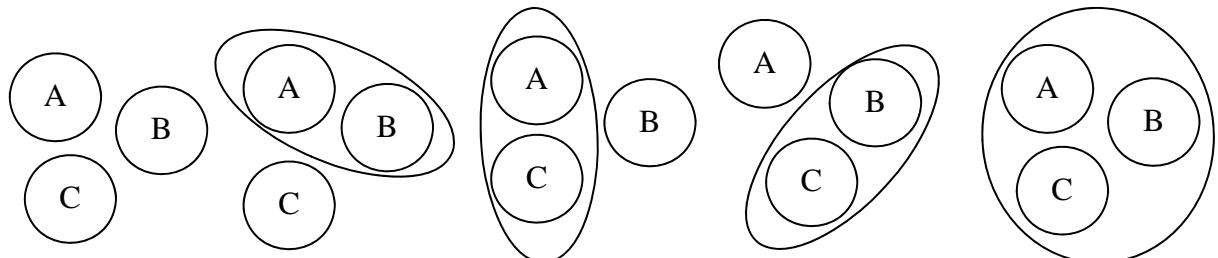


Fig.4-5 : 三種區域可能的聚合結果

由於 A、B、C 之間的需求數列與轉移矩陣可能有非常多種情況，而且因為其之間的關係複雜，直接依照地區之間需求數的 correlation matrix 或是 transition matrix 是無法保證其可以獲得最佳解的，其反例如下：根據轉移次數聚合的反例：

Transition	A	B	C
A	1	9	3
B	3	7	8
C	1	6	8

Probability	A	B	C
A	0.076923	0.692308	0.230769



B	0.166667	0.388889	0.444444
C	0.066667	0.4	0.533333

按此範例，如果依照轉移次數應聚合(B,C)，如果依照轉移矩陣應聚合(A,B)，而結果如下：

$$(B,C) \text{ 聚合} : \|\check{Q}\| = 0.93$$

$$(A,B) \text{ 聚合} : \|\check{Q}\| = 0.58$$

可見依轉移矩陣聚合較恰當。

根據轉移矩陣聚合的反例：

Transition	A	B	C
A	3	2	4
B	16	20	17
C	6	4	10

Probability	A	B	C
A	0.333333	0.222222	0.444444
B	0.301887	0.377358	0.320755
C	0.3	0.2	0.5

按此範例，如果依照轉移次數應聚合(B,C)，如果依照轉移矩陣應聚合(A,C)，而結果如下：

$$(B,C) \text{ 聚合} : \|\check{Q}\| = 0.73$$

$$(A,C) \text{ 聚合} : \|\check{Q}\| = 0.65$$

可見依轉移次數聚合較恰當。

由於此種特性，我們無法確定聚合後的一定為最優解，這也是此種 surrogate approach 法可能的問題，後續結果比較中，會比較直接對目標函式的組合以及依據 correlation matrix 與 transition matrix (surrogate)的異同。聚合轉移次數的方式，請參考 Appendix 1.。

#### 4.4 資源分配策略規劃方法

本節將介紹四種不同的規劃求解方法，配合問題的條件以及剛剛推演的性質建立適當的演算法去解決優化問題。本研究發展 4 個演算法來建立需求規劃策略：

貪婪式規劃方法、階層式規劃方法、K 區域規劃方法與基因演算規劃方法。

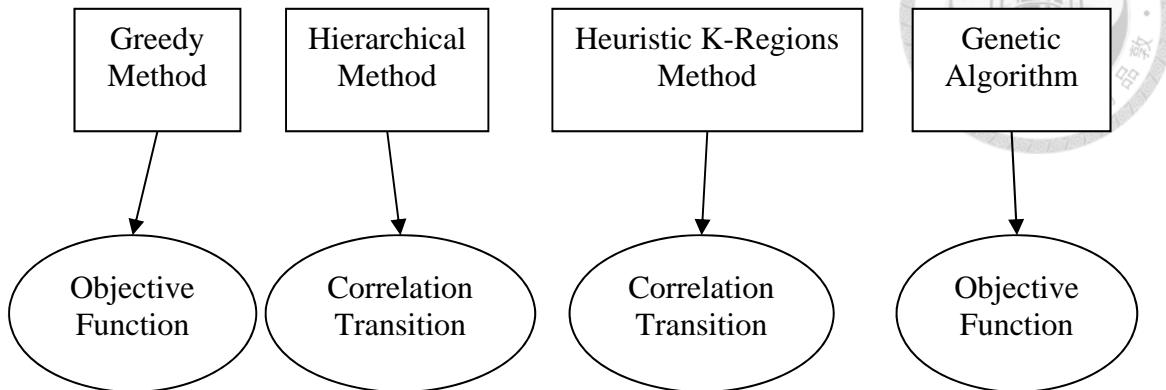


Fig.4-6：規劃方法

上述為四種方法與目標函數(Objective function)、聚集選項(correlation matrix or transition matrix、transition count)的關係，貪婪式與基因演算規劃方法是直接針對目標函數進行優化的策略，階層式與 K 區域法是針對地區之間需求的 correlation matrix 與 transition matrix 進行聚合，兩種方式的概念不完全相同。

不過四種方法基本上都符合下圖結構：

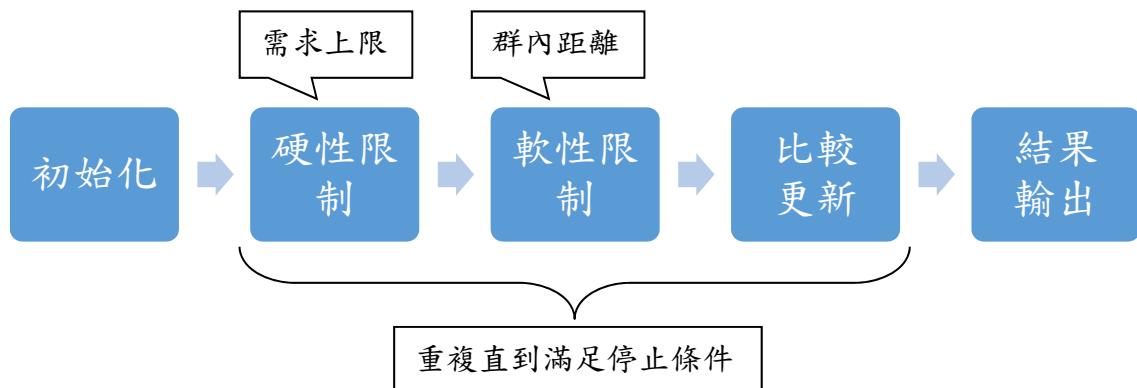


Fig.4-7：規劃方法流程圖

因為本研究探討的問題要考量到網路容量上限與不希望服務的範圍會差太多，因此在聚合的過程中皆會考量這 2 種限制因素。

#### 4.4.1 貪婪式規劃方法

貪婪式規劃方法為直接對目標函數進行聚合，將現有的群集兩兩進行聚合後，觀察哪 2 個聚合群集的聚合結果可以最貼近目標值的趨勢，直到聚合至所需的聚



合群集數。本研究撰寫的演算法如下：

### 演算概念

Input :

- 原始資料：Macro data、Micro data、Location centroid
- 參數：聚合群集個數( $k$ )、需求上限、群內距離限制( $\kappa\%$ )、群集距離種類、目標函數

Repeat :

- 1 將目前的聚合群集兩兩進行聚合
- 2 比較 1.之結果，將最符合目標趨勢的 2 個聚合群集進行聚合，聚合過程中須滿足最大需求上限，優先選擇 Location centroid 較近的前  $\kappa\%$  對組合
- 3 重複 1.-2.直到滿足停止條件：已歸類成  $k$  堆

### 4.4.2 階層式規劃方法

階層式規劃方法為利用剛剛所推演的關係矩陣與轉移矩陣，建立聚合群集之間的距離矩陣  $D(i, j)$ ，並開始將距離最近的聚合群集兩兩聚合，直到聚合至所需的聚合群集數。這種方法又被稱為 bottom-up 的聚合方式，將目前屬性群集的最小單位聚合至上層的單位。本研究撰寫的演算法如下：

### 演算概念

Input :

- 原始資料：Macro data、Micro data、Location centroid
- 參數：聚合群集個數( $k$ )、需求上限、群內距離限制( $\kappa\%$ )、群集距離種類、聚合選項

Initialization :

- 計算距離矩陣，根據不同的群集距離種類。

Repeat :

1. 聚合距離矩陣中最短的 2 個群集為 1 個群集，聚合時必須滿足小於需求上限，優先選擇 Location centroid 較近的前  $\kappa\%$  對組合
2. 重複 1.直到滿足停止條件：已歸類成  $k$  堆



#### 4.4.3 K 區域規劃方法

K 區域規劃方法的概念與 K-means clustering 類似，用 1 個中心點去表示聚合群集，在聚合的過程中主要是依據區域與此中心點的距離，將離中心最近之區域納入區域內，並更新群集的中心點，該方法以單一中心點取代整個聚合中心，減少計算距離時所需的計算量。本研究撰寫的演算法如下：

##### 演算概念

Input :

- 原始資料：Macro data、Micro data、Location centroid
- 參數：聚合群集個數(k)、需求上限、群內距離限制( $\kappa\%$ )、群集距離種類、聚合選項，初始距離下限

Initialization :

- 選取 k 個初始中心：從 WCV 與 Trace of P 中可以瞭解當  $\bar{x}_k$  較大，兩者的目標函數值會隨之下降與上升，因此，前 k 個初始中心我們選擇平均需求較高的前 k 個區域，另外，為了盡量符合 soft constraint，我們將初始位置盡量安排在不同的區域，使得最後的結果可以往外散佈(初始距離下限)。

Repeat :

- 1 從剩餘區域挑選與此 7 群中心最短不相似度的區域進行聚合，聚合後須滿足小於需求上限，優先選擇 Location centroid 較近的前  $\kappa\%$  對組合
- 2 重新計算新的群集中心：找出同群內距離所有區域最近距離之區域，計算方法如下：

$$m_i = r_{i*} = \arg \min \frac{1}{n_i} \sum_{r_i, r_{i'} \in i} \text{dissimilarity}(r_i, r_{i'})$$

其中  $\text{dissimilarity}(r_i, r_{i'})$  為相同群集內  $i$  內，兩個區域  $(r_i, r_{i'})$  的不相似度，不相似度可以有 correlation matrix 或是 transition probability 兩種。

- 3 重複 1.-2. 直到滿足停止條件：所有區域皆已分配至 k 群



#### 4.4.4 基因演算法規劃方法

基因演算法的概念是將可行解轉換成數個染色體，這些染色體組成一個世代，世代會隨著每次迭代進行擇優演化、交配與突變而產生新的世代，每次迭代都會儲存暫時最優解，經過數次迭代後，最後將找到的最優解輸出。本研究撰寫之演算法如下：

##### 演算概念

Input :

- 原始資料：Macro data、Micro data、Location centroid
- 參數：聚合群集個數( $k$ )、需求上限、群內距離限制( $\kappa\%$ )、母體數、擇優率、交配率、突變率、迭代上限、收斂條件、目標函數

Initialization :

- 將所有區域編號成  $1 \sim k$  而成 1 個染色體，該染色體必須滿足小於需求上限，群集間的距離大於距離下限。重複製造染色體直到抵達母體數。

Repeat :

- 1 評估：計算目前母體內所有染色體的目標值
- 2 挑選：根據染色體目標值的大小，越接近目標的挑選機率就越大。本研究以輪盤抽取法實作挑選程序
- 3 交配：將 1 對染色體從母體取出，交換染色體其中幾個解，過程須滿足小於需求上限，重複交配個數直到滿足交配率。
- 4 突變：將 1 個染色體從母體取出，改變染色體中其中幾個解，過程須滿足小於需求上限，重複突變直到滿足突變率。
- 5 將解依照其群集內的離 location centroid 的平均距離排序，挑選前  $\kappa\%$  的解為下一個世代的母體。
- 6 重複 1-5.直到滿足中止條件：到達迭代上限 or 滿足收斂條件

結果評估可以與 7 個 RNC 所計算出來的指標比較，來觀察我們的規劃策略是否有改進，以及比較各種規劃方式。



## Chapter 5 實際資料分析

本章節對實際資料進行分析，接下來的小節依序為：資料分析與轉移矩陣模型的建立，RNC 之需求規劃分析與規劃策略結果比較。

### 5.1 資料分析與轉移矩陣模型

本節觀察原始資料，並將原始的資料轉換成需求資訊，最後估計出區域之間的轉移矩陣模型。

根據資料立方體，我們可以快速的查詢的 24 小時下，不同區域，所有類型總合的網路需求，以之前定義系統表達為如下圖：

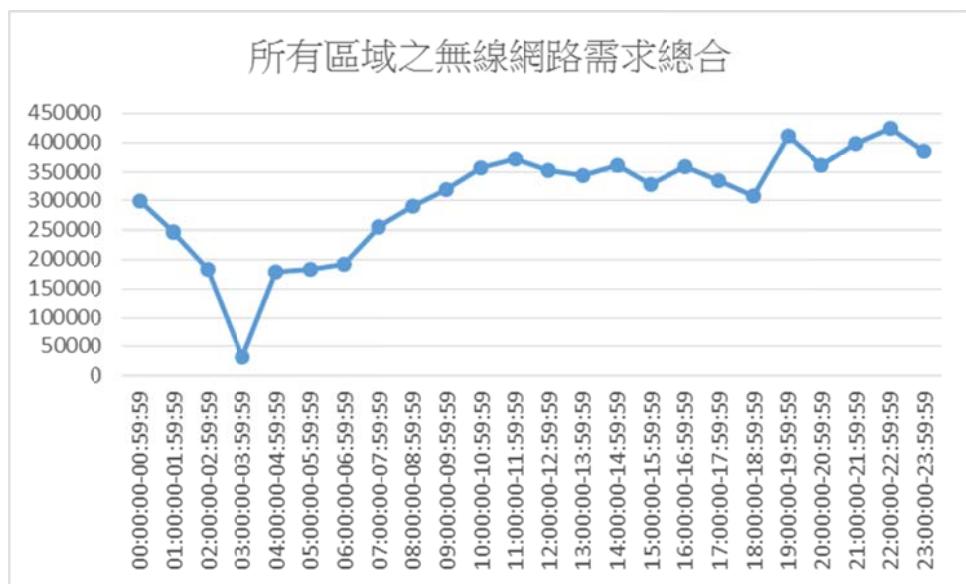


Fig.5-1 : Macro data 之需求數列

將需求拆解 49 個區域而 24 小時下：

不同區域的人口分佈情形如 Appendix2.：可以發現其人口密度隨著時間的變化在各地區的情形略有不同，由圖可以推測，可能是住宅區部分可以由 04:00~06:00 的綠色區塊推敲而得，而商業區的部分應該是在 13:00~15:00 的紅色區塊，08:00~10:00 應該是上班的通勤時間，15:00 之後漸漸有下班的人潮出現。

下圖為當地使用者一天下來，所經過的區域與轉移比例。會發現接近 5 成的人一天下來只停留在 1 個區域，這樣的人也不會有移動，造成這樣的結果有可能是因為區域的範圍較大而導致，如果想看更細緻的移動情形，就需要將區域的範圍再縮小。

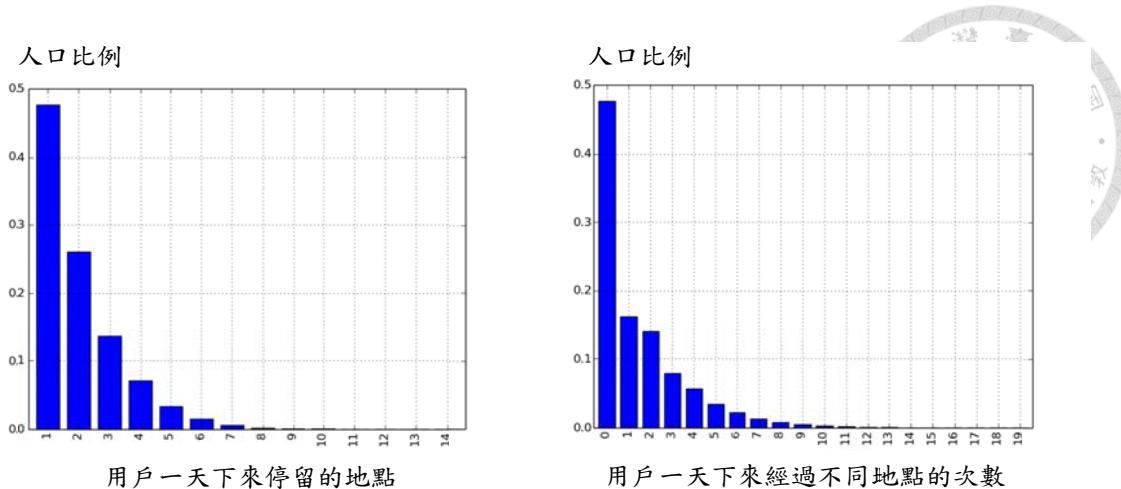


Fig.5-2：使用者移動情形(a)使用者停留的地點數(b)使用者轉移的的點數

圖中橫軸為人口所經過的地點(a)以及不同地區轉移數(b)，縱軸為人口比例。

**轉移矩陣估計：**由於現在規劃的日程以一天為基準，根據公式可以得到一天下來的轉移矩陣，其熱形圖(heat map)如下圖所示：這個圖形闡釋區域之間一整天下來人口流動的情形，可以發現機率較高的通常都是鄰近的區域，也就是轉移矩陣中靠近對角線的部分，還有像是下圖 Fig.5-3 轉移矩陣熱圖，紅色圈起來的區域轉移，可以對應到下圖 Fig.5-3 人口分布圖的黑色圈中，這個地區推測是頻繁的商業區，也是通勤族往來的地方。

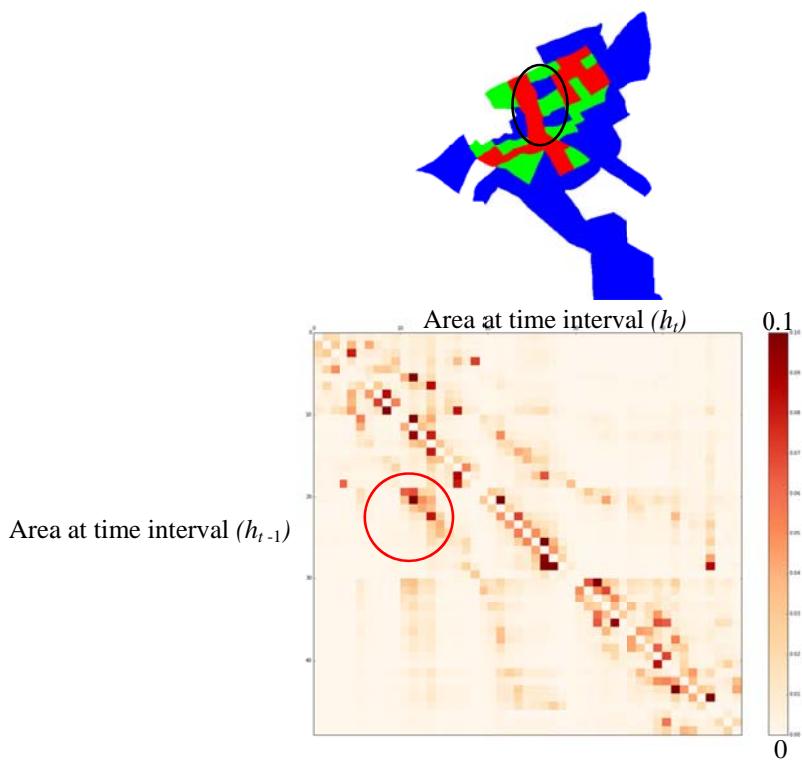


Fig.5-3：人口分布圖與轉移矩陣熱圖



圖代表的是非對角線之轉移矩陣，從縱軸( $h_{t-1}$ )至橫軸( $h_t$ )表現 49 個地區的人口轉移比例，其最高的機率值，也就是圖中紅色區域為 0.1。

另外，我們也從 Micro data 利用第 3 章所述的方法生成 Macro data，並繪製其 23 小時下的人口變化：



Micro data 生成的 Macro data 之需求數列

可以發現其與 Macro data 有些微的不同，這可能會影響我們需求規劃的結果，因此兩種 data 都會納入本研究分析。

## 5.2 RNC 之需求規劃分析

本節開始進行 RNC 的需求規劃分析，哪些 RNC 應該控制哪些基地台是我們的疑問，經由第 4 章所述的規劃分析方法，進行當地 RNC 的控管計畫，並在下一節提供分析結果，提供決策者做個參考。一開始先介紹原始 RNC 所反映的情形。

原始 RNC 的分析與規劃模型參數設定：原始 RNC 的分佈如下圖：



Fig.5-4 : RNC 分布情形

整體地區由 7 個 RNC 所覆蓋，可以發現 RNC 不一定要完全的相連在一起(圖中的黃色區域)，但是通常同個 RNC 控管的範圍不會差距太遠，RNC 的服務範圍有些需重疊的部分，但在本研究中依照行政區域的劃分是不會有重疊區域的。

7 個 RNC 的網路需求數列如下所示：

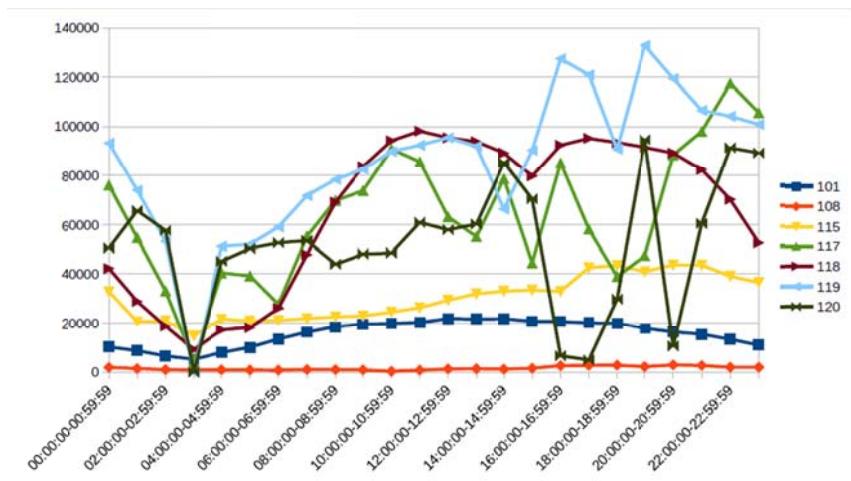


Fig.5-5 : 7 個 RNC 之需求數列

可以發現晚間的需求震盪明顯變大，推測可能是該地區的人晚上較為活躍，可以對應圖，其中 RNC117、120、119 的需求變異明顯比其他地方還要大許多，這代表 RNC 可能可以有更好的管理方式去控制基地台。另外，由於每個 RNC 應該有其控管容量的限制，這裡我們取目前的最大需求：132821(Macro data)與



73181(Micro data 估計之 Macro data)作為之後的模型輸入時，「需求上限」參數。另外，也計算 RNC 之間的轉移矩陣如下圖：

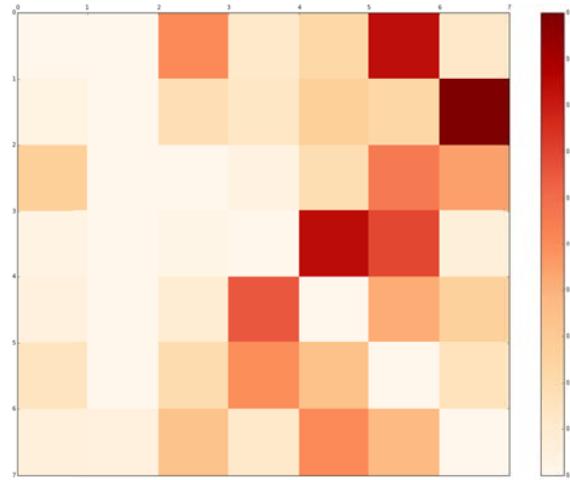


Fig.5-6：7 個 RNC 之轉移矩陣

可以發現 RNC108 到 RNC120 的轉移數是最高的，對應回原圖也是合理的，因為兩個 RNC 覆蓋的範圍幾乎重疊在一起。因此相信有更好的方式將該地區進行合併或解析。

規劃方法與結果：第 4 章提及不少需求規劃方法，先針對共同的參數進行設定，如下列：

- Macro data：同 3.1 所述，為 24 小時下的各個地區的需求數列
- Micro data：同 3.2 所述，為 24 小時下有橫越 2 時段之各個地區的人口轉移量。
- Location centroid：地區中心，地區中心的算法是依照一整天下來，將所有使用者在該地區使用網路的位置進行平均，而得到的需求密度中心，計算方法如下：

$$\text{Loc}_i = (x_i, y_i) = \frac{\sum_u^U (x_{iu}, y_{iu})}{U}$$

$(x_{iu}, y_{iu})$  表示某位使用者  $u$  在  $i$  區域內的經緯度座標與基地台連線， $U$  表示該區域一天下來的總人口數。

- 群內距離限制( $\kappa\%$ )：目前以  $\kappa=25\%$  為群內距離的軟性限制，此值表示聚合過程會優先挑選區域中心較近的前  $\kappa=25\%$  距離進行聚合。



各種規劃方法的參數設定如下：

- 貪婪式規劃方法

- 目標函數：SCV、WCV 與  $\|\bar{\mathbf{Q}}\|_F$  、 $\|\bar{\mathbf{M}}\|_F$

- 階層式規劃方法

- 群集距離種類：以完整連結法當作群集與群集間的距離

原因：研究做了些嘗試：比較使用三種不同連結法在 correlation matrix 的效果，如下圖：可以發現，完整連結法較有明確的不相似度變化，因此以此種方法當作群集之間的距離。

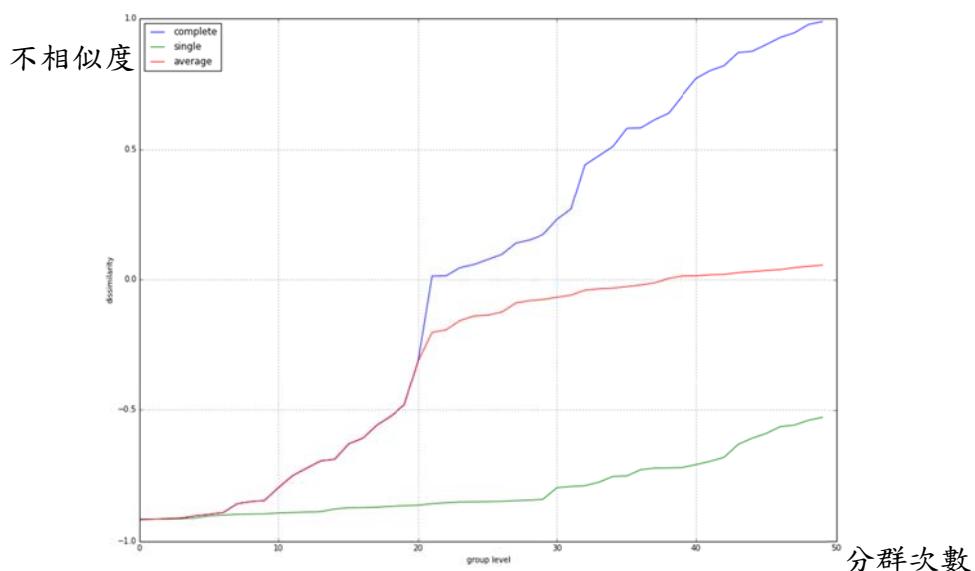


Fig.5-7：三種 linkage 的結果比較

上圖橫軸為分群的次數，也就是目前已將多少對群集聚合，縱軸為分群時比較的最小不相似度。

- 聚合選項：correlation matrix、transition probability

- K 區域規劃方法

- 初始距離下限： $\geq 5$  (km)

- 聚合選項：correlation matrix、transition probability

- 基因演算規劃方法

- 目標函數：SCV、WCV 與  $\|\bar{\mathbf{Q}}\|_F$  、 $\|\bar{\mathbf{M}}\|_F$

- 母體數：40 個



- 交配率：47.5%：相當於每次交配產出 19 個染色體
- 突變率：2.5%：相當於每次突變產出 1 個染色體
- 迭代上限：50 次，由於計算效率不佳，暫時以 50 次為上限。
- 收斂條件：0.00001，目標函數進步差距小於此數值即停止。
- 目標函數：Weighted-average CV、 $\|\bar{\mathbf{Q}}\|_F$

這樣就完全設定好模型所需的參數，下一節為結果比較。

### 5.3 規劃策略結果比較

本節安排依序為：macro data 與 micro data 生成之 macro data 兩種資料個別的需求規劃方法之結果比較，不同規劃策略在 day 4 的效果，以及與原始 RNC 之比較。

#### 需求規劃方法之結果比較

將規劃策略結果繪製於地圖上，各群集之無線網路需求數列，各區域間的轉移矩陣熱形圖。由這三張圖可以評比需求規劃策略帶來的影響為何，也可以對應回原來的使用者移動與使用網路的情形。

##### Input: macro data and micro data

- 貪婪式規劃方法：目標函數為 Weighted-average CV
- 貪婪式規劃方法：目標函數為 Simple-average CV
- 貪婪式規劃方法：目標函數為  $\|\bar{\mathbf{Q}}\|_F$
- 貪婪式規劃方法：目標函數為  $\|\bar{\mathbf{M}}\|_F$
- 階層式規劃方法：聚合選項為 correlation matrix
- 階層式規劃方法：聚合選項為 transition matrix
- 階層式規劃方法：聚合選項為 transition count
- K 區域規劃方法：聚合選項為 correlation matrix
- K 區域規劃方法：聚合選項為 transition matrix
- K 區域規劃方法：聚合選項為 transition count
- 基因演算規劃方法：目標函數為 Weighted-average CV
- 基因演算規劃方法：目標函數為 Simple-average CV



- 基因演算規劃方法：目標函數為  $\|\check{\mathbf{Q}}\|_F$

基因演算規劃方法：目標函數為  $\|\check{\mathbf{M}}\|_F$

詳細圖表見 Appendix 3.

Input: micro generated macro data and micro data

- 貪婪式規劃方法：目標函數為 Weighted-average CV
- 貪婪式規劃方法：目標函數為 Simple-average CV
- 貪婪式規劃方法：目標函數為  $\|\check{\mathbf{Q}}\|_F$
- 貪婪式規劃方法：目標函數為  $\|\check{\mathbf{M}}\|_F$
- 階層式規劃方法：聚合選項為 correlation matrix
- 階層式規劃方法：聚合選項為 transition matrix
- 階層式規劃方法：聚合選項為 transition count
- K 區域規劃方法：聚合選項為 correlation matrix
- K 區域規劃方法：聚合選項為 transition matrix
- K 區域規劃方法：聚合選項為 transition count
- 基因演算規劃方法：目標函數為 Weighted-average CV
- 基因演算規劃方法：目標函數為 Simple-average CV
- 基因演算規劃方法：目標函數為  $\|\check{\mathbf{Q}}\|_F$
- 基因演算規劃方法：目標函數為  $\|\check{\mathbf{M}}\|_F$

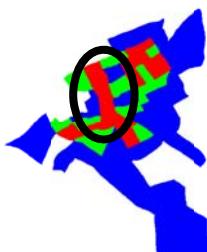
詳細圖表見 Appendix 4.，從 Appendix 3.、Appendix 4. 中觀察到的現象：

- 從需求數列圖貪婪法會將高需求的群集與低需求的群集分隔開來，根據其演算法的特性，推測可能是聚合過程中，每次聚集都是大群集將小群集聚合而來。
- 階層式規劃法中，聚合選項為 correlation matrix 時，需求數列較為集中，因此最後的網路容量上限較為平均，但是地圖上 RNC 服務範圍有些破碎，使得其轉移矩陣的移動量散佈在各個地方。
- K 區域法會很明顯的將區域依地理位置劃分成數個區塊，這應該是因為



初始的 K 個區域中心散布於不同的位置而導致。

- 基因演算規劃方法在地圖上配置的結果最為破碎，WCV 與 SCV 可以有效的降低需求變異，但會造成轉移的效果提高； $\|\bar{\mathbf{Q}}\|_F$  與  $\|\bar{\mathbf{M}}\|_F$  呈現的效果卻不明顯，猜想可能是 constraints 的關係使世代交替的效果降低，因此較難得到更好的解。
- 對應回原來的人口分佈圖，可以發現下圖黑色圈起來的區域為人口集中的中心：



除了是網路需求的高密度區域外，也同時是人口轉移的集中區域，未來可針對此區做更細部的資料分析，利用本研究之方法進行 small cells 的配置規劃。



結果比較表：比較目標值(WCV, SCV,  $\|\check{\mathbf{Q}}\|_F$ ,  $\|\check{\mathbf{M}}\|_F$ )、各集群之需求(資源)上限的變化程度：

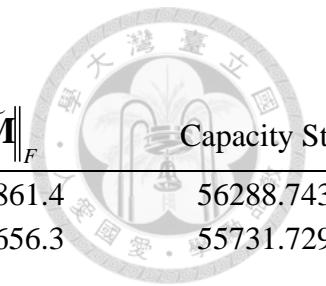
Input: macro data and micro data

		目標函數、聚合選項選擇	WCV	SCV	$\ \check{\mathbf{Q}}\ _F$	$\ \check{\mathbf{M}}\ _F$	Capacity	StDev
Greedy	WCV		0.32696762	0.312158396	0.310704539	190870.7027	54521.14229	
	SCV		0.3330435	0.301943066	0.282434878	198307.1505	59728.28705	
	$\ \check{\mathbf{Q}}\ _F$		0.35164881	0.324178887	0.236949394	147271.3534	43702.05401	
	$\ \check{\mathbf{M}}\ _F$		0.3488864	0.333879499	0.255718886	121842.3505	52284.5876	
Hierarchical	correlation matrix		0.33407133	0.331342967	0.283404349	139931.4468	8988.532091	
	transition matrix		0.37037002	0.347970326	0.201833876	109728.7552	58180.72978	
	transition count		0.36520527	0.347756573	0.290029387	111374.9402	61491.47656	
K-region	correlation matrix		0.34225942	0.33141316	0.24139964	151563.6844	44787.55164	
	transition matrix		0.35049293	0.346474576	0.232596522	130952.9089	42879.70832	
	transition count		0.34969333	0.340720342	0.231595575	128367.9983	35690.45189	
GA	WCV	0.31889433		0.315391747	0.336074766	176432.7784	36451.27228	
	SCV	0.32460012		0.314089997	0.30033133	159273.5683	24684.17512	
	$\ \check{\mathbf{Q}}\ _F$		0.32509976	0.320274349	0.285858937	150057.5224	20807.97823	
	$\ \check{\mathbf{M}}\ _F$		0.32988054	0.328777816	0.285524981	140426.7394	15130.80386	

Table 6 : 不同規劃策略在 macro data 與 micro data 之結果比較

根據上圖可以發現基因演算規劃法對降低需求變異的效果最好(紅字，黃色網底)，其次為貪婪法(黑字，粗體)；階層式規劃法中，聚合選項為轉移矩陣或轉移次數可以有效的降低地區之間的人口轉移，其次是 K 區域法中的轉移矩陣；針對各個地區的網路需求資源上限(network capacity)，可以發現階層式規劃法中，聚合選項為 correlation matrix 的是最穩定的，呼應前述。

Input: micro generated macro data and micro data



	目標函數、聚合選項選擇	WCV	SCV	$\ \check{\mathbf{Q}}\ _F$	$\ \check{\mathbf{M}}\ _F$	Capacity StDev
Greedy	WCV	0.332922676	0.320408423	0.452458514	158861.4	56288.74327
	SCV	0.3334677	0.296457227	0.304644388	207656.3	55731.72917
	$\ \check{\mathbf{Q}}\ _F$	0.35164881	0.324178887	0.236949394	147271.4	43702.05401
	$\ \check{\mathbf{M}}\ _F$	0.350277218	0.329107129	0.244466123	123605.4	49088.01959
Hierarchical	correlation matrix	0.346013923	0.33005612	0.297034835	182594.3	40494.0691
	transition matrix	0.368631054	0.346702734	0.205267679	119537.1	52518.58426
	transition count	0.350359695	0.362325929	0.291957594	124656.6	59523.38827
K-region	correlation matrix	0.34639755	0.340377863	0.237811059	140341.4	40673.59028
	transition matrix	0.350335064	0.346269387	0.237038035	136549.2	41189.86126
	transition count	0.344183731	0.336012251	0.237722333	137259	41476.66052
GA	WCV	0.319426425	0.320909917	0.29586329	145444.9	20179.14819
	SCV	0.323138351	0.318281836	0.292692681	153737.5	26034.33514
	$\ \check{\mathbf{Q}}\ _F$	0.326930378	0.320141879	0.286010115	136229.4	17780.38311
	$\ \check{\mathbf{M}}\ _F$	0.32432923	0.325108709	0.2957122	136866.1	15408.44769

Table 7 : 不同規劃策略在 micro data 估計之 macro data 與 micro data 之結果比較

可以發現：除了 WCV 之外皆略有改變，不過通常最優(紅字，黃色網底)是沒有改變的，比較不穩定的參數為網路需求資源上限(藍色，斜體，綠色網底)，階層式規劃方法，聚合選項為 correlation matrix 在隔天的表現並不如之前那麼好，反而基因演算規劃方法有較穩定的表現。

結果比較表：程式運行速度比較

	目標函數、聚合選項選擇	Process Time(s)
Greedy	WCV	12.935
	SCV	11.804
	$\ \bar{\mathbf{Q}}\ _F$	87.413
	$\ \bar{\mathbf{M}}\ _F$	83.207
Hierarchical	correlation matrix	30.984
	transition matrix	36.613
	transition count	40.356
K-region	<b>correlation matrix</b>	<b>7.317</b>
	transition matrix	8.415
	<b>transition count</b>	<b>7.217</b>
GA	WCV	136.576
	SCV	112.448
	$\ \bar{\mathbf{Q}}\ _F$	116.982
	$\ \bar{\mathbf{M}}\ _F$	132.515

Table 8 : 不同規劃策略之程式運行速度

這裡不同方式在 2 種輸入資料的速度也差不多，因此不特別做比較。可以發現 K 區域法的速度明顯較快，因為其計算主要發生於更新中心區域的時候，剩下的聚合過程較貪婪法、階層式規劃方法較少，基因演算規劃方法較慢的原因是因為每次過程中，都需要讀取原始資料並重複計算聚合後的目標值。



## 不同規劃策略在 day 4 的效果

結果比較表：

Input: macro data and micro data



		WCV	SCV	$\ \check{\mathbf{Q}}\ _F$
Greedy	WCV	0.267447697	0.248592	0.311763695
	SCV	0.272975953	<b>0.236685</b>	0.2821788
	$\ \check{\mathbf{Q}}\ _F$	0.285270581	0.267631	0.237943707
	$\ \check{\mathbf{M}}\ _F$	0.283072337	0.284057	0.260545404
Hierarchical	correlation matrix	0.278615495	0.256679	0.309769058
	transition matrix	0.304277431	0.27533	<b>0.190885925</b>
	transition count	0.299979855	0.283625	0.275310548
K-region	correlation matrix	0.285409942	0.275015	0.239636157
	transition matrix	0.2921072	0.285488	0.233469363
	transition count	0.295405088	0.292218	<b>0.231864999</b>
GA	WCV	<b>0.2604309</b>	0.251993	0.327638524
	SCV	<b>0.266278552</b>	0.253102	0.29782704
	$\ \check{\mathbf{Q}}\ _F$	0.26928978	0.263075	0.284220289
	$\ \check{\mathbf{M}}\ _F$	0.270053126	0.271509	0.285296454

Table 9 : Day 4 , macro data 與 micro data 之結果比較

可以發現隨著時間的改變，結果的變化比對表 Table 6 差異並不大



## 與原始 RNC 之比較

原始 RNC 之目標值：

- WCV : 0.41267238
- SCV : 0.414566221
- $\|\check{\mathbf{Q}}\|_F$  : **0.26362992724**
- $\|\check{\mathbf{M}}\|_F$  : **131304.4009**
- Capacity standard deviation : 50086.6136

比對表 Table 6，可以發現多數針對 CV 使用的演算法，可能會使得原本的轉移次數變得更高，因此，在做優化的部分，本研究建議還是以 transition matrix or transition count 為主。但是如果想要同時使 CV 下降的話，建議可以依據 K 區域法的方式聚合選項 correlation matrix、transition matrix 與 transition count 的規劃方法決定規劃策略。

		WCV	SCV	$\ \check{\mathbf{Q}}\ _F$	$\ \check{\mathbf{M}}\ _F$
RNC		0.41267238	0.414566221	<b>0.26362992724</b>	<b>131304.4009</b>
Greedy	WCV	0.32696762	<b>0.312158</b>	<b>0.310704539</b>	<b>190870.7</b>
	SCV	0.3330435	<b>0.301943</b>	<b>0.282434878</b>	<b>198307.2</b>
	$\ \check{\mathbf{Q}}\ _F$	0.35164881	0.324179	0.236949394	<b>147271.4</b>
	$\ \check{\mathbf{M}}\ _F$	0.3488864	0.333879	0.255718886	121842.4
Hierarchical	correlation matrix	0.33407133	0.331343	<b>0.283404349</b>	<b>139931.4</b>
	transition matrix	0.37037002	0.34797	<b>0.201833876</b>	109728.8
	transition count	0.36520527	0.347757	0.290029387	111374.9
K-region	correlation matrix	0.34225942	0.331413	0.24139964	151563.7
	transition matrix	0.35049293	0.346475	0.232596522	130952.9



	transition count	0.34969333	0.34072	<b>0.231595575</b>	128368
GA	WCV	<b>0.31889433</b>	0.315392	<b>0.336074766</b>	<b>176432.8</b>
	SCV	<b>0.32460012</b>	0.31409	<b>0.30033133</b>	<b>159273.6</b>
	$\ \check{\mathbf{Q}}\ _F$	0.32509976	0.320274	<b>0.285858937</b>	<b>150057.5</b>
	$\ \check{\mathbf{M}}\ _F$	0.32988054	0.328778	<b>0.285524981</b>	<b>140426.7</b>

可以發現原來的 RNC 配置對使用者轉移數率已做一定的優化，對應回上表，貪婪式規劃方法在 WCV、SCV 的表現雖然使得目標函數降低，但卻會提高轉移率；階層式規劃方法選擇 correlation matrix 的方式並不如預期；基因演算規劃方法的表現皆不好；因此本研究建議以 K 區域法轉移矩陣/轉移次數作為規劃的方法。



由上述結果可以知道各種演算法的表現情形：

- 基因演算法降低需求變異的效果最好，但在程式執行速度非常的慢，猜想因為 GA 在解碼計算目標函數值時因為資料的讀取與計算造成運作上的瓶頸。其分群的結果會使 RNC 控管的地區分散四處，基於地理分布的考量，似乎沒有那麼好。
- 貪婪法與階層式方法皆有不錯的效果：針對目標函數 Weighted-average 來說，直接對目標函數的聚合比較會比使用 correlation matrix 還要來的更好；但是在非對角線轉移矩陣的大小上，會發現階層式的 transition probability 明顯好很多。
- K 區域法在效果上相較於前幾種方法沒有那麼佳，但在執行速度上是最快的。與階層式或是贪婪式相比，其只考慮剩餘區域與群集中心的距離，而沒有計算整個距離矩陣，其結果基於初始中心的選擇，也會按照地理位置的分布散開。

相互比較下，各種方法各有優缺，本研究建議使用 K 區域法進行需求規劃策略模型，除了其運算速度外，可以同時的控制 Weighted-average CV 與  $\|P\|_F$  下降，又根據結果繪製出來的群集，其針對地理位置的遠近也有不錯的控制效果，故推薦以此法作為 RNC 控制計畫的一個方法。



## 5.4 無線網路資源分配結果

這裡以 K 區域規劃方法，聚合選項為 transition matrix 為例進行後續的資源分配：

7 個集群之需求資源規劃上限：

群集	需求上限
X12X11X6X20X21X32X31X42	82252
X14X13X15X23X24X22X25X7X16X8X9X10X5	131528
X27X26X29X28X18X17X19X4X3X2X30X1	90297
X40X39X43X35X34X37X33X38	82598
X46X45	21007
X41X48X36X49X44	33066
X47	15969

Table 10 : K 區域規劃方法：transition matrix 之無線網路資源分配

根據圖 Fig.6-10 可以發現人口轉移數高的區域為左上角橙色區塊，其為人口流動的集中區域，而有多數比例的人可能會從藍紫色區域往綠色區域，因此在配置 RNC 管理基地台時，可能要使部分的區域重疊於這些高移動區域的地方。還有紅色區域與藍色區域中，其需求數列呈現一定的相關性，我們亦可以從中觀察這些區域的高峰值，動態的調整網路資源(像是改變 RNC 下基地台的 power 或是方向)。



## Chapter 6 結果討論

### 6.1 結果分析與建議

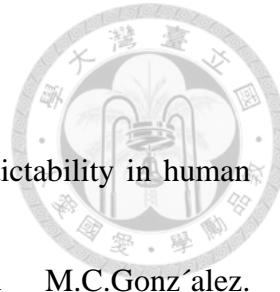
經由不同種規劃方法，本研究提供優化當地無線網路中心的控管方式，這個方式在未來可能可以應用於伺服器的資料存取系統，現在所有的服務幾乎都是在雲端處理，在藉由網路傳輸的方式到每一位穿戴式裝置的使用者上，隨著使用者的量與對網路的需求與日俱增，中間的網路傳輸資料的方式也可能需要改良。本研究的啟發是減少資料在核心網路內的傳遞，並且使得在地基地台可以由無線網路控制中心有效控管，進而得到其網路使用效能。

在規劃方法的建議上，最後是推薦使用 K 區域法做為網路資源規劃的方法，考量其運算速度與可以同時優化目標的能力，雖然不是最好的解，但是仍然可以有效的優化網路的結構。而決策者也可根據其決策需要，特別著重在減少網路之間傳輸量的轉移，或是網路服務有一定的效率這樣，可以依本研究之各項方法略作調整，以達到目的。

### 6.2 未來研究方向

本研究為一個網路規劃方法的雛形，從使用者在一個網路環境的行為，了解整個環境的網路需求變化，本研究對使用者的移動性對需求造成的變化影響較少琢磨，之後的研究建議可以朝向這個方向前進。另外針對網路優化的概念，本研究之方法概念可延伸應用於 small cell 的網路配置當中，像是在一個 hot spot 人群熙來攘往的地區，要如何根據不同型態的資料以及不同的服務需求，甚至是考慮不同細度的時間、空間與網路類型，動態的作網路環境的調整；抑或是應用於 fog computing 的架構建立：使用一個或一個協作多個終端用戶客戶端或接近用戶邊緣設備來進行大量運算、通信而不是連結至核心網路，本研究可以應用於 fog node 在不同區域的配置；最後就是結合 Google loon project 中，動態的去調整網路環境，利用需求規劃方法得到最佳的網路資源配置效果。

## REFERENCE



- [1] C. Song, Z. Qu, N. Blumm, and A. Barabási. Limits of predictability in human mobility. *Science*, 2010.
- [2] C.M.Schneider, V.Belik,T.Couronné, Z.Smoreda, and M.C.González. Unravelling daily human mobility motifs. *Journal of The Royal Society Interface*, 10(84), 2013.
- [3] Wen-Chih Peng and Ming-Syan Chen. Shared Data Allocation in a Mobile Computing System: Exploring Local and Global Optimization. *IEEE Trans. Parallel Distrib. Syst.*, 16(4):374–384, 2005.
- [4] Huang, Y. F., and Lin, K. H. 2008. Global Data Allocation Based on User Behaviors in Mobile Computing Environments. *Computer Communications*. 31, 10 (June 2008), 2420-2427.  
DOI= <http://dx.doi.org/10.1016/j.comcom.2008.03.009>
- [5] Ross, Sheldon M. *Introduction to probability models*. Academic press, 2014.
- [6] Anderson, Theodore W., and Leo A. Goodman. "Statistical inference about Markov chains." *The Annals of Mathematical Statistics* (1957): 89-110.
- [7] Jain, Anil K., and Richard C. Dubes. *Algorithms for clustering data*. Prentice-Hall, Inc., 1988.
- [8] Friedman, Jerome, Trevor Hastie, and Robert Tibshirani. *The elements of statistical learning*. Vol. 1. Springer, Berlin: Springer series in statistics, 2001.
- [9] 鄭怡超，「需求之組合規劃策略研究」，國立台灣大學工業工程學研究所碩士班論文，2001
- [10] Jang, Jyh-Shing Roger, Chuen-Tsai Sun, and Eiji Mizutani. "Neuro-fuzzy and soft computing; a computational approach to learning and machine intelligence." (1997).
- [11] 陳健，「需求規劃層級之定義及最佳化」，國立台灣大學工業工程學研究所碩士班論文，2002



## APPENDIX

### Appendix 1. 轉移次數聚合方法

這裡我們以研究範例說明：

Transition	A	B	C
A	1	9	3
B	3	7	8
C	1	6	8

如果我們現在想要聚合 A、B (A+B)的話，就讀取原始的轉移次數資訊，

1. 將 A、B 之間的所有轉移次數加總而得到(A+B) -> (A+B) : 1+9+3+7
2. 將所有 A、B 轉移至 C 的次數加總而得到(A+B) -> (C) : 3+8
3. 將所有 C 轉移至 A、B 的次數加總而得到 (C)->(A+B) : 1+6
4. 保留原本 C 轉移至 C 的轉移次數得到(C)->(C) : 8

Transition	(A+B)	C
(A+B)	20	11
C	7	8

得到如上表。利用此表可以重新估計轉移矩陣：

Transition	(A+B)	C
(A+B)	$\frac{20}{31}$	$\frac{11}{31}$
C	$\frac{7}{15}$	$\frac{8}{15}$



## Appendix 2. 不同時段下的網路需求分布

這裡描述不同時段下的網路需求分布情形，圖中紅色區域為人口密度(人口數/區域大小( $0.01\text{km}^2$ ))大於 20，綠色區域介於 10 到 20，藍色區域小於 5。其結果如下頁所示：

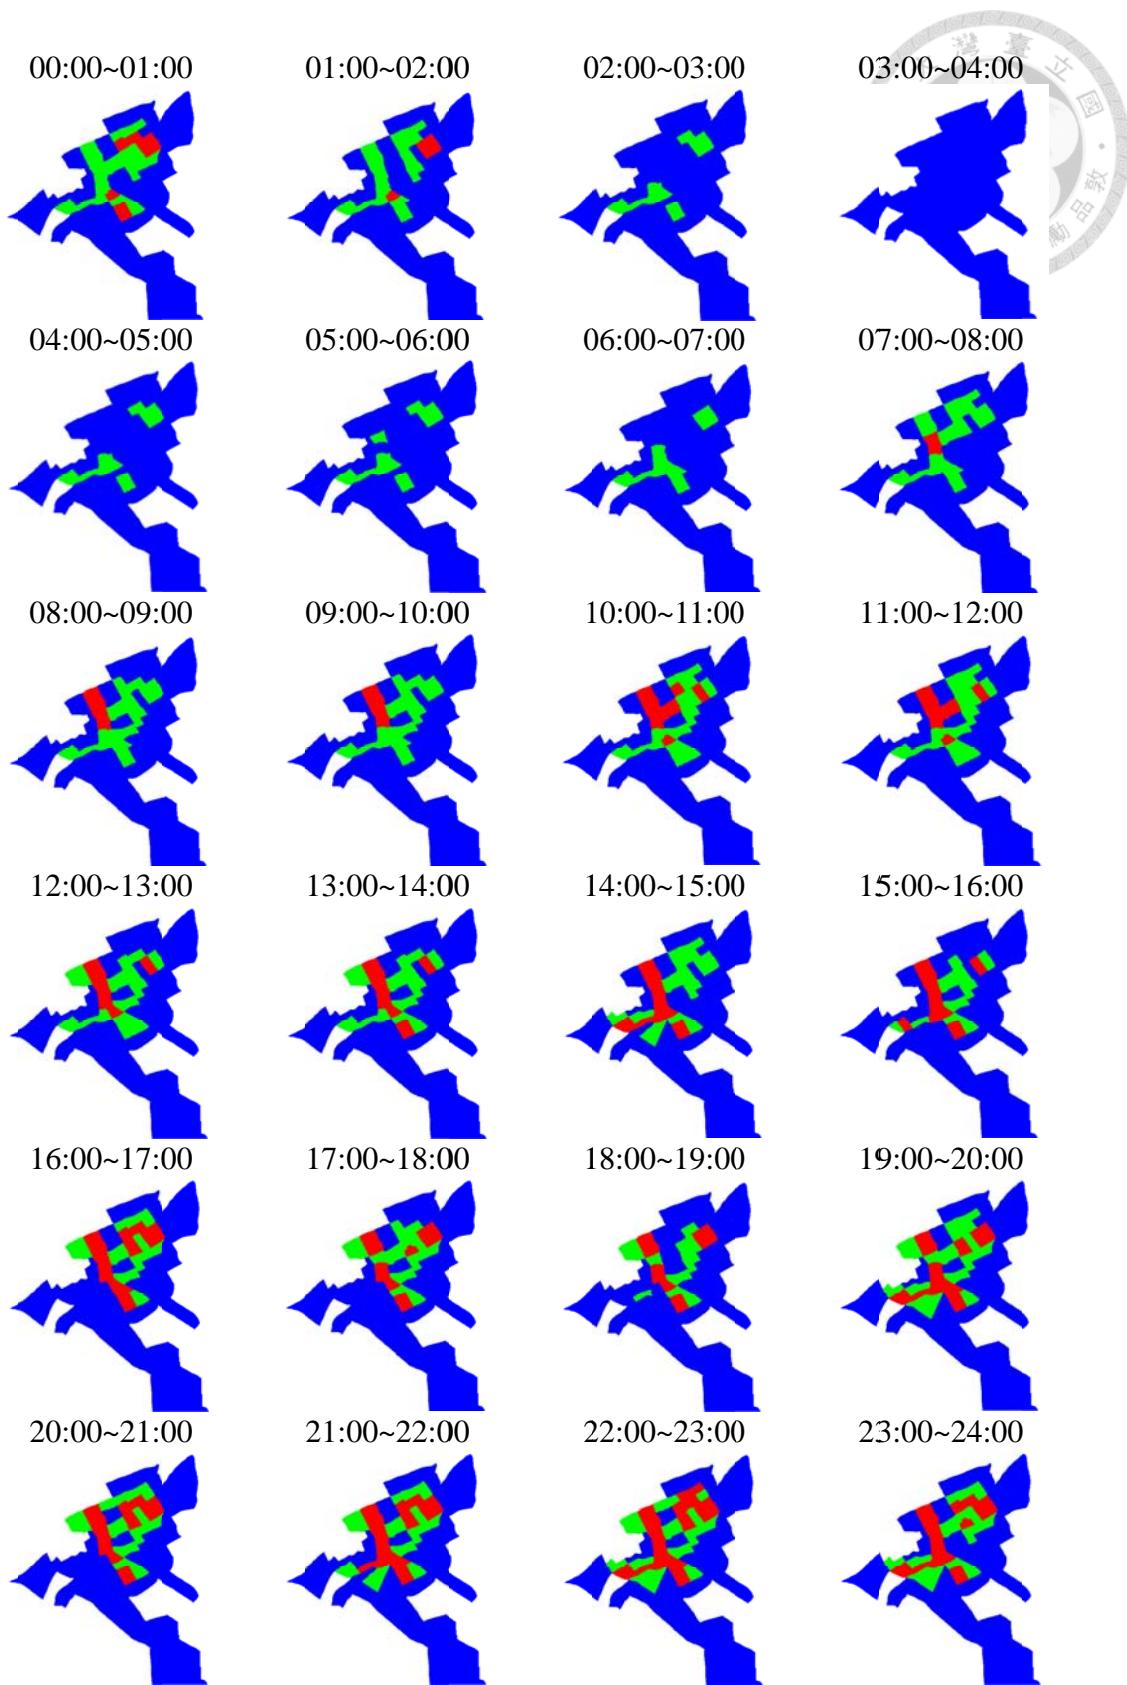


Fig.6-1 : 網路需求分布



### Appendix 3. Macro data and micro data 之規劃策略結果

Input: macro data and micro data

- 貪婪式規劃方法：目標函數為 Weighted-average CV

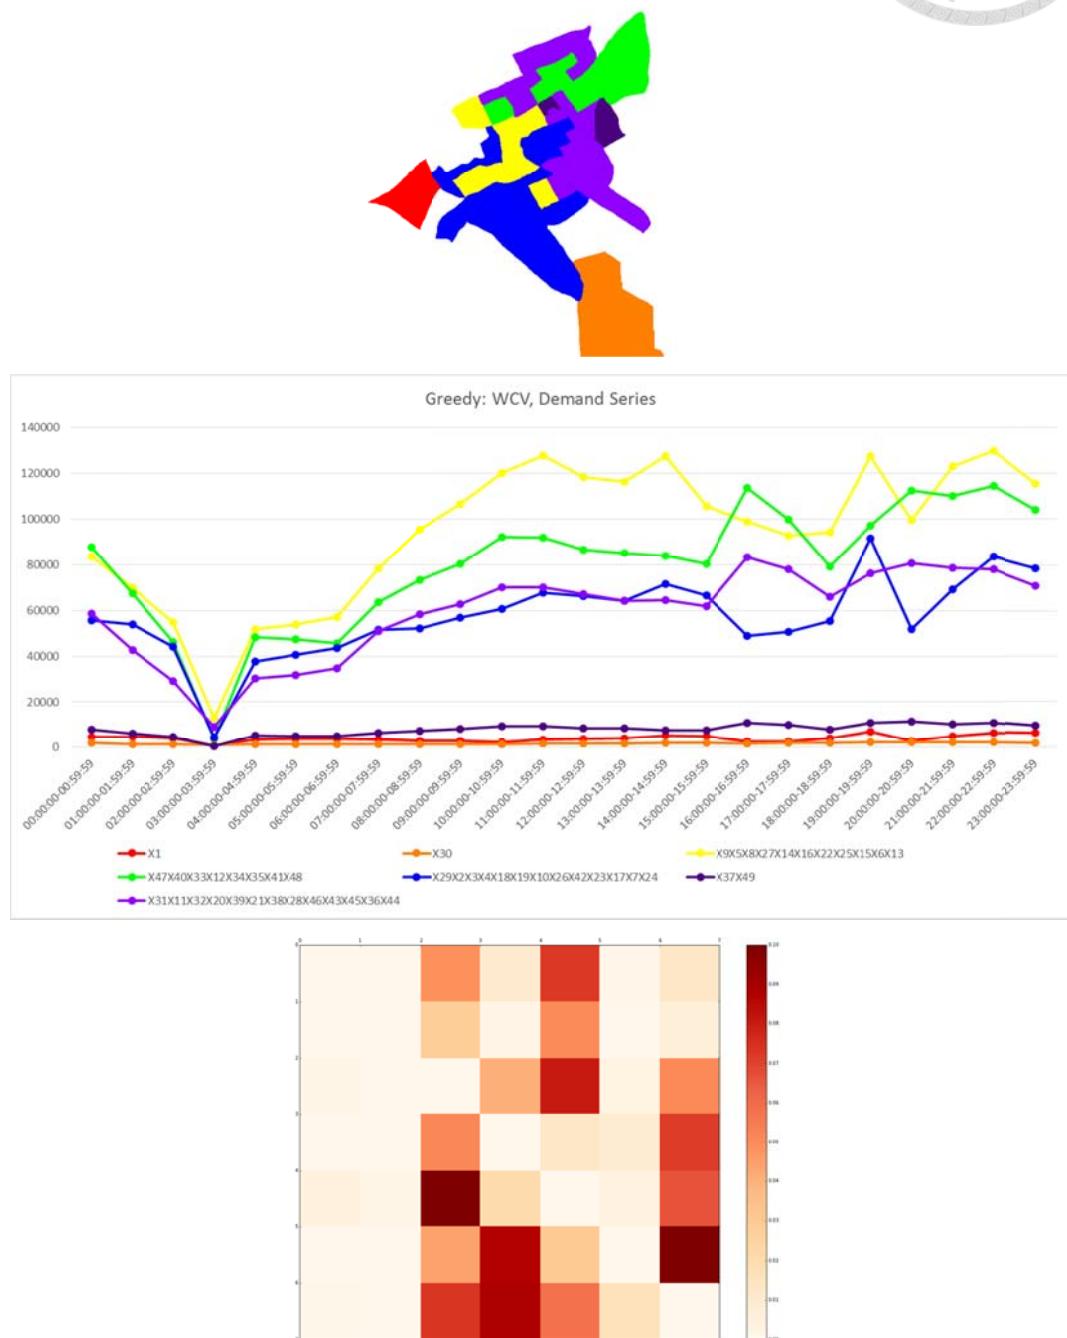


Fig.6-2 : 貪婪式規劃法：WCV

- 貪婪式規劃方法：目標函數為 Simple-average CV

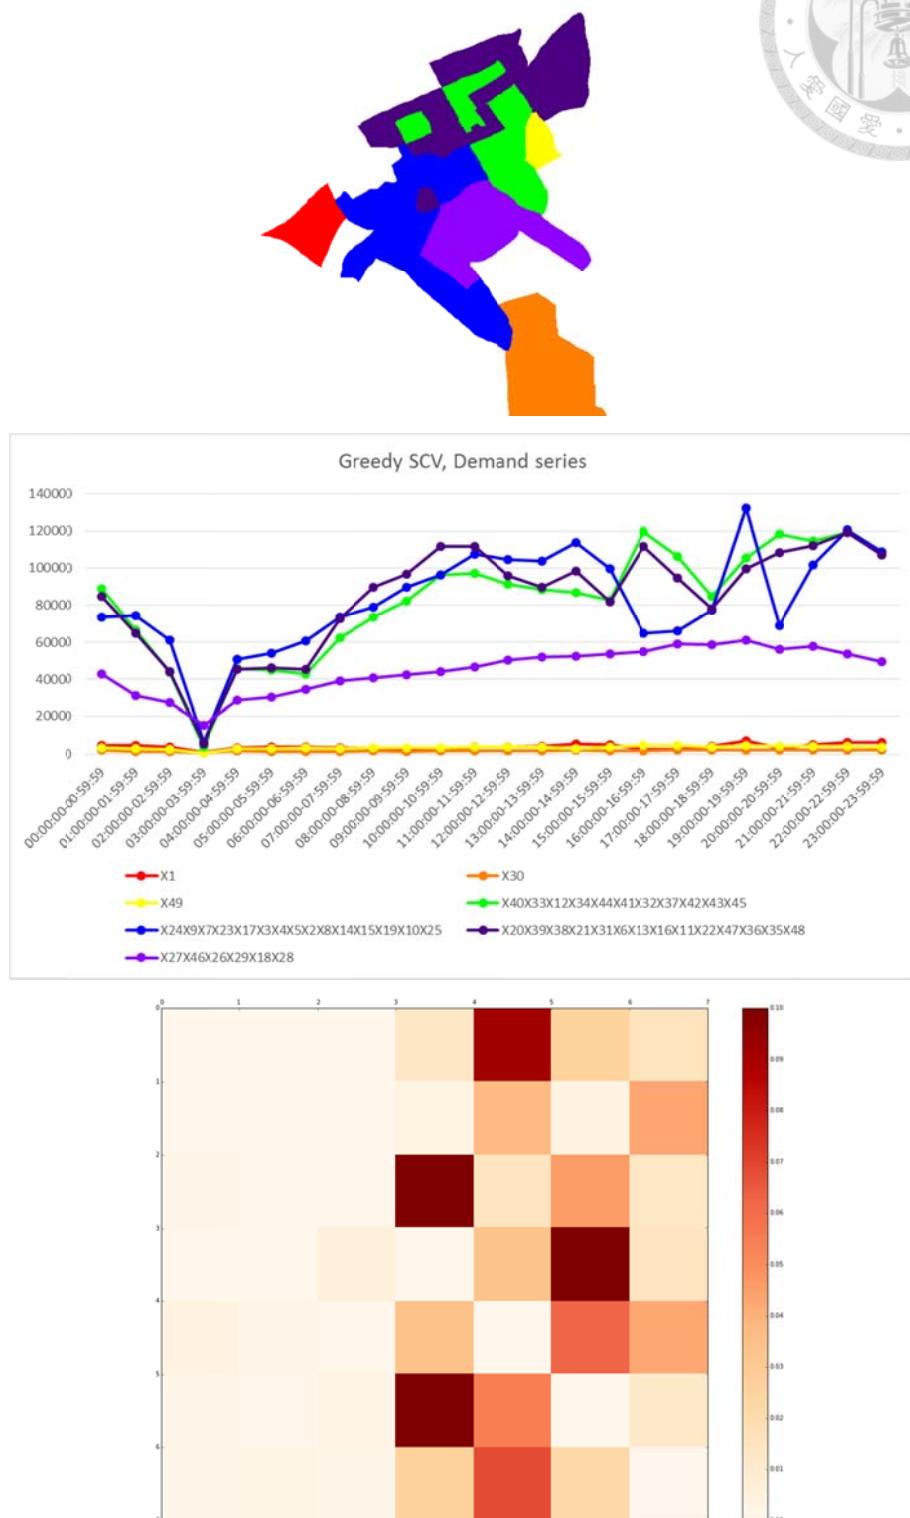


Fig.6-3 : 貪婪式規劃法：SCV

- 貪婪式規劃方法：目標函數為  $\|\check{\mathbf{Q}}\|_F$

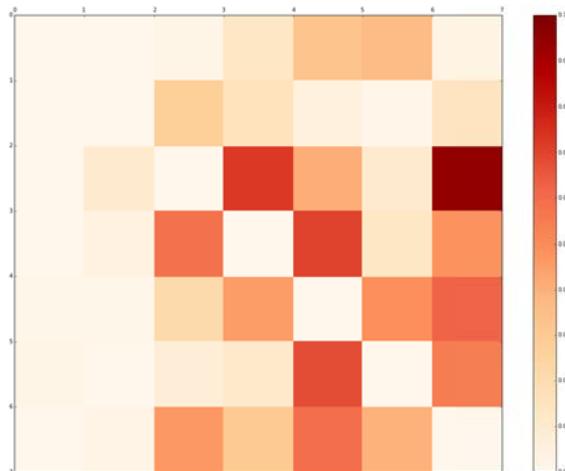
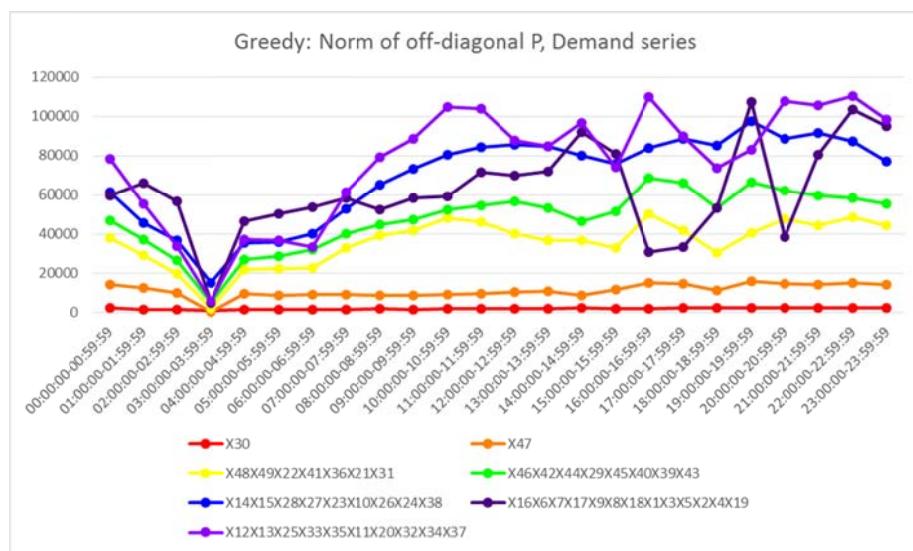
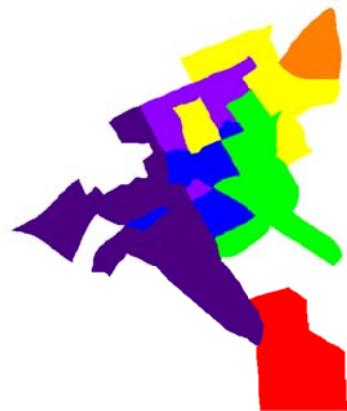


Fig.6-4 : 貪婪式規劃法 :  $\|\check{\mathbf{Q}}\|_F$



- 貪婪式規劃方法：目標函數為  $\|\tilde{\mathbf{M}}\|_F$

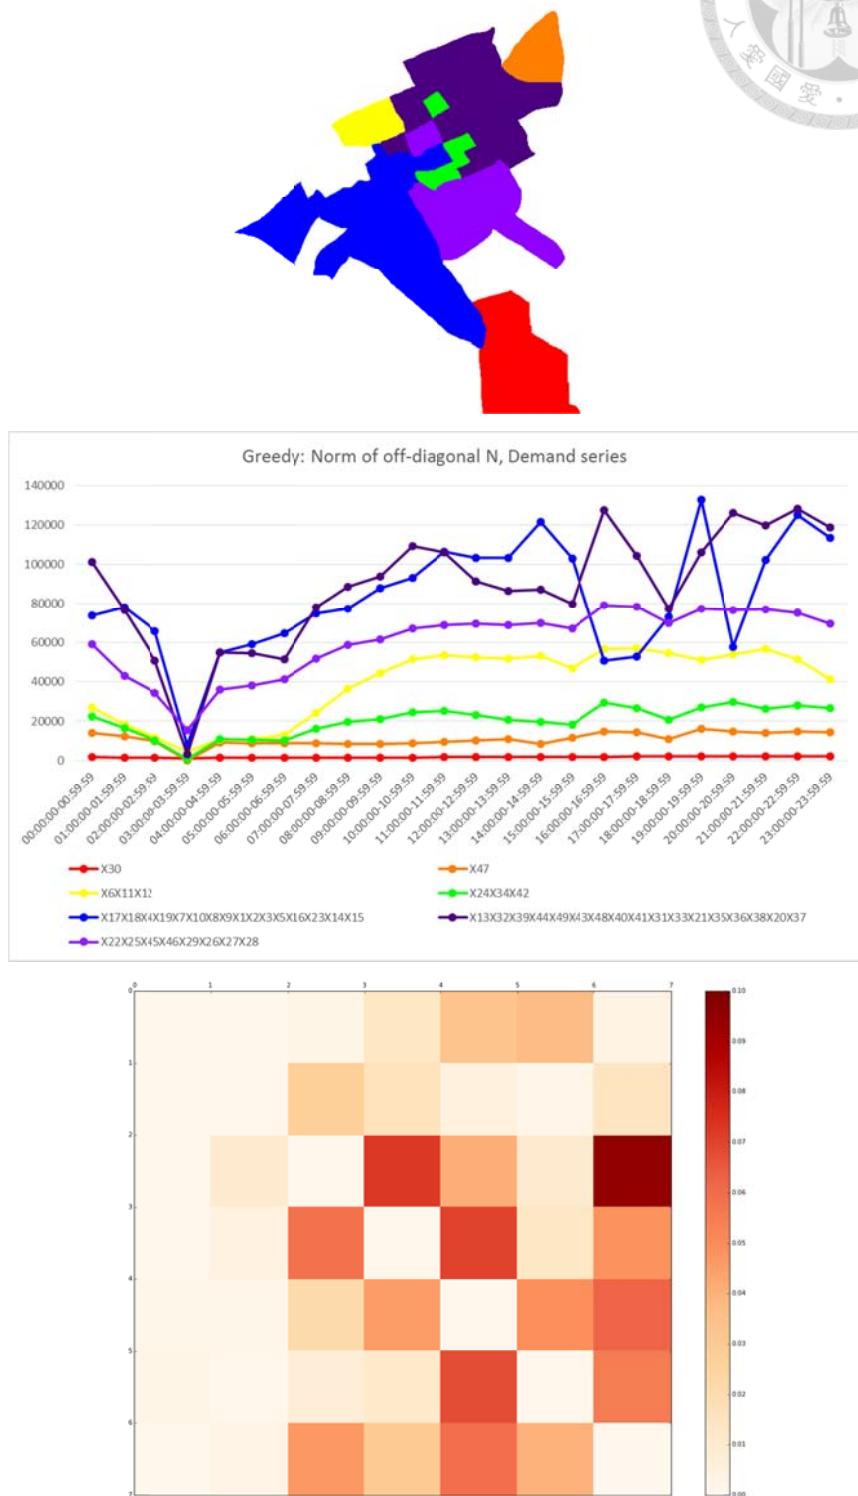


Fig.6-5 : 貪婪式規劃法： $\|\tilde{\mathbf{M}}\|_F$

- 階層式規劃方法：聚合選項為 correlation matrix

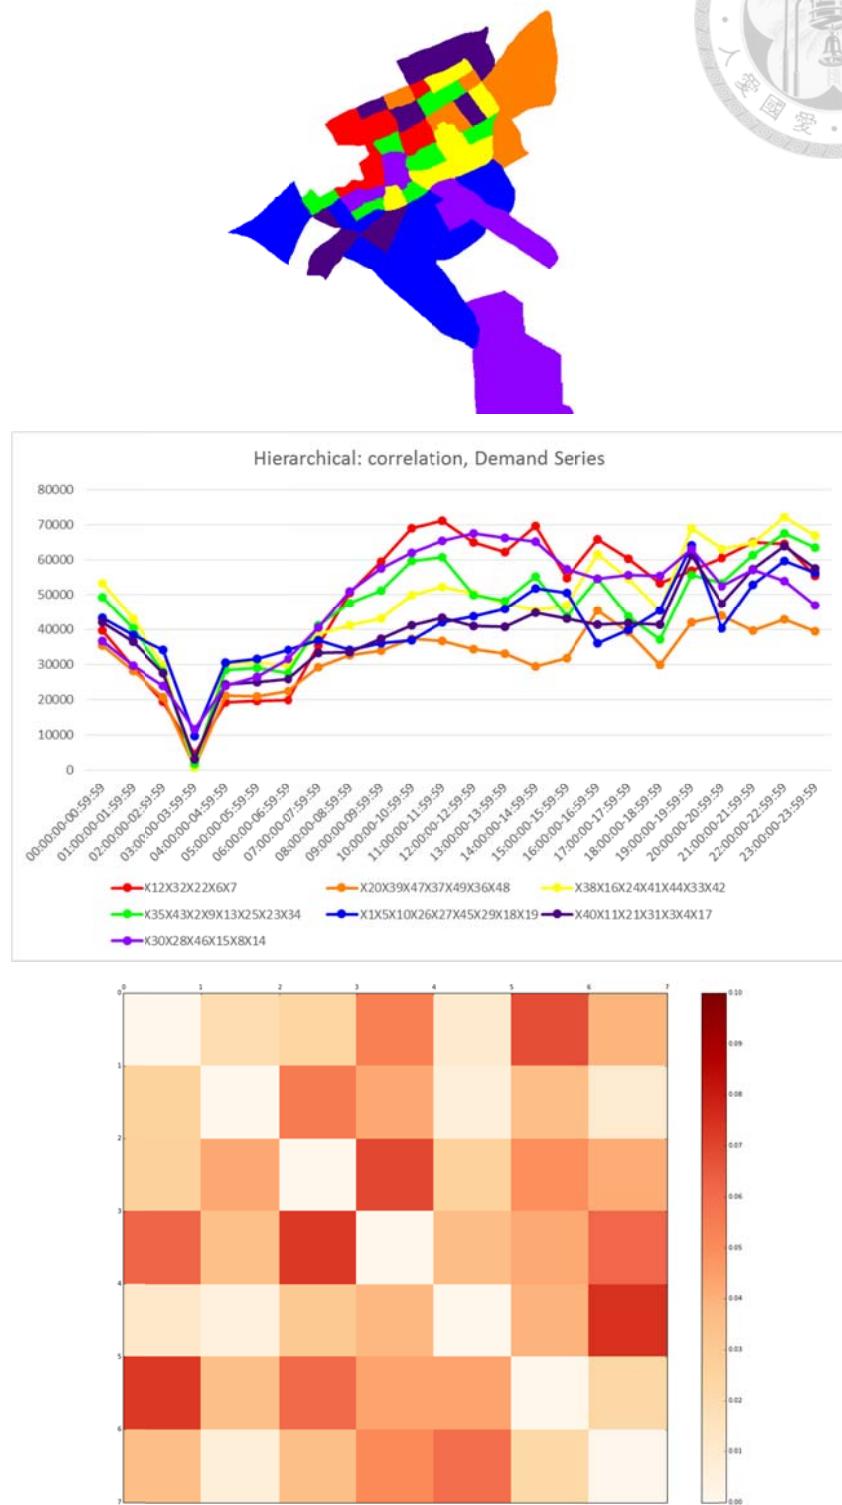


Fig.6-6 : 階層式規劃法 : correlation matrix



- 階層式規劃方法：聚合選項為 transition matrix

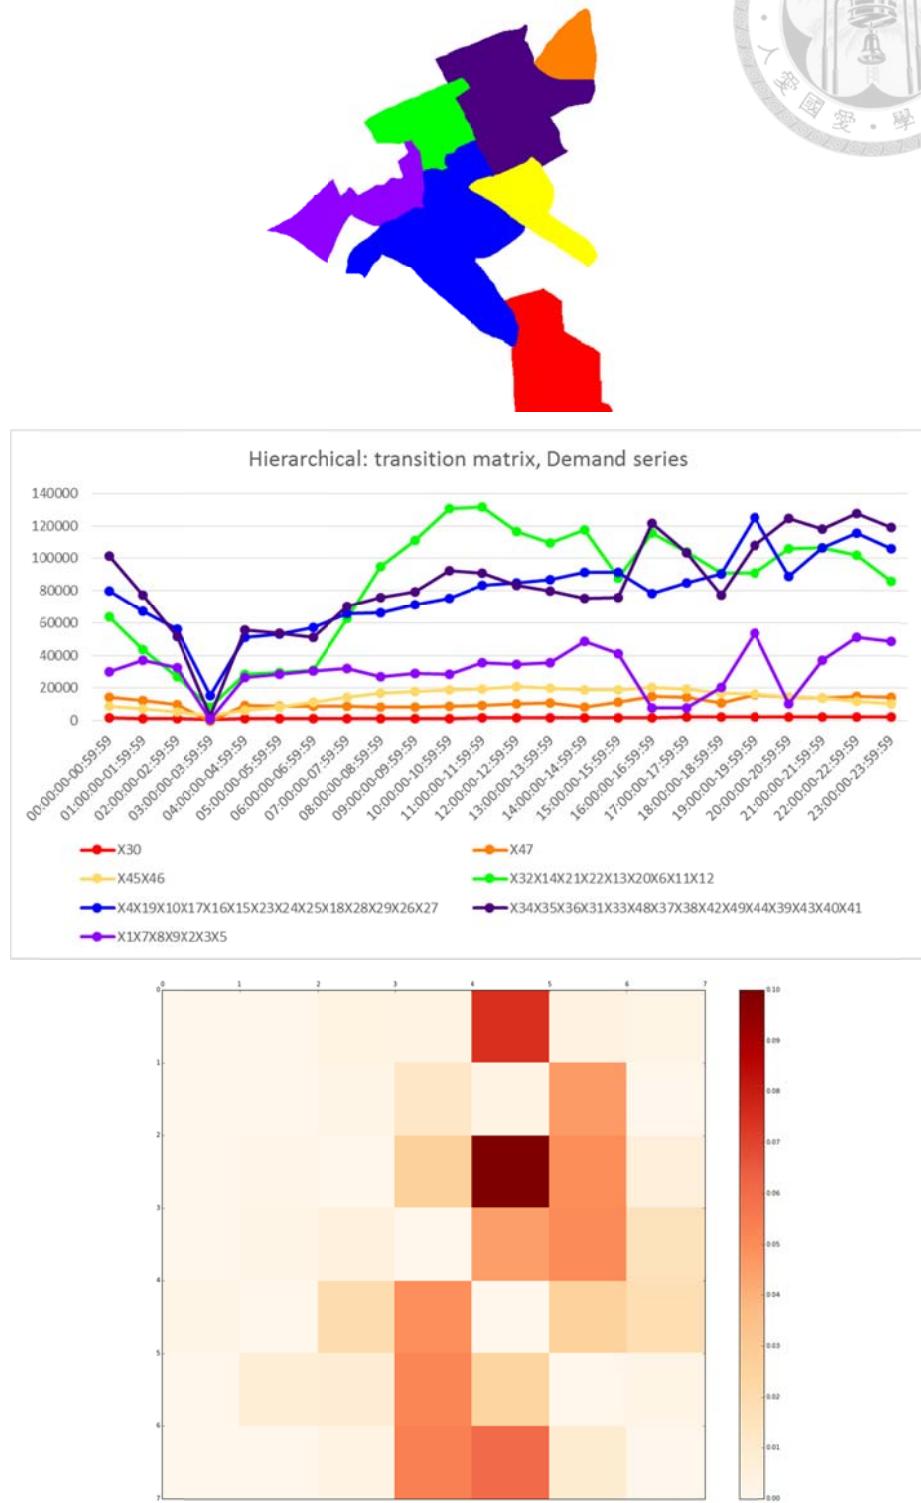


Fig.6-7：階層式規劃法：transition matrix



- 階層式規劃方法：聚合選項為 transition count

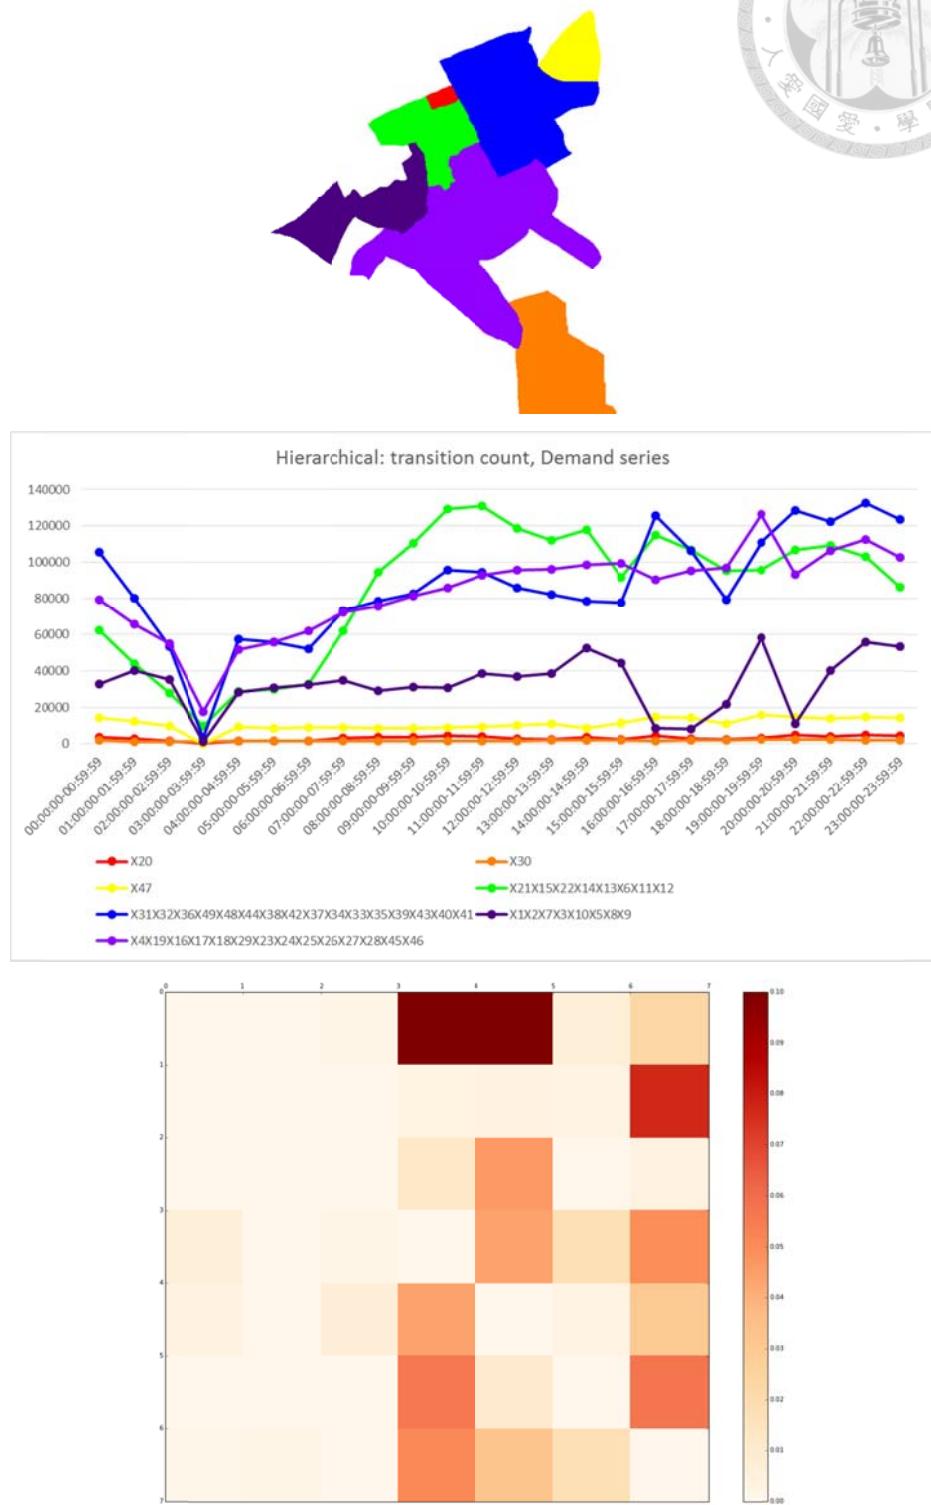


Fig.6-8：階層式規劃法：transition count

- K 區域規劃方法：聚合選項為 correlation matrix

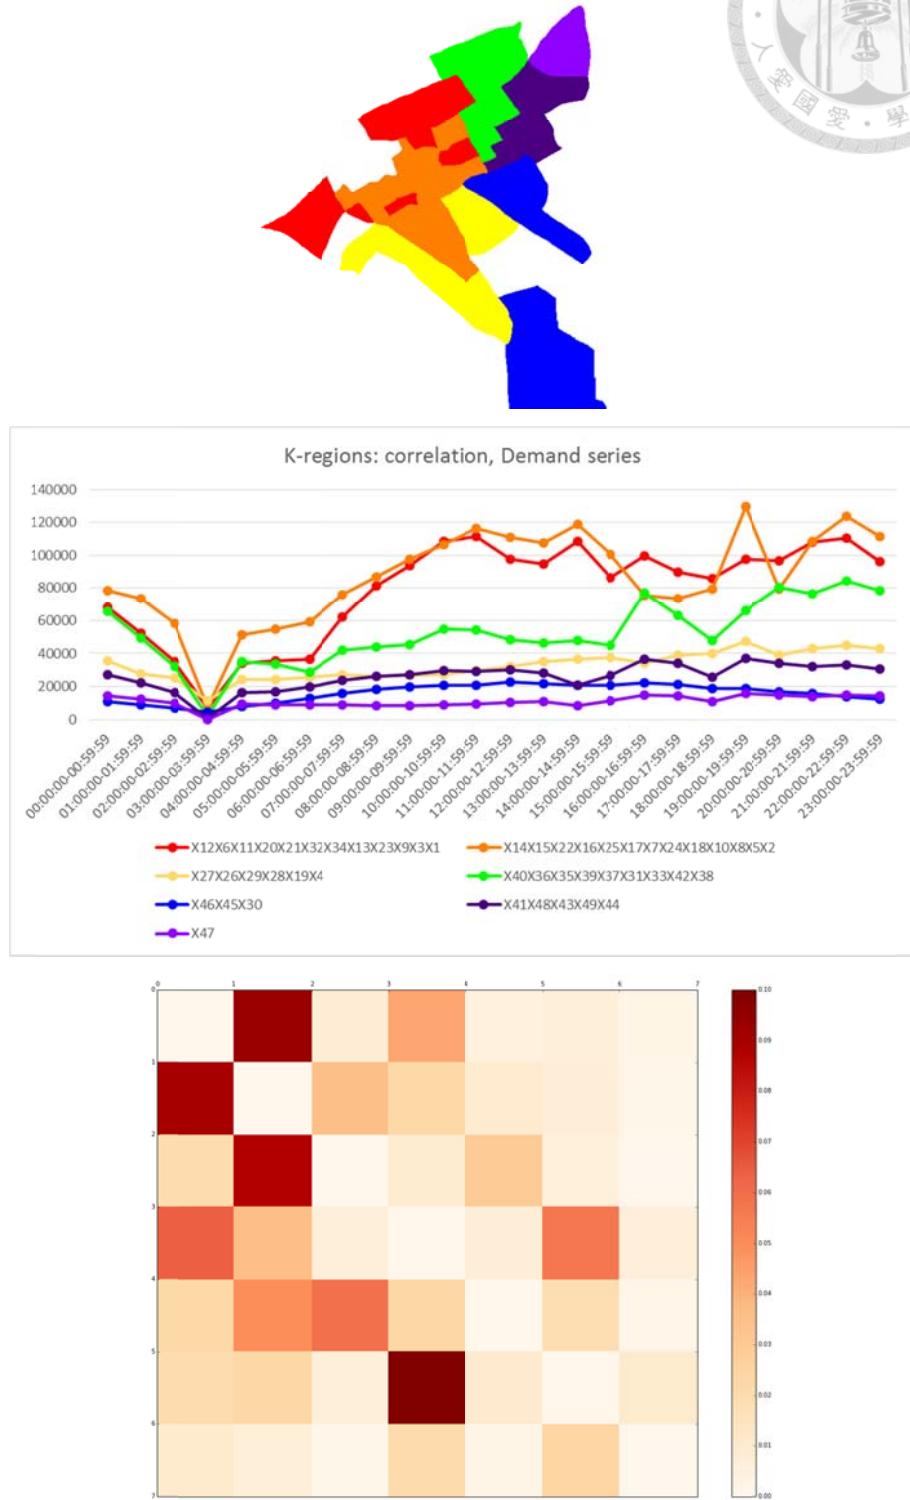


Fig.6-9 : K 區域規劃法 : correlation matrix

- K 區域規劃方法：聚合選項為 transition matrix

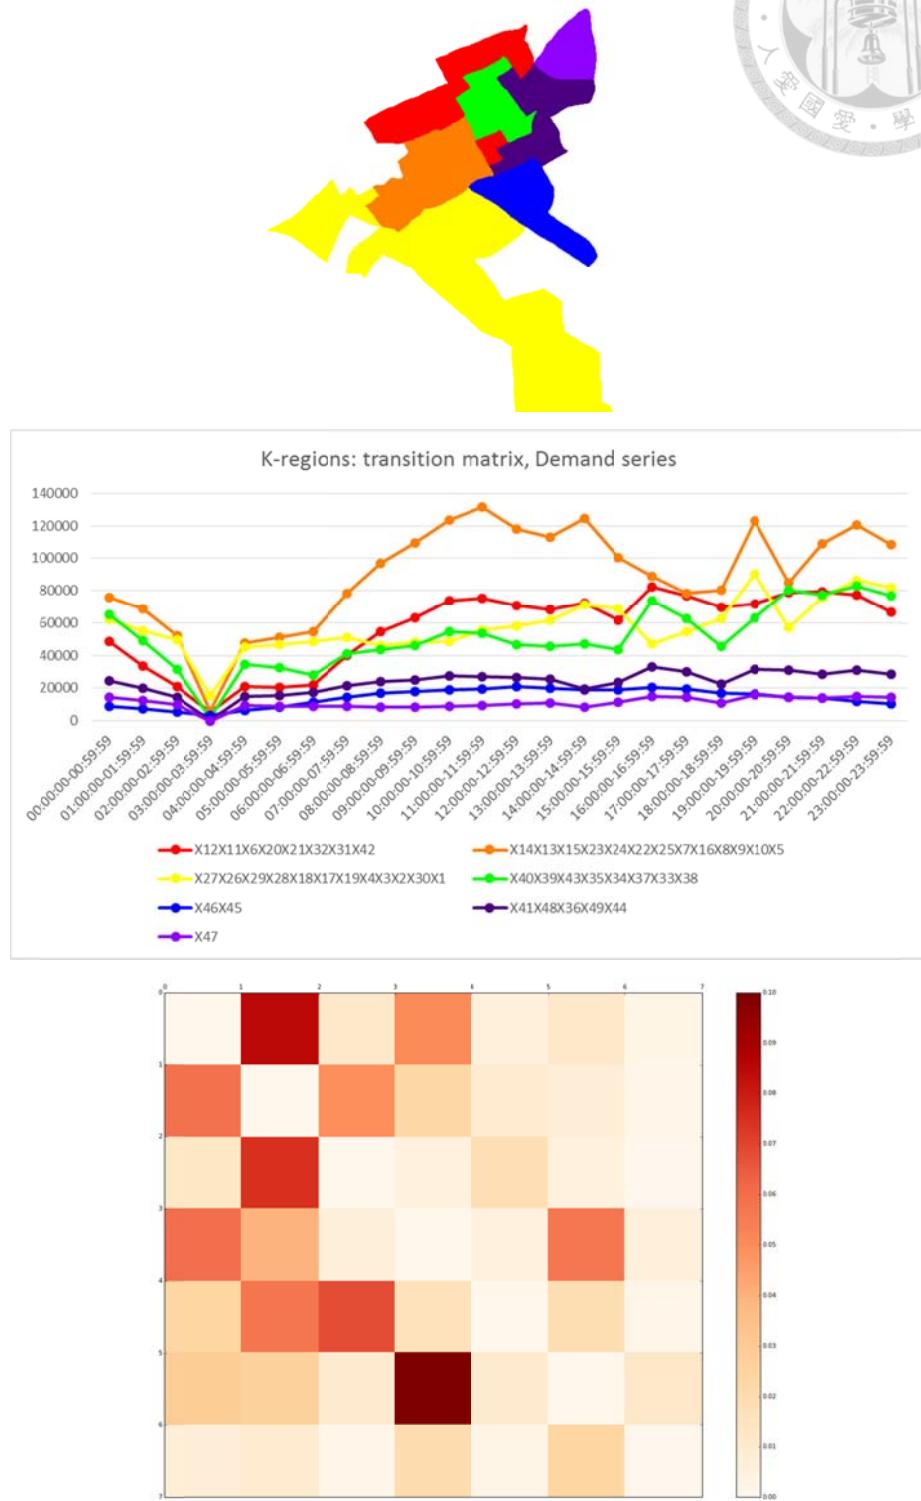


Fig.6-10 : K 區域規劃法：transition matrix



- K 區域規劃方法：聚合選項為 transition count

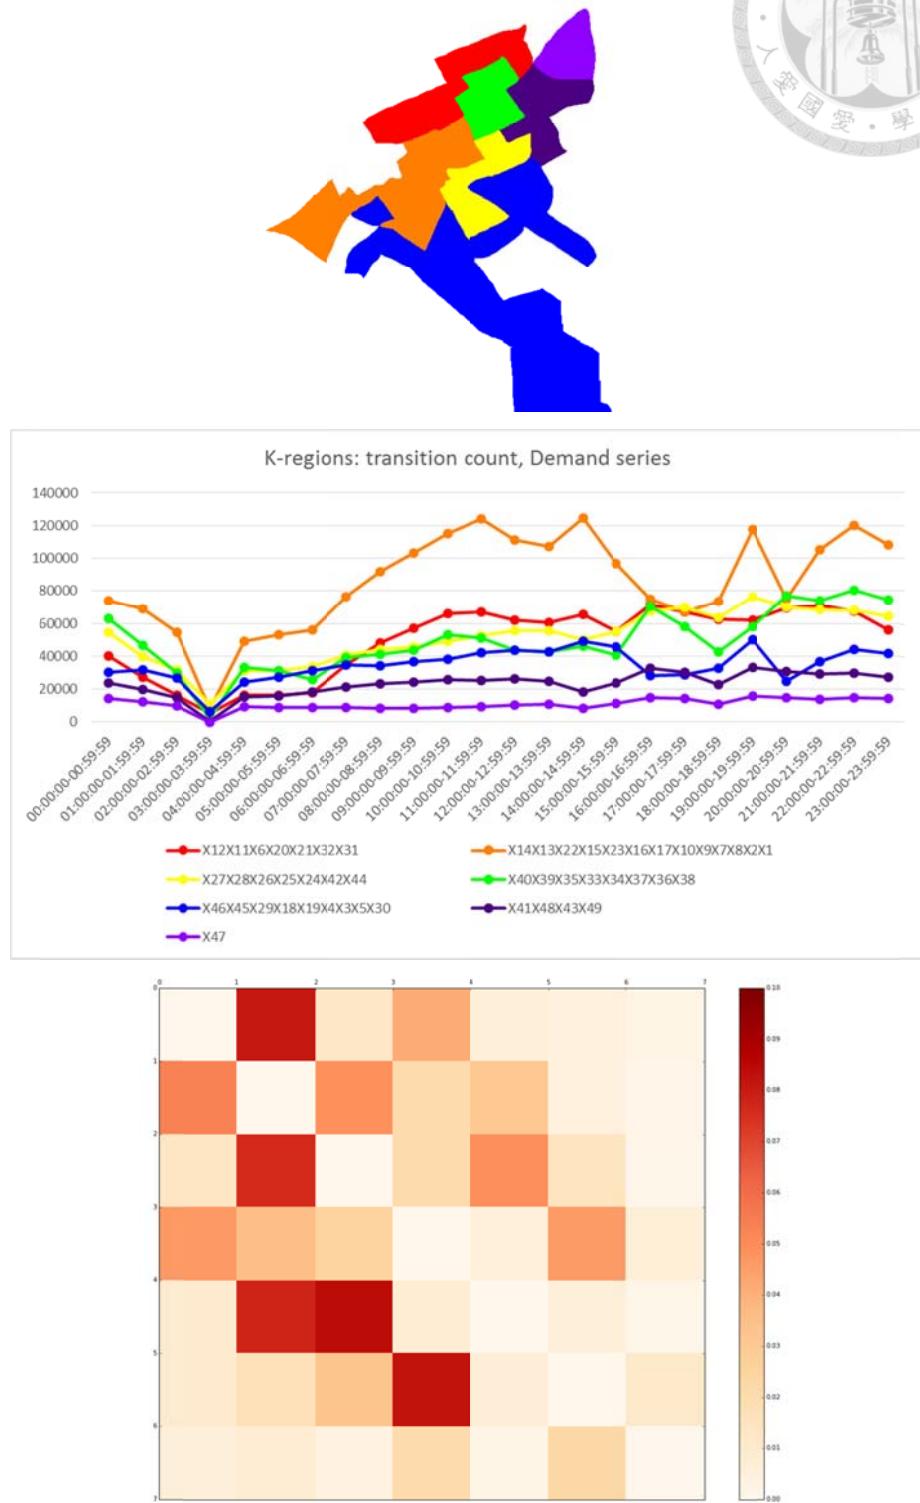


Fig.6-11 : K 區域規劃法：transition count



- 基因演算規劃方法：目標函數為 Weighted-average CV

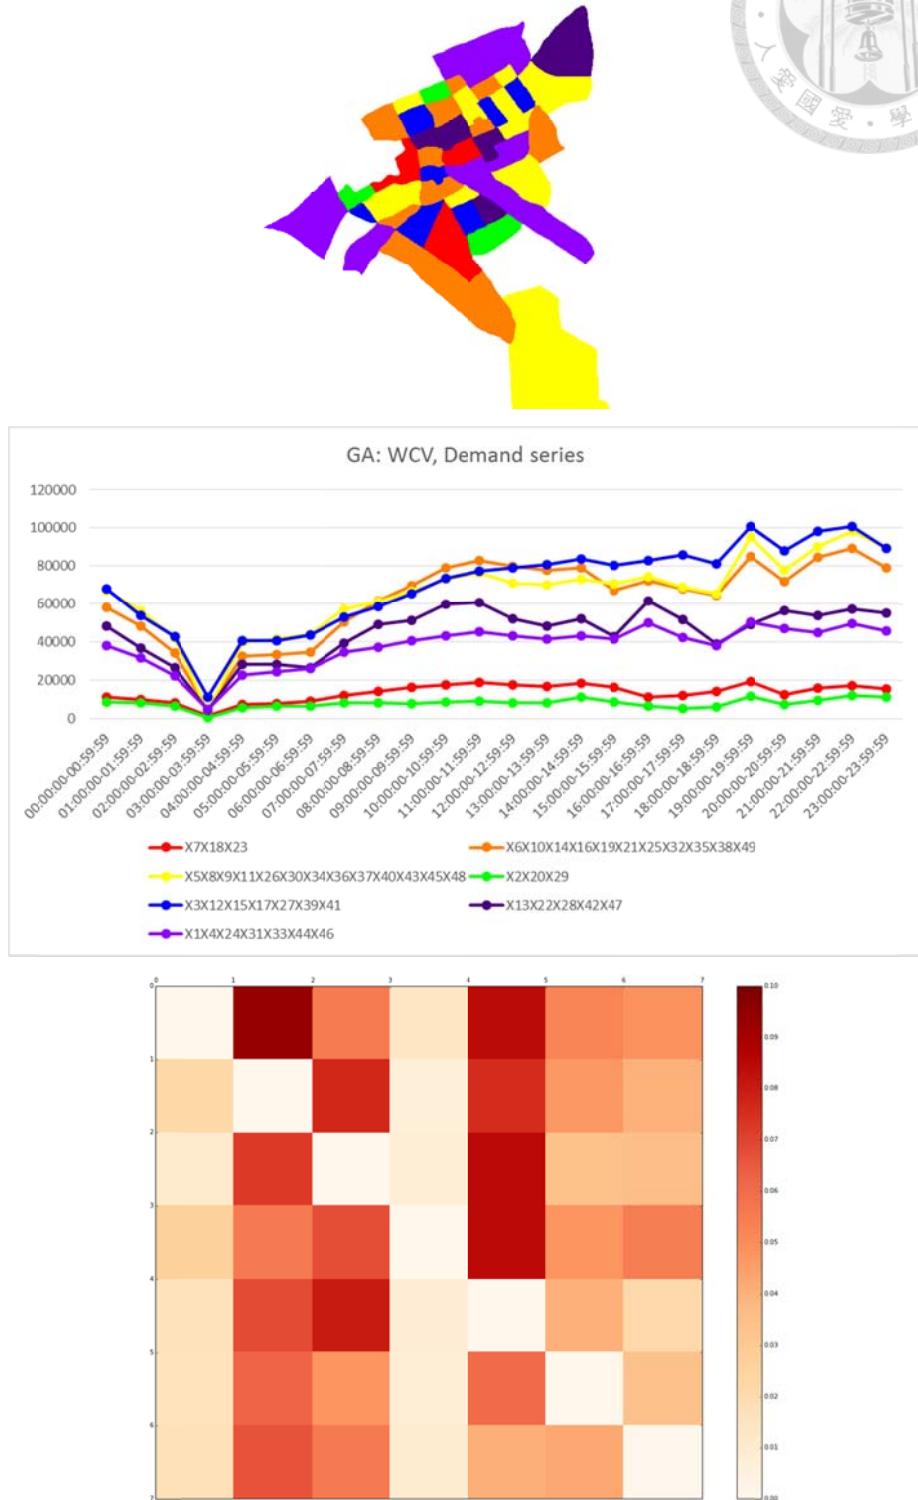


Fig.6-12 : 基因演算規劃法：WCV

- 基因演算規劃方法：目標函數為 Simple-average CV

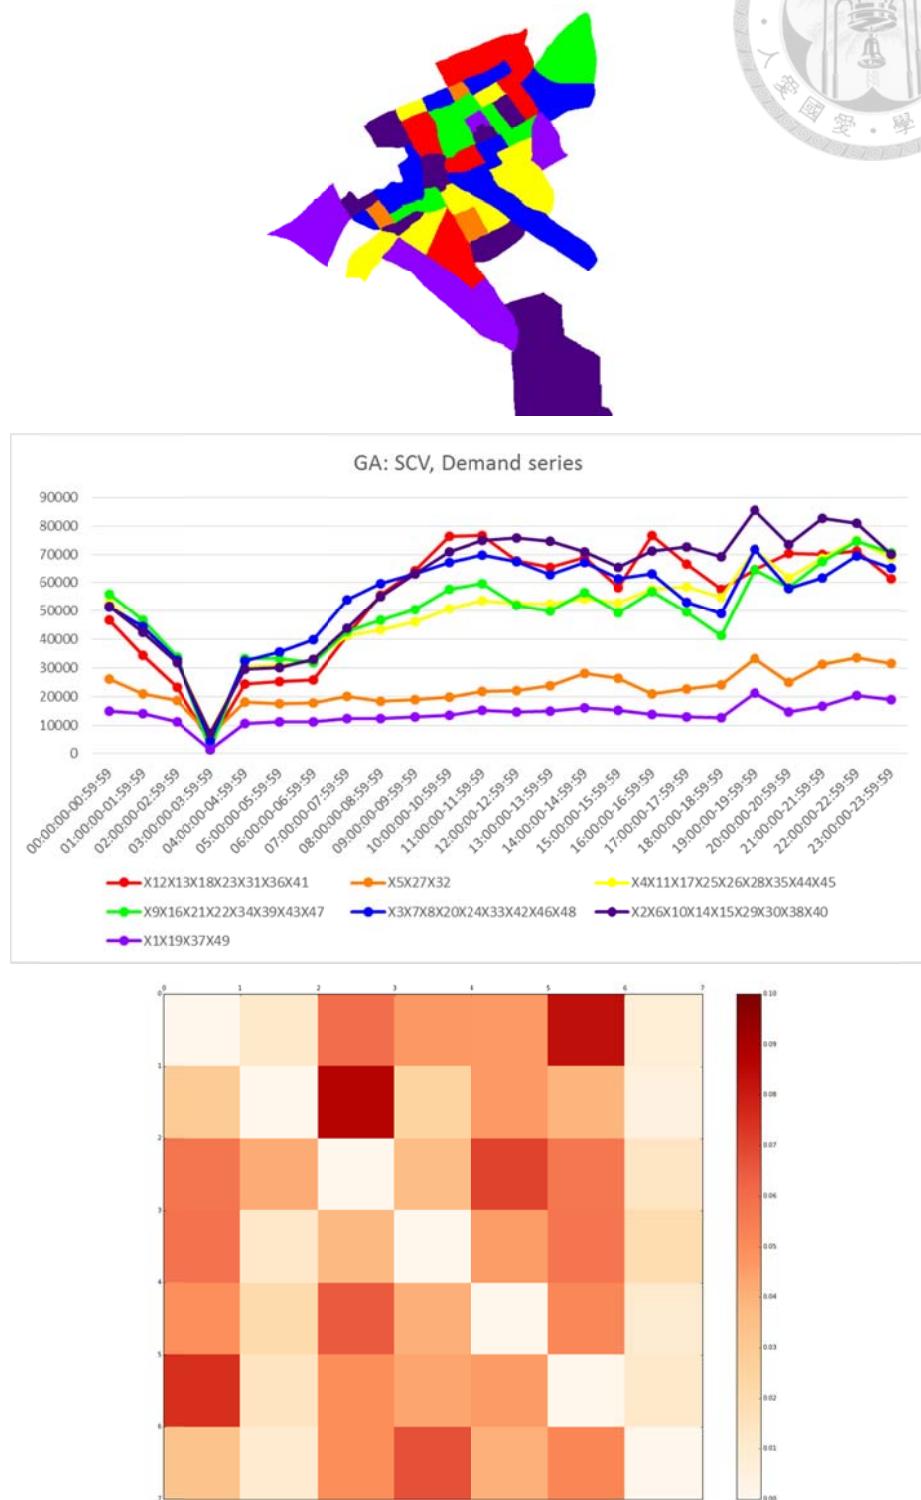


Fig.6-13：基因演算規劃法：SCV



- 基因演算規劃方法：目標函數為  $\|\check{\mathbf{Q}}\|_F$

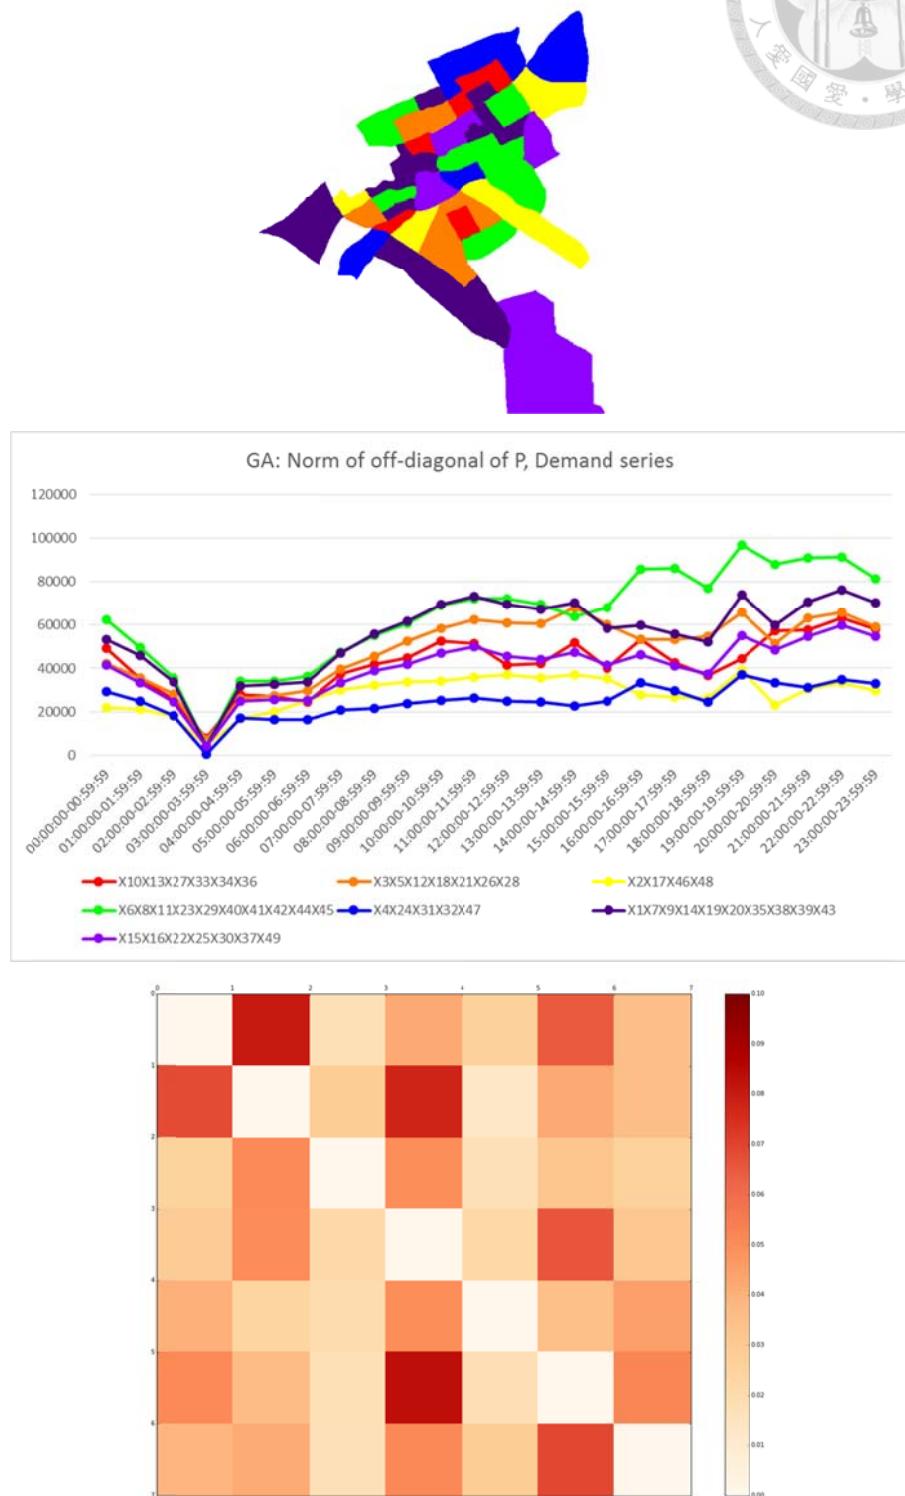


Fig.6-14 : 基因演算規劃法 :  $\|\check{\mathbf{Q}}\|_F$



- 基因演算規劃方法：目標函數為  $\|\bar{\mathbf{M}}\|_F$

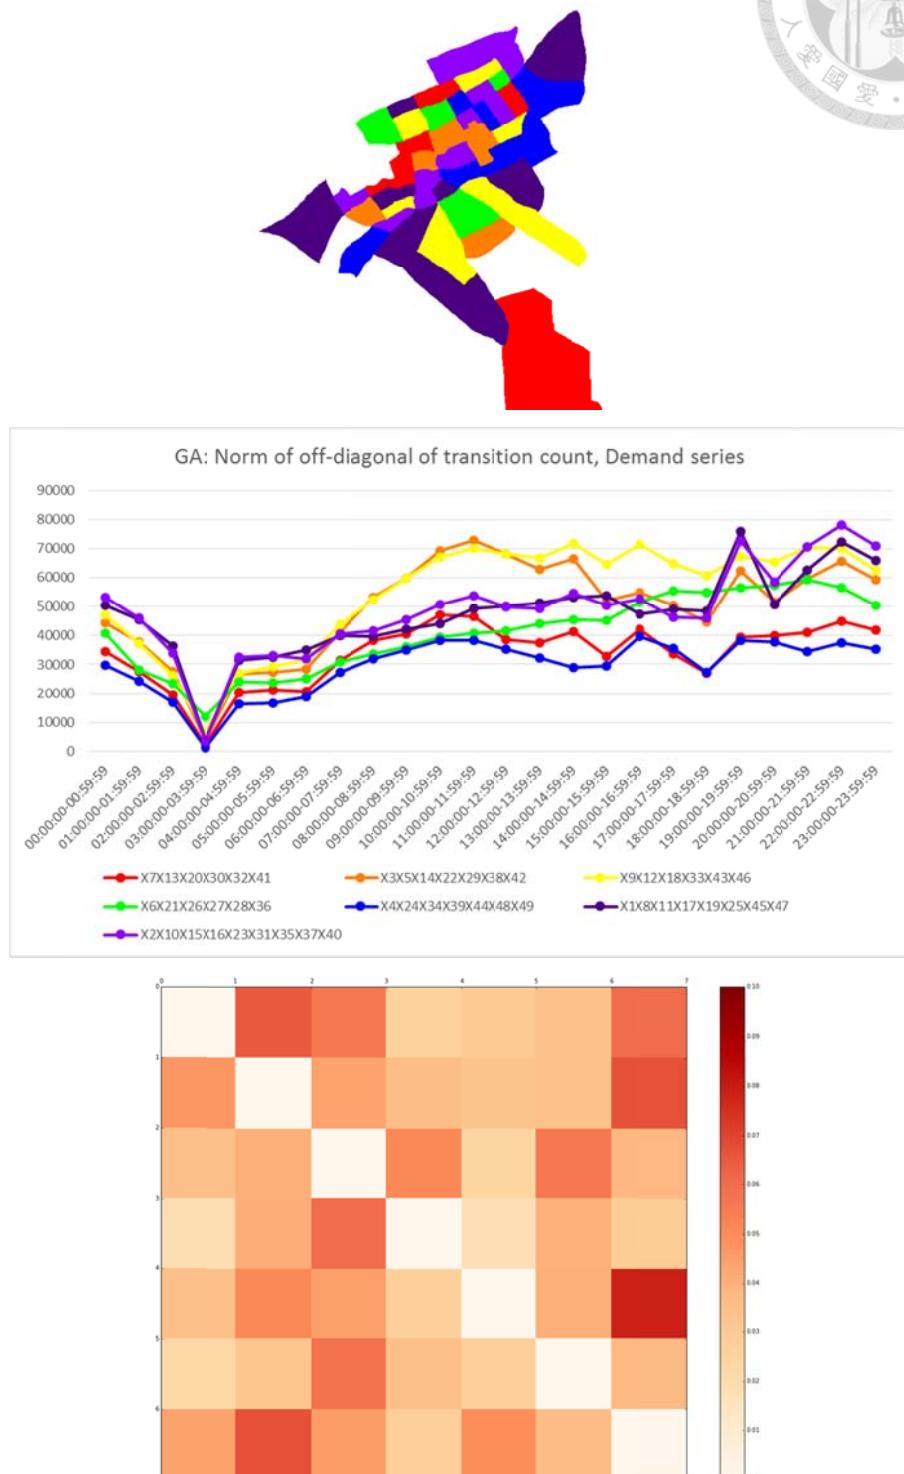


Fig.6-15：基因演算規劃法： $\|\bar{\mathbf{M}}\|_F$

## Appendix 4. Micro data 估計之 macro data and micro data 之規劃策略結果

貪婪式規劃方法：目標函數為 Weighted-average CV

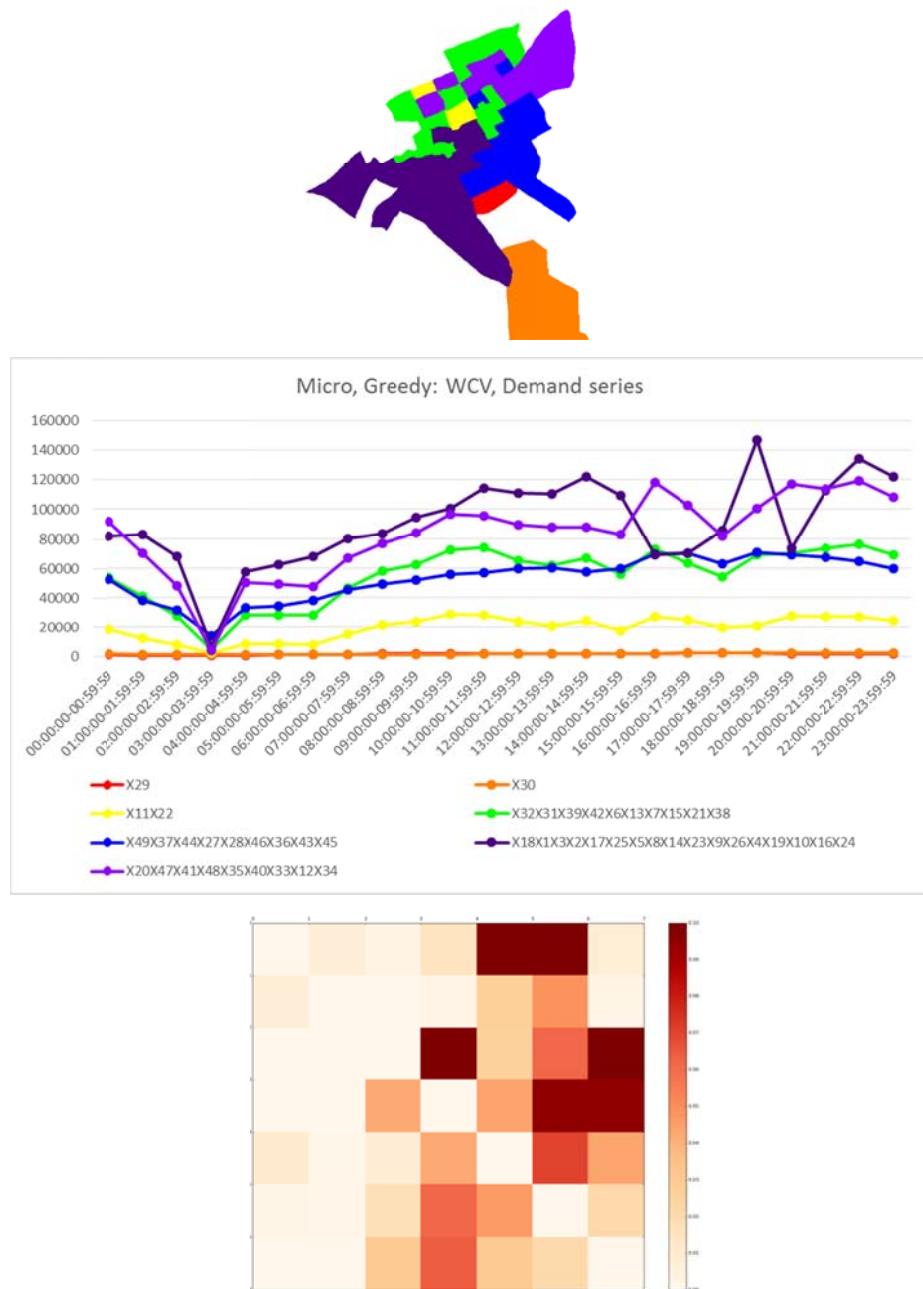


Fig.6-16 : Micro data 下貪婪式規劃方法：WCV

## 貪婪式規劃方法：目標函數為 Simple-average CV

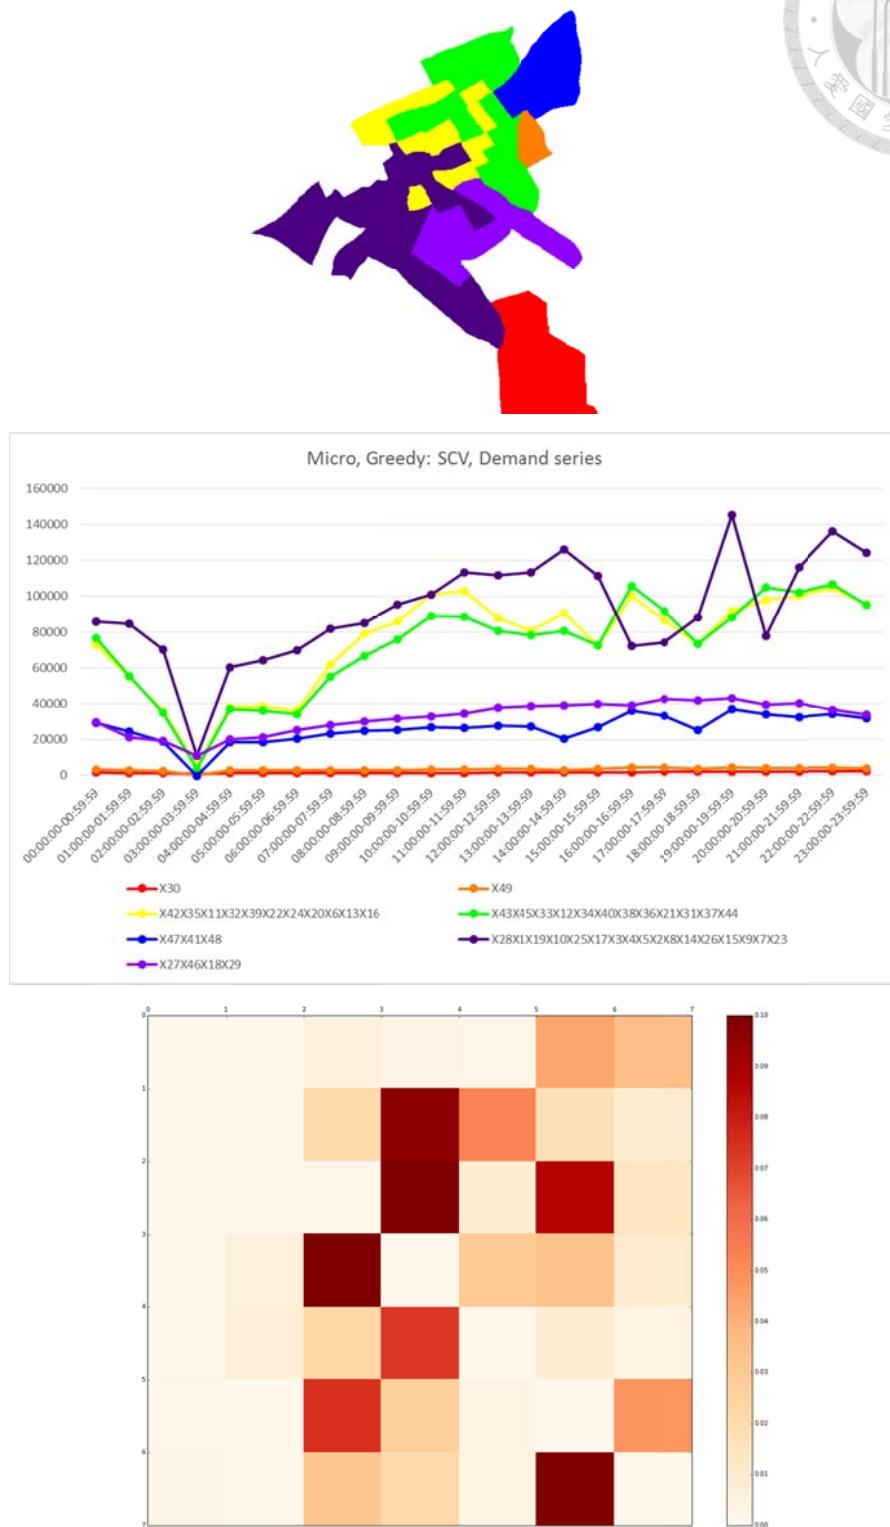


Fig.6-17 : Micro data 下貪婪式規劃方法：SCV

## 貪婪式規劃方法：目標函數為 $\|\tilde{\mathbf{Q}}\|_F$

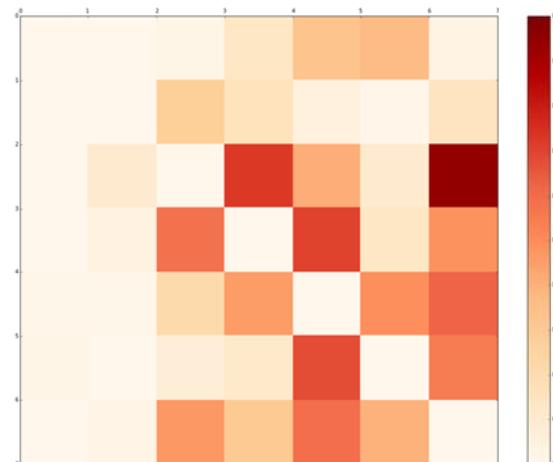
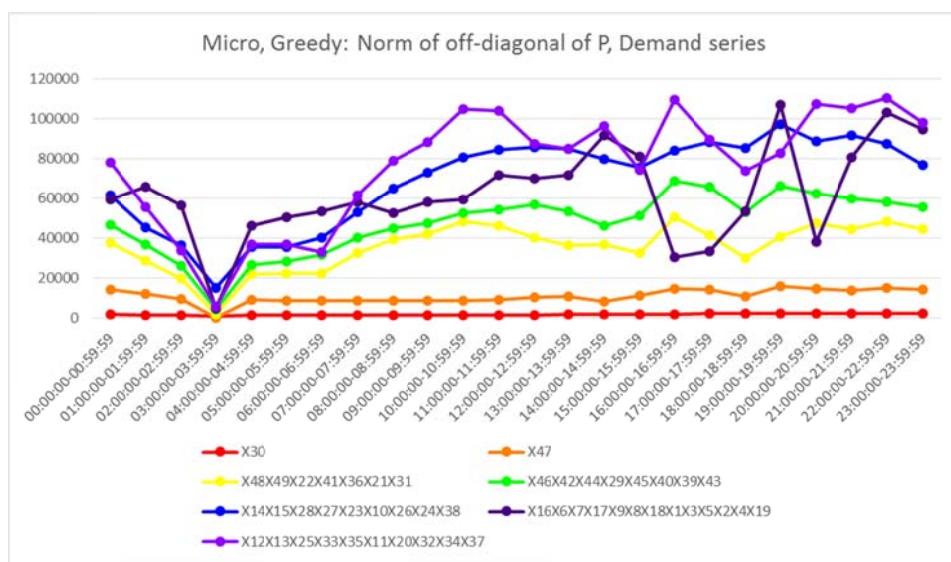
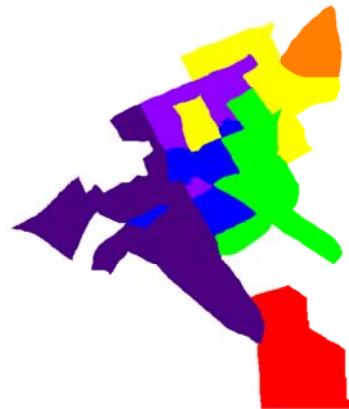


Fig.6-18 : Micro data 下貪婪式規劃方法： $\|\tilde{\mathbf{Q}}\|_F$

## 貪婪式規劃方法：目標函數為 $\|\tilde{\mathbf{M}}\|_F$

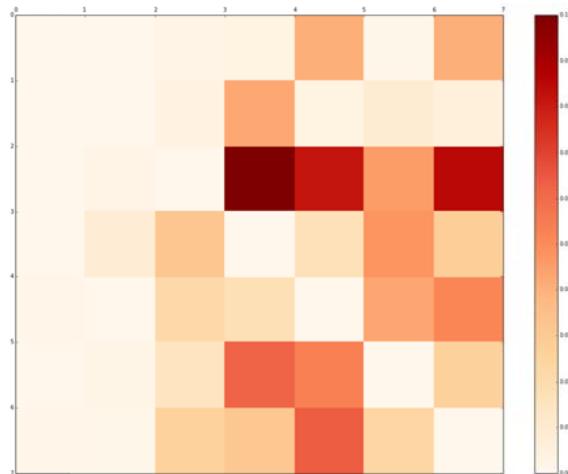
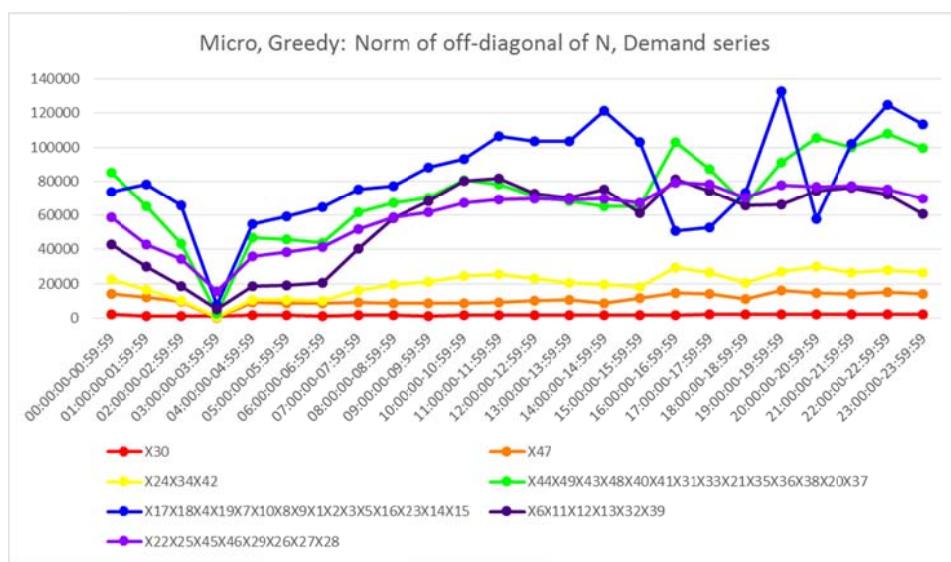
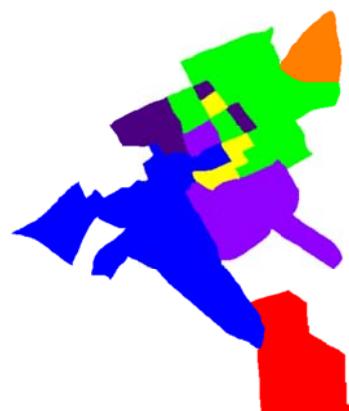


Fig.6-19 : Micro data 下 貪婪式規劃方法 :  $\|\tilde{\mathbf{M}}\|_F$

## 階層式規劃方法：聚合選項為 correlation matrix

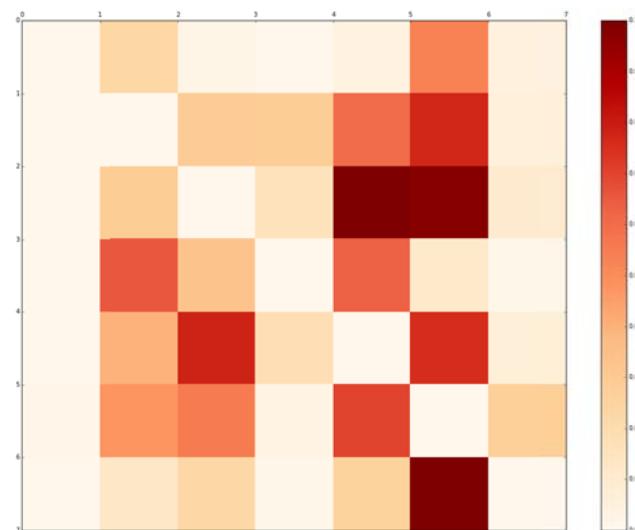
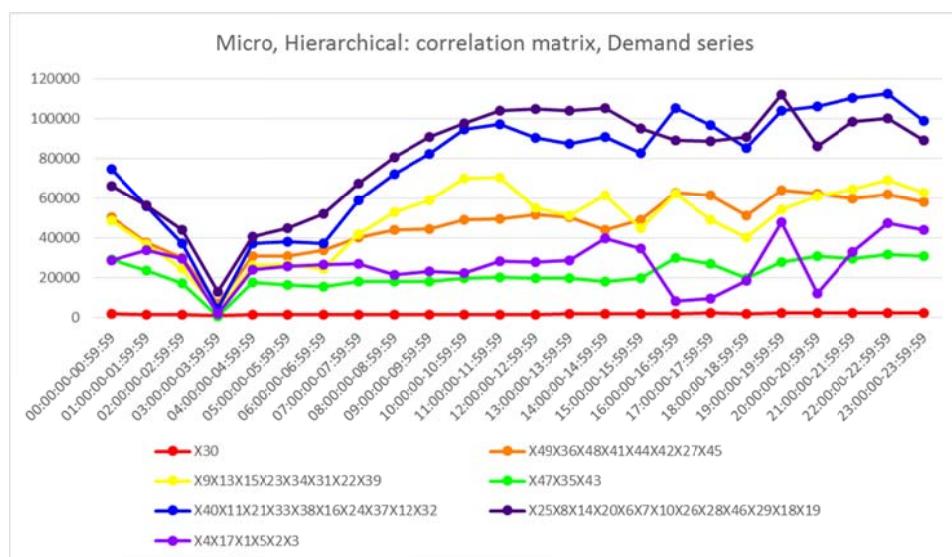


Fig.6-20 : Micro data 下階層式規劃方法：correlation matrix

## 階層式規劃方法：聚合選項為 transition matrix

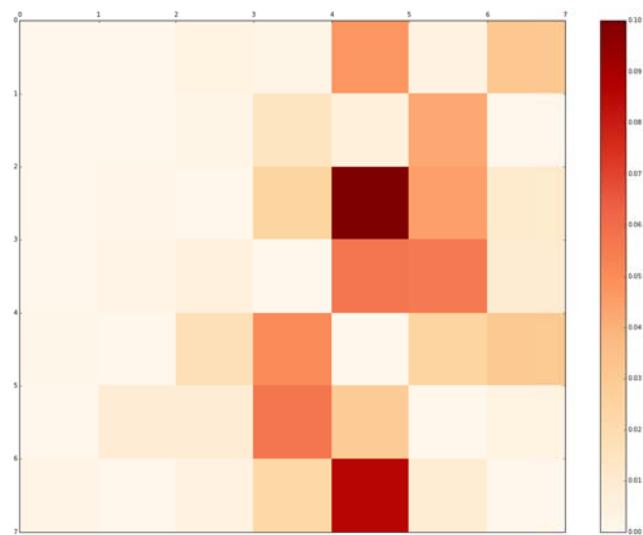
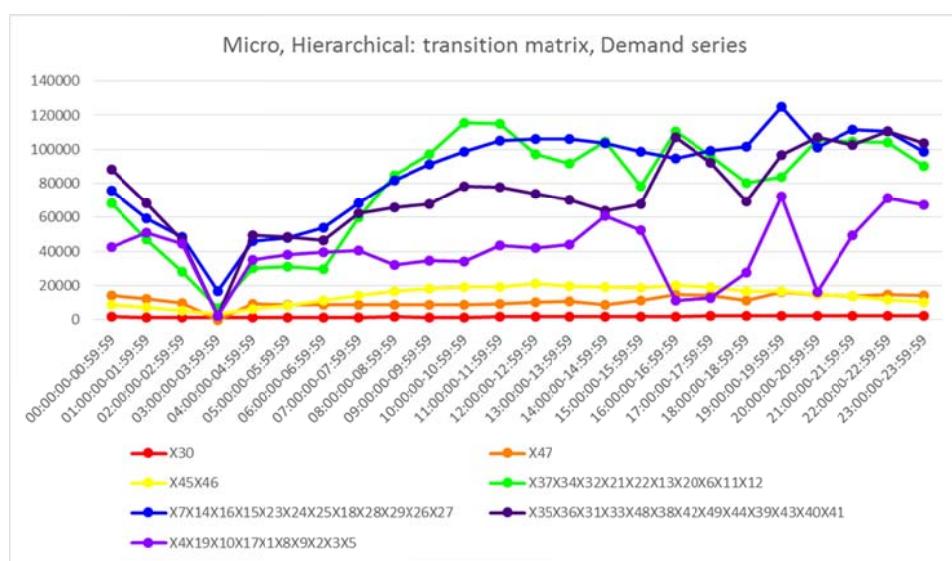


Fig.6-21 : Micro data 下階層式規劃方法：transition matrix

## 階層式規劃方法：聚合選項為 transition count

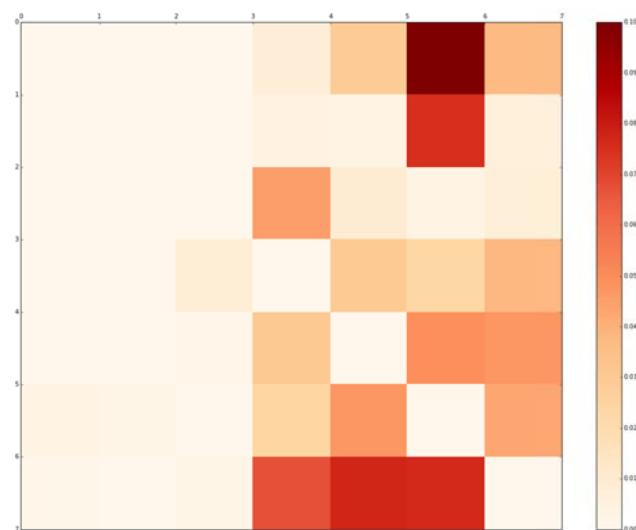
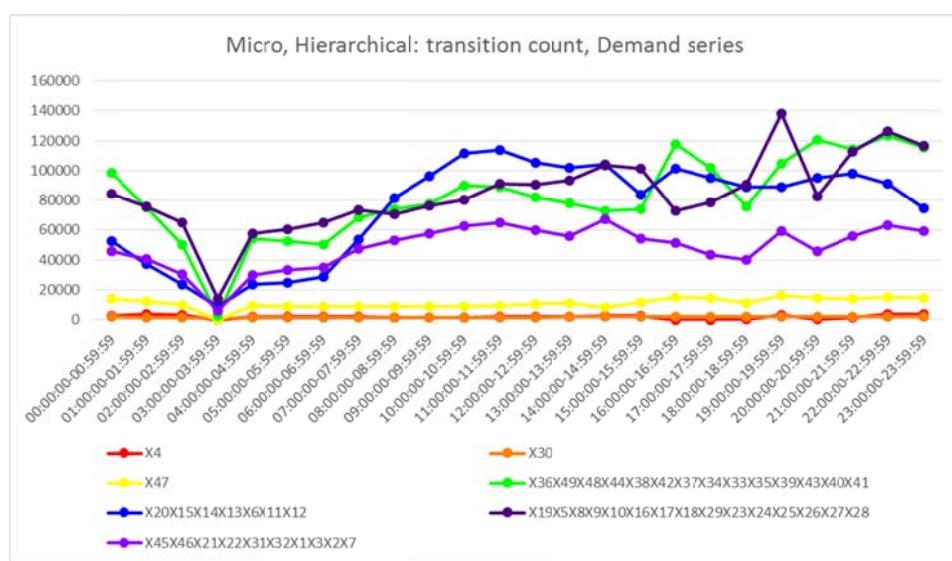


Fig.6-22 : Micro data 下階層式規劃方法：transition count

## K 區域規劃方法：聚合選項為 correlation matrix

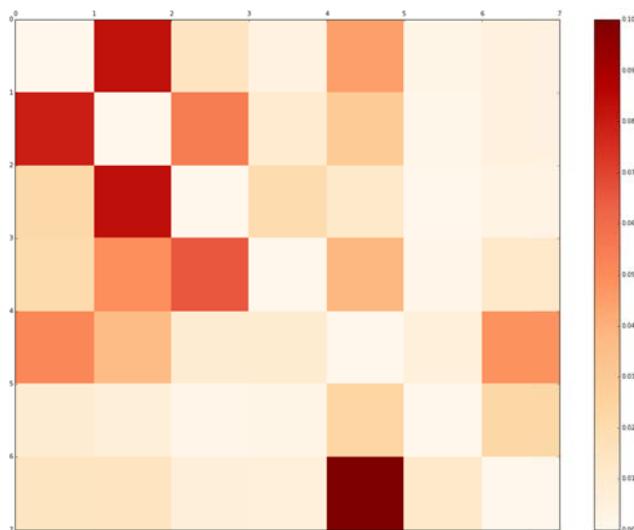
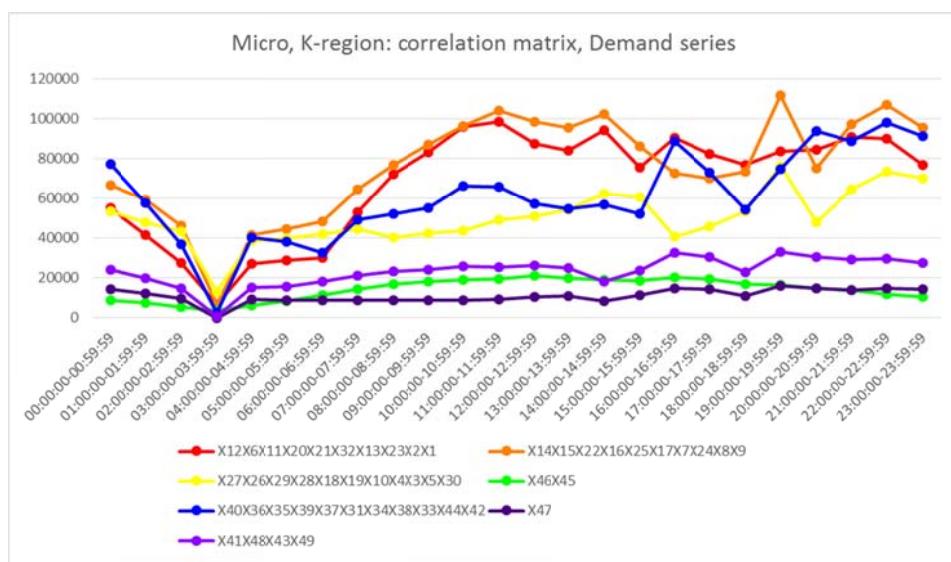
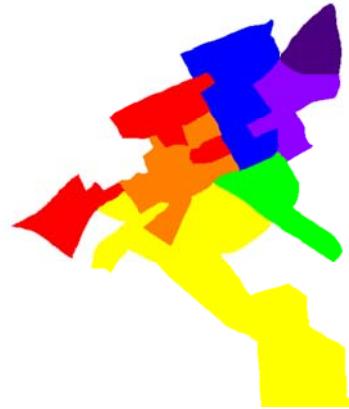


Fig.6-23 : Micro data 下 K 區域規劃方法：correlation matrix

## K 區域規劃方法：聚合選項為 transition matrix

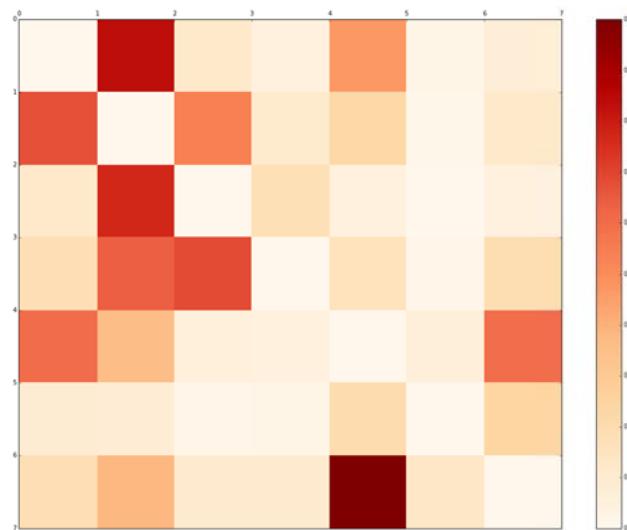
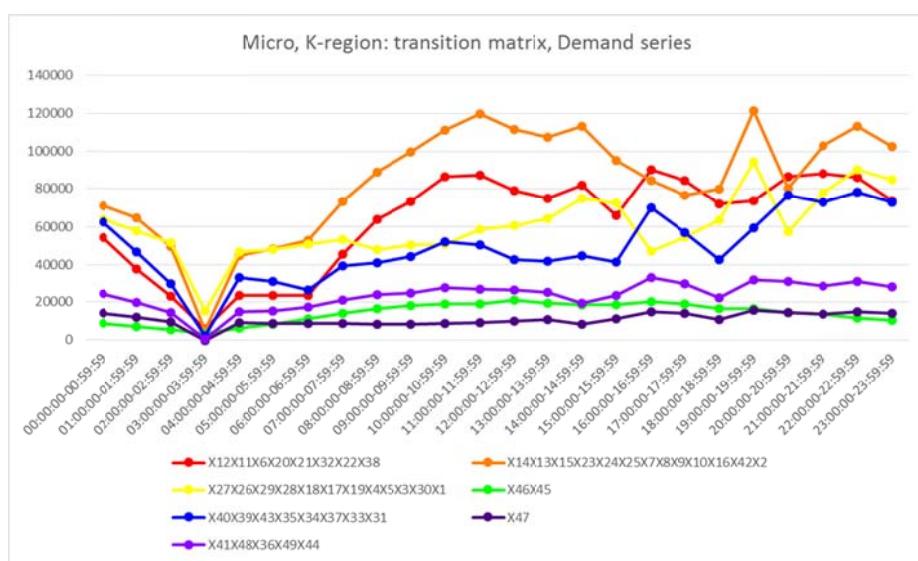


Fig.6-24 : Micro data 下 K 區域規劃方法：transition matrix

## K 區域規劃方法：聚合選項為 transition count

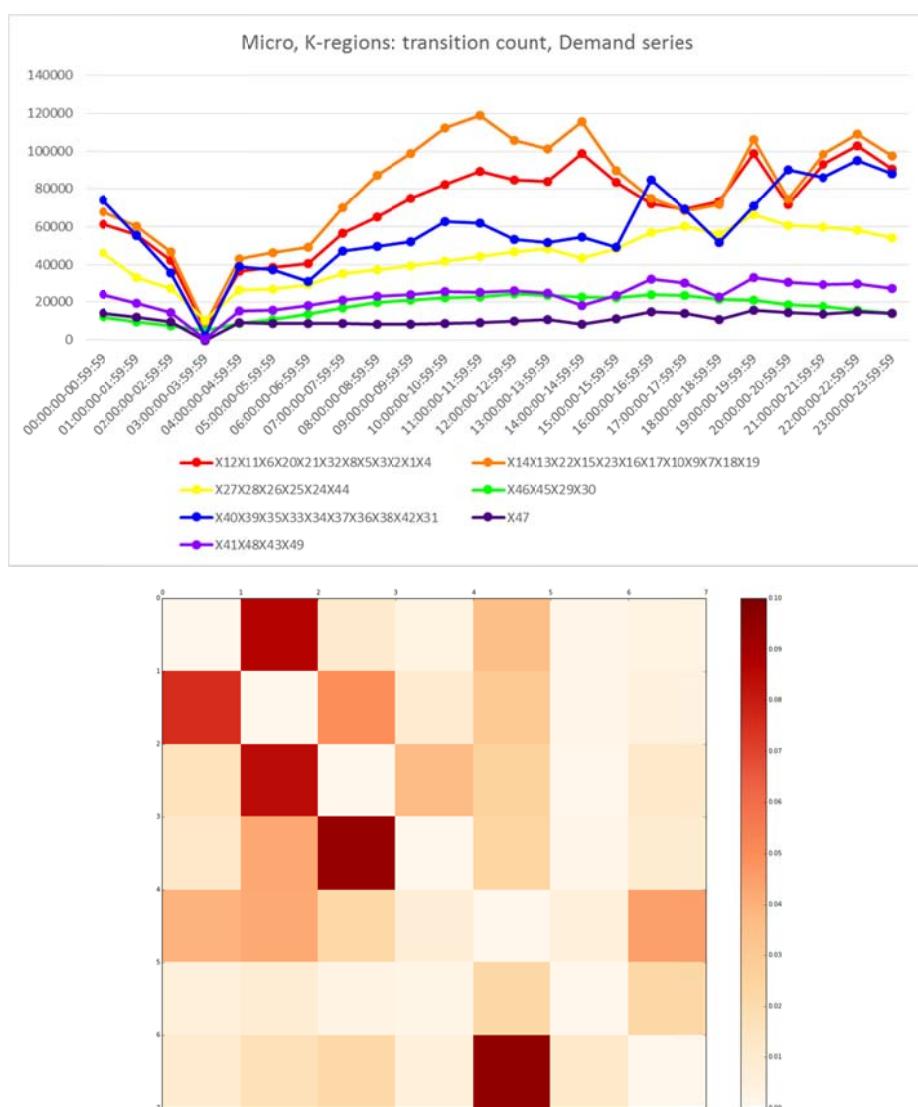


Fig.6-25 : Micro data 下 K 區域規劃方法：transition count

## 基因演算規劃方法：目標函數為 Weighted-average CV

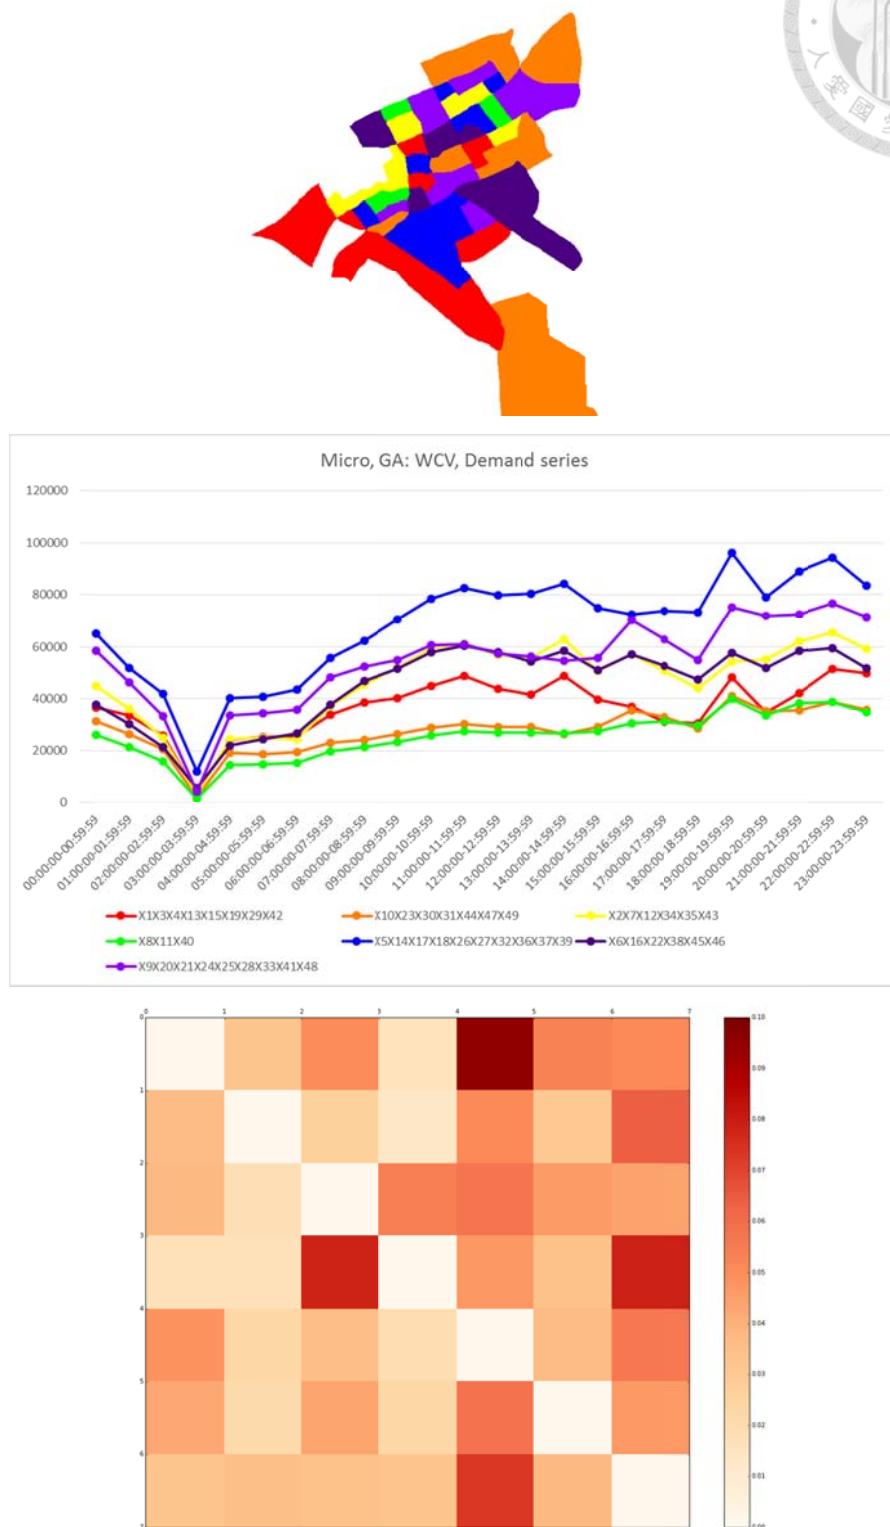


Fig.6-26 : Micro data 下基因演算規劃方法：WCV

## 基因演算規劃方法：目標函數為 Simple-average CV

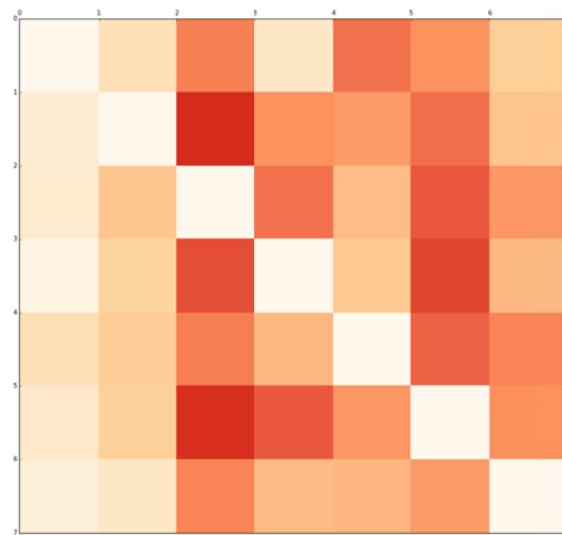
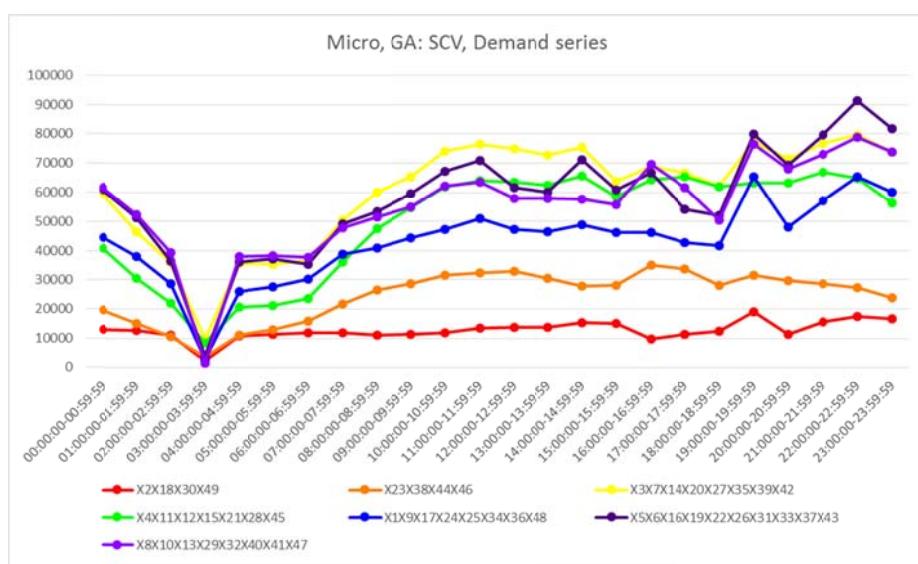
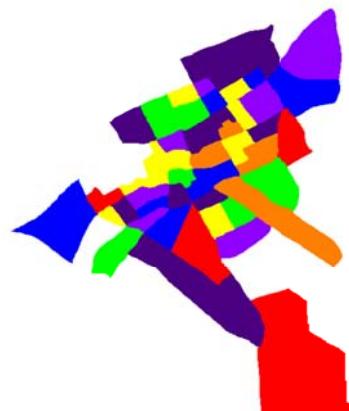


Fig.6-27 : Micro data 下基因演算規劃方法：SCV

## 基因演算規劃方法：目標函數為 $\|\check{\mathbf{Q}}\|_F$

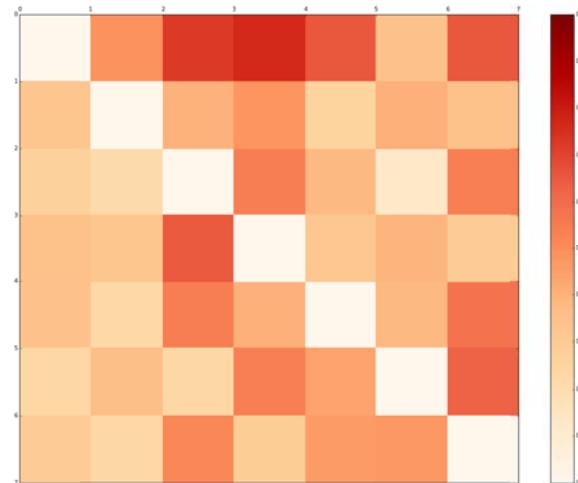
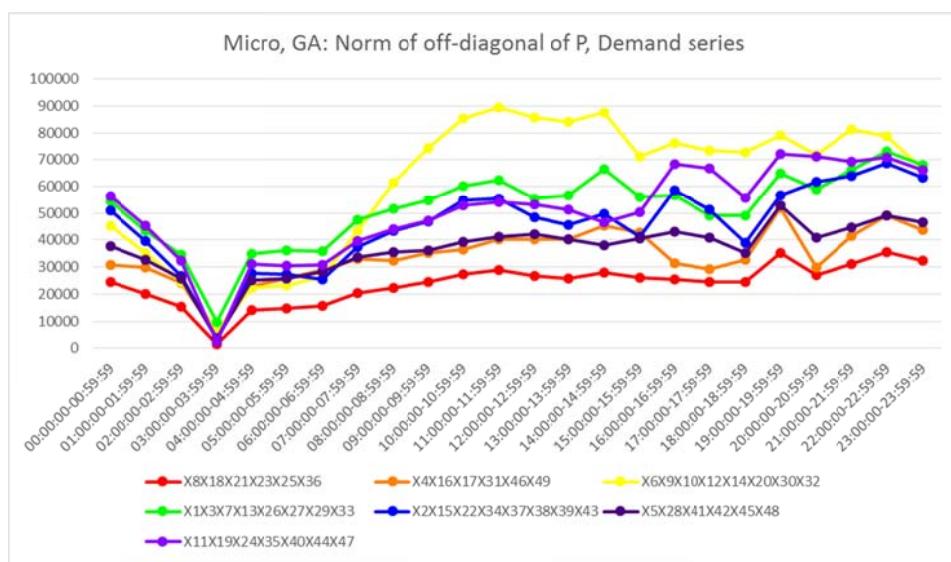


Fig.6-28 : Micro data 下基因演算規劃方法： $\|\check{\mathbf{Q}}\|_F$

## 基因演算規劃方法：目標函數為 $\|\check{\mathbf{M}}\|_F$

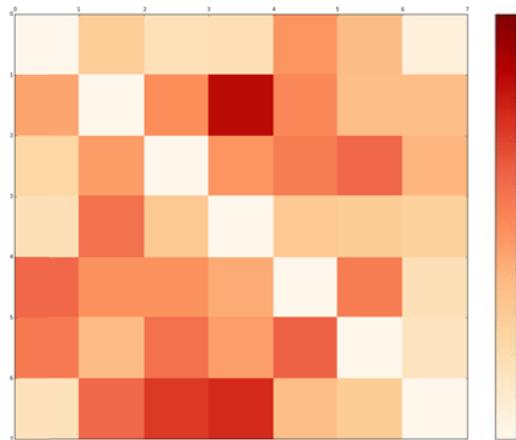
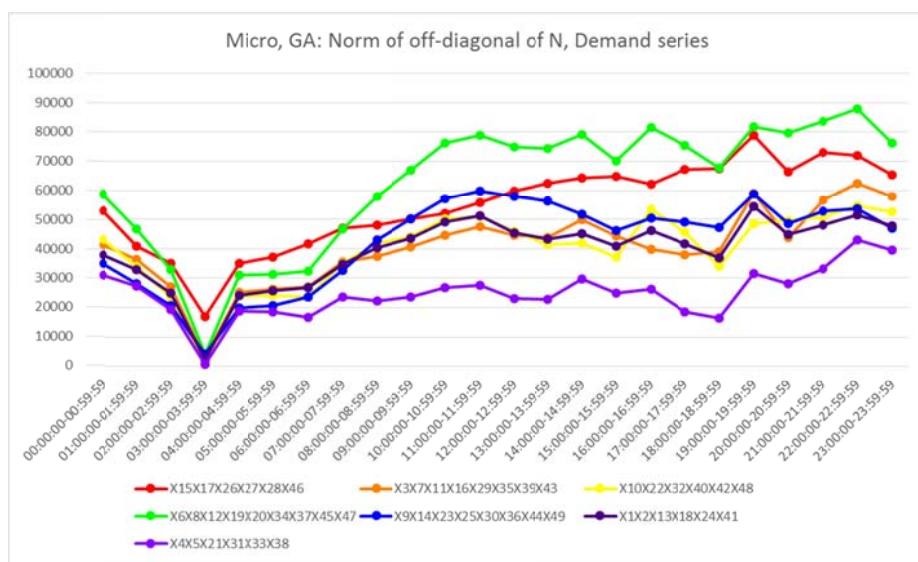


Fig.6-29 : Micro data 下基因演算規劃方法： $\|\check{\mathbf{M}}\|_F$