

題目：捷運流量樣態分析－利用K-means與時間序列模型尋找顧客群與分時預測

研究目的：

1. 設計方法統計捷運各站分時流量。
2. 利用時間序列模型預測捷運時流量。
3. 配合人口特徵資料找出捷運主要客群結構。
4. 針對不同群體制定商業活動，試圖達到精準行銷。

研究方法摘要：

1. 使用時間序列模型對捷運分時流量建模
2. 使用K-means分群找出客群結構

研究成果摘要：

1. 使用所建立之SARIMA模型可準確預測一日的流量(三周訓練資料)
2. 利用K-mean分出差異較大的五個族群，找出常用與不常用的捷運族群

隊名：三天沒洗澡

參賽者：黃歆貽、賴汶靖、朱峻弘、吳子耀

指導老師：黃禮珊

壹、問題陳述與題目訂定

近年交通流量的調查被視為重要之議題，不論是對於火車流量與票價間的探討、高速公路流量預測以研擬舒緩交通之配套措施，亦或是根據流量統計與預測提供用路人更好的規劃。而本研究希望透過分析捷運流量資料，進而預測捷運分時流量，並根據人口特徵資料找出捷運主要客群，針對不同群體應制定何種商業活動進行探討。

本研究以捷運流量為主要分析資料，研究目的如下：

1. 設計方法統計捷運各站時流量。
2. 利用時間序列模型預測捷運時流量。
3. 配合人口特徵資料找出捷運主要客群結構。
4. 針對不同群體制定商業活動，試圖達到精準行銷。

透過分析捷運 OD(Original Destination)資料統計出各站時流量，並透過時間序列模型預測各站時流量。此外，藉由捷運各站分時進站流量與各村里人口特徵資料，探討捷運搭乘客群，藉此制定合宜商業活動。為了達到上述之目的，本研究以 Dijkstra 演算法 統計捷運各站時流量、以含季節性時間序列模型(SARIMA)預測時流量、K-means 分群演算法 找出捷運搭乘客群。

因此，本研究之題目為「捷運流量樣態分析—利用 K-means 與時間序列模型尋找顧客群與分時預測」。

貳、資料介紹與處理

一、捷運分時 OD 資料

所使用的資料為台北捷運一月份每日分時各站 OD 統計資料，每筆資料所對應的時段為出站時間，以表一的最後一筆為例，代表 0:00~0:59 這段時間有 4 個人是從松山機場進站，內湖出站。總資料有 7,581,601 筆，當中共有 59,973,222 累積乘車人次，資料中共有 108 個站點。

表一、每日分時各站 OD 流量統計資料

日期	時段	進站	出站	人次
2017-01-01	00	松山機場	松山機場	0
2017-01-01	00	松山機場	中山國中	0
2017-01-01	00	松山機場	南京復興	0
2017-01-01	00	松山機場	忠孝復興	0
2017-01-01	00	松山機場	大安	0
2017-01-01	00	松山機場	科技大樓	1
2017-01-01	00	松山機場	六張犁	0
2017-01-01	00	松山機場	麟光	1
2017-01-01	00	松山機場	辛亥	0
2017-01-01	00	松山機場	萬芳醫院	2
2017-01-01	00	松山機場	萬芳社區	1
2017-01-01	00	松山機場	木柵	0
2017-01-01	00	松山機場	動物園	2
2017-01-01	00	松山機場	大直	1
2017-01-01	00	松山機場	劍南路	0
2017-01-01	00	松山機場	西湖	2
2017-01-01	00	松山機場	港墘	0
2017-01-01	00	松山機場	文德	1
2017-01-01	00	松山機場	內湖	4

圖一、台北捷運目前 107 站站點圖

假設進出站時間皆在同一時段，將 OD 資料轉換成每天各時段、站點與站點間目前的乘車人次資料。每一段區間都會依照上行、下行而有不同的箭頭方向，此步驟是將各日期、各時段的區間人次資料合併並統整。



圖二、OD 資料轉區間人次資料示意圖

但在整理 OD 資料與區間人次資料轉換時，其實並沒有這麼順利，一個起點、終點站只會有一種路線，藉由圖二也可以發現此事，例如從松江南京站到台北車站其實就有好多種不同的乘車方式，那若遇到這種多路線的乘車方式時，要怎麼將這筆資料轉換成區間累積人次是我們一開始面臨的一大挑戰。最終我們利用 Dijkstra 演算法 幫助我們找出兩個站點間的最短搭乘路徑，(這裡我們是假設相鄰兩站的距離皆相同下使用此演算法，之後也可以藉由得到各站點間實際搭乘時間、距離得到真實的距離權重)。

二、捷運進站時資料

表二、捷運時進站資料以 105 年 1 月為例(僅擷取部分)

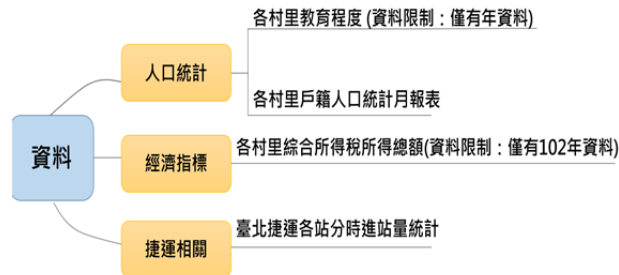
日期	時段	松山機場	中山國中	南京復興	忠孝復興	大安	科技大樓	六張犁	麟光	辛亥	萬芳醫院	萬芳社區	木柵	動物園	大直	劍南路	西湖	港墘	文德	內湖
2016/1/1	5	13	58	115	192	63	66	53	35	21	57	19	12	27	30	50	37	34	21	45
2016/1/1	6	37	144	313	457	212	222	207	124	41	166	47	81	70	130	105	108	115	50	156
2016/1/1	7	69	254	368	554	256	218	311	150	66	282	64	82	77	181	148	134	162	112	203
2016/1/1	8	127	346	458	646	432	330	344	162	136	425	99	115	102	198	175	152	212	172	257
2016/1/1	9	150	464	685	792	555	443	453	235	137	486	127	177	142	284	245	224	292	229	371
2016/1/1	10	403	659	918	1,125	698	497	557	296	192	664	153	189	292	344	379	287	357	257	430
2016/1/1	11	386	755	1,209	1,529	956	584	768	387	212	647	144	273	605	448	515	343	456	307	587
2016/1/1	12	403	749	1,242	1,962	887	549	604	329	168	669	169	310	799	420	542	381	360	312	541
2016/1/1	13	340	829	1,234	2,704	910	693	672	311	177	749	177	321	1,287	507	600	438	511	349	654
2016/1/1	14	424	903	1,545	3,873	995	709	705	281	174	677	168	360	1,589	512	844	506	540	281	600
2016/1/1	15	413	721	1,286	3,906	773	647	587	258	149	563	128	291	2,383	432	1,004	389	374	237	543
2016/1/1	16	465	691	1,350	4,201	795	596	491	232	165	488	115	311	3,486	435	1,239	342	422	294	558
2016/1/1	17	446	878	1,621	4,918	1,131	699	557	306	190	745	186	375	4,221	565	1,435	468	502	389	660
2016/1/1	18	335	679	1,530	4,670	890	618	500	207	127	565	125	421	1,563	472	1,066	348	465	290	535
2016/1/1	19	247	600	1,299	4,430	660	487	401	135	80	364	90	167	1,005	354	948	302	229	187	256
2016/1/1	20	201	481	1,310	4,626	671	379	416	87	57	233	59	194	600	270	954	273	228	139	220
2016/1/1	21	151	493	1,413	4,947	856	450	376	107	44	199	31	105	429	244	1,272	231	236	102	221
2016/1/1	22	155	268	956	4,651	579	290	264	62	29	150	31	25	215	219	1,005	122	167	73	127
2016/1/1	23	45	129	503	1,254	226	162	138	49	14	64	16	22	32	109	268	87	76	31	55
2016/1/1	0	8	26	110	243	43	23	21	7	7	3	2	4	10	29	59	18	13	2	13
2016/1/1	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2016/1/2	5	2	14	37	41	23	16	20	12	20	13	4	6	4	13	9	9	12	1	10
2016/1/2	6	31	80	130	171	87	91	119	50	39	110	29	32	29	55	47	57	71	43	87
2016/1/2	7	55	228	259	308	212	181	194	138	81	220	78	88	66	122	87	103	155	106	180
2016/1/2	8	160	465	460	599	390	316	353	197	134	448	106	141	156	183	214	199	256	176	332

105 年的捷運時進站資料如表二之格式，每站共有 7,694 筆資料，從每日上午 5 點至隔日凌晨 1 時，利用此資料各捷運站的進站人數分別將其分配至對應的村里，藉此與人口結構資料結合。然而，時捷運進站資料雖為每日早上 5 時至隔日凌晨 1 時，但是下午 5 時過後之進站，可

能是因為乘客在早上由某一站出站後，下午必須回程則有進站紀錄，若是這樣法將進站乘車的紀錄準確對應至各村里的人口特徵，因此我們排除下午 5 時以後之進站紀錄(即僅取用上午 5 時至下午 4 時之資料)。

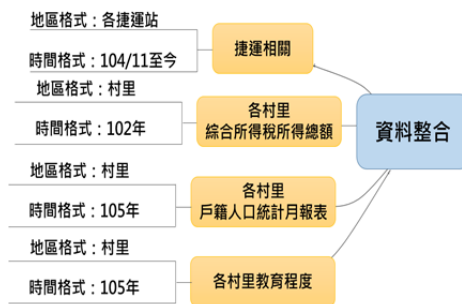
三、人口結構資料

除了上述所提及之 OD 資料，我們也希望能了解捷運的客群主要特徵為何，因此使用了 105 年的捷運時進站資料與人口特徵資料進而分析，原始資料介紹如圖三。



圖三、資料簡介

將台北捷運各站時進站量統計資料作為主軸，以人口統計資料包含各村里教育程度、各村里戶籍人口統計月報表，與衡量財富之各村里綜合所得稅所得總額之資料為輔，其中，各村里教育程度的資料僅有年資料，而綜合所得稅資料僅有 102 年之資料，接著我們將資料進行整合。



圖四、資料整合

由圖四可看出各資料之時間涵蓋範圍不同不一，捷運資料為 104/11 月至今、各村里綜所稅資料為 102 年年資料、各村里戶籍人口月報表為 105 年月資料、各村里教育程度為 105 年月資料。綜合上述資料，因此在整合資料時我們僅取 105 年作為主要分析之資料。而其中，捷運資料地區格式為各捷運站，為了能夠對應人口特徵資料，我們利用捷運站與村里之間的距離關係將各捷運站的流量分至新北市與台北市各村里。

分配方式如下：

- 計算各村里到與它最近之捷運站的距離。
- 根據各村里所對應之最近捷運站分類，舉例而言，若村里X、Y、Z最近捷運站皆為A站，則此三個村里則為同一類。
- 將同一類中之村里的距離反比分配所對應捷運站的流量，但距離超過1公里之村里則不分配流量。

此流量分配的假設基於距離捷運站越近的居民因為便利性，搭捷運的次數便較頻繁，此外若離捷運站過遠則假設其會優先選擇其他交通工具，因此不做流量之分配。

再者，為了後續模型建立與可解釋性，將資料進行處理並定義下列指標：

平均每人每月進站次數

經濟能力：綜合所得平均數。

平均教育程度：教育程度（加權平均計算）。

有偶比例：婚姻狀態。

性別比：女性人數/男性人數。

學生比例：8~24歲人數/總人數。

上班族比例：25~65歲人數/總人數。

表三、資料處理後之樣態

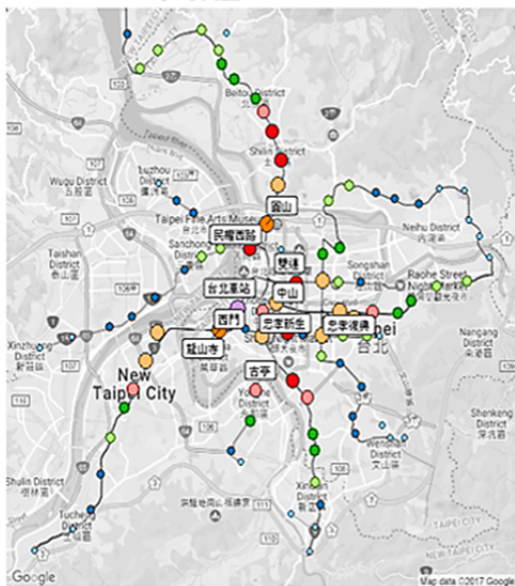
	行政區	村里	平均每人每月進站次數	性別比	青壯年比例	學生比例	有偶比例	總和所得平均數 (取Log後)	教育程度
1	三重區	二重里	8.015	0.447	0.556	0.671	0.16	0.009	0.11
2	三重區	三民里	3.796	0.481	0.53	0.633	0.258	0.134	0.261
3	三重區	三安里	16.051	0.58	0.651	0.357	0.512	0.092	0.203
4	三重區	大同里	24.285	0.61	0.854	0.361	0.566	0.121	0.276
5	三重區	大安里	12.279	0.454	0.515	0.606	0.337	0.053	0.109
6	三重區	大有里	2.367	0.492	0.81	0.46	0.222	0.083	0.232
7	三重區	大園里	6.381	0.454	0.488	0.519	0.311	0.105	0.177
8	三重區	大德里	28.539	0.622	0.639	0.326	0.447	0.106	0.154
9	三重區	中山里	24.131	0.533	0.629	0.518	0.442	0.155	0.305
10	三重區	中央里	13.898	0.484	0.678	0.316	0.526	0.093	0.15
11	三重區	中正里	71.302	0.45	0.797	0.345	0.382	0.12	0.171
12	三重區	中民里	26.881	0.451	0.689	0.479	0.391	0.044	0.106
13	三重區	中興里	32.874	0.447	0.693	0.476	0.314	0.114	0.231
14	三重區	五谷里	93.364	0.352	0.695	0.42	0.392	0.141	0.191
15	三重區	五常里	3.025	0.506	0.587	0.578	0.134	0.052	0.145
16	三重區	五華里	2.075	0.584	0.66	0.552	0.301	0.215	0.278
17	三重區	五順里	3.387	0.47	0.617	0.606	0.208	0.052	0.116
18	三重區	五福里	3.221	0.587	0.749	0.403	0.389	0.175	0.255
19	三重區	仁忠里	4.188	0.497	0.706	0.438	0.291	0.01	0.073
20	三重區	仁華里	10.347	0.531	0.784	0.416	0.302	0.109	0.215

我們將資料整理為如上表之型態，在每個村里中，計算相對應的人平均每月進站次數、性別比、青壯年比例、學生比例、有偶比例、綜合所得平均數、教育程度，共七個指標。為了後續分群模型建立，將資料皆做適當的標準化處理，使各指標藉由0到1之間。

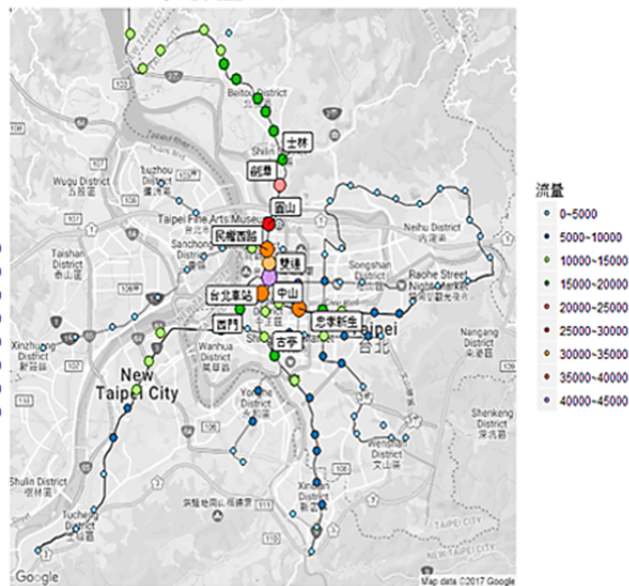
四、資料視覺化呈現

將資料處理與整合完畢後，我們將台北捷運每日分時各站 OD 統計資料與 105 年捷運時進站資料利用圖像化的方式呈現。

2017-01-06 18 時 總流量



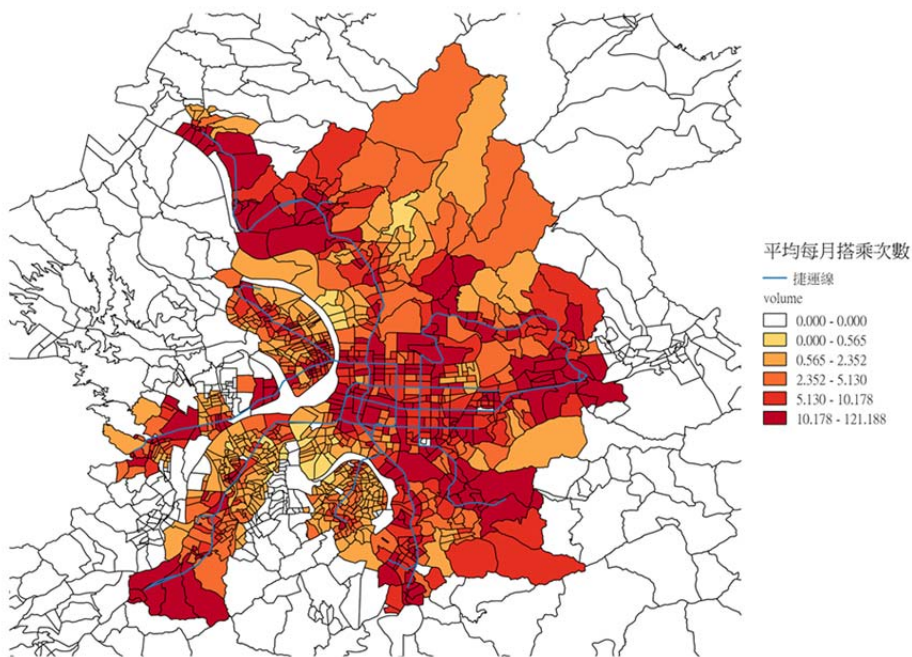
2017-01-29 18 時 總流量



圖五、分時 OD 資料—以 106 年 1 月 6 日 18 時為例

圖六、分時 OD 資料—106 年 1 月 29 日 18 時為例

由圖五與圖六為將各站分時 OD 資料整理後的視覺化呈現，其中有特別標示出來的捷運站為當時流量前十大的捷運站，106 年 1 月 29 日為過年初二，由圖中可發現平日與過年期間流量有所差異，平日捷運流量多分布於淡水線與板南線，而過年期間流量多分布於淡水線，我們推測此結果可能是因板南線沿線多商業區域，平日必須至板南線沿線上班所造成之緣故。因為上述原因，在後續資料分析時我們將過年期間視為特殊節日將其排除。



圖七、各村里對應之人平均每月搭乘次數

將資料藉由前述所述之 105 年捷運進站時流量分配後，其結果呈現如圖七。藍線代表為捷運線，而顏色深淺分別為各村里對應之人平均每月搭乘次數。由圖七可看出捷運沿線之村里平均每月搭乘次數普遍較非捷運沿線者高，主要是因在處理資料時，我們利用距離來分配各捷運站之流量。然後各村里人口數與各捷運站流量不盡相同，因此距離並非唯一決定各村里人平均每月搭乘次數之因素。

參、方法介紹

一、Seasonal ARIMA (SARIMA) Model

SARIMA 是時間序列模型中常用的模型之一，由於時間序列資料經常伴隨著很強的季節周期性，例如星期、月份或者是年份，因此將季節週期性(Seasonal)的因素加入差分整合移動平均自迴歸模型(ARIMA Model)中。一般來說，會將 SARIMA 模型寫做， $SARIMA(p,d,q)(P,D,Q)_s$ ，其中 AR 是"自回歸"， p 為自回歸項數，MA 為「移動平均」， q 為移動平均項數， d 為使之成為平穩序列所做的差分次數(階數)； P 為季節性的自回歸項數， Q 為季節性的移動平均項數， D 為季節性的差分次數，而 s 就是季節性的週期。

SARIMA 的模型如下：

$$\left(1 - \sum_{i=1}^p \varphi_i B^i\right) \left(1 - \sum_{i=1}^P \Phi_i B^{im}\right) (1 - B)^d (1 - B^{Ds}) y_t = \left(1 + \sum_{i=1}^q \theta_i B^i\right) \left(1 + \sum_{i=1}^Q \Theta_i B^{im}\right) \epsilon_t$$

其中， y_t 是在時間 t 的資料， B 為滯後算子(Lag operator)，也就是 $B^1(y_t) = y_{t-1}$ ， φ_i 、 Φ_i 、 θ_i 以及 Θ_i 是不為零的常數， ϵ_t 為誤差項。

二、K-means

K-means 為一廣為人知的分群演算法，主要是將資料集分成 K 個不重疊的群體。因此在使用 K-means 分群演算法上，第一步便是事先決定 K ，便會依照所指定的 K ，將所有的資料點分為 K 個群體。為了說明 K-means 分群演算法的流程，我們先行定義： C_1, \dots, C_k 為每個群體內觀測值的子集合，且需滿足以下兩個條件：

1. $C_1 \cup C_2 \cup \dots \cup C_k = \{1, \dots, n\}$ ，即每個觀測值至少必須屬於一個群體。
2. $C_k \cap C_{k'} = \emptyset, \forall k \neq k'$ ，即每個群體不重疊。

綜合以上兩個條件，可得每個觀測值僅能屬於其中一個群體。

K-means 分群演算法實行流程是將 n 個觀測值分到 K 個集合中，其中 $K \leq n$ ，使組內平方和(WCSS, within-cluster sum of squares)最小。換句話說，便是需要滿足以下之式子：

$$\min_C \sum_{k=1}^K N_k \sum_{C(i)=k} \|x_i - \bar{x}_k\|^2$$

其中 \bar{x}_k 為各群平均， $N_k = \sum_{i=1}^n I(C(i) = k)$ 。

演算法步驟如下：

1. 隨機分配觀測值到 K 個群體。
2. 給定 K 的個數。
3. 算出各群的中心點並計算組內平方和。
4. 將距離各群中心點最近的觀測值分至各群。
5. 重複步驟 3 與 4 直到組內平方和收斂。


肆、模型建立

一、Seasonal ARIMA (SARIMA) Model


在找尋適當的 SARIMA 模型參數時，最常用的就是去看資料的 ACF(Auto-Correlation Function)與 PACF(Partial Auto-Correlation Function)這兩張圖，透過圖八與圖九，我們可以看到 ACF 有遞減的趨勢，和明顯的週期性(s =21，每日的捷運資料，共 21 個小時)，而 PACF 則在 p =4 時有明顯的截斷(cut off)，在季節性的自迴歸項則是在 P =2 時截斷。因此，我們選擇了 SARIMA(4,0,0) (2,0,0)₂₁ 來建置時間序列的流量預測模型。

表四、模型系數與標準差

Coefficients:							
	AR1	AR2	AR3	AR4	SAR1	SAR2	Intercept
Estimator	1.1410	-0.7646	0.4366	-0.1890	0.8705	0.0200	5881.0628
S.E.	0.0477	0.0690	0.0693	0.0472	0.0493	0.0506	868.1422




圖八、ACF 結果



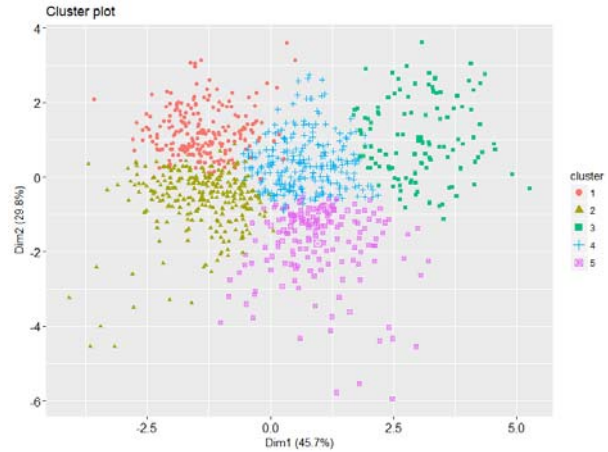
圖九、PACF 結果

二、K-means

在執行 K-means 演算法中，決定多少個群體為第一步驟，此步驟會影響分群後的解釋與結果，因此亦可視為最重要的一步。我們藉由畫出不同 K 之下的總組內平方和來決定群數。



圖十、群體之總組內平方和



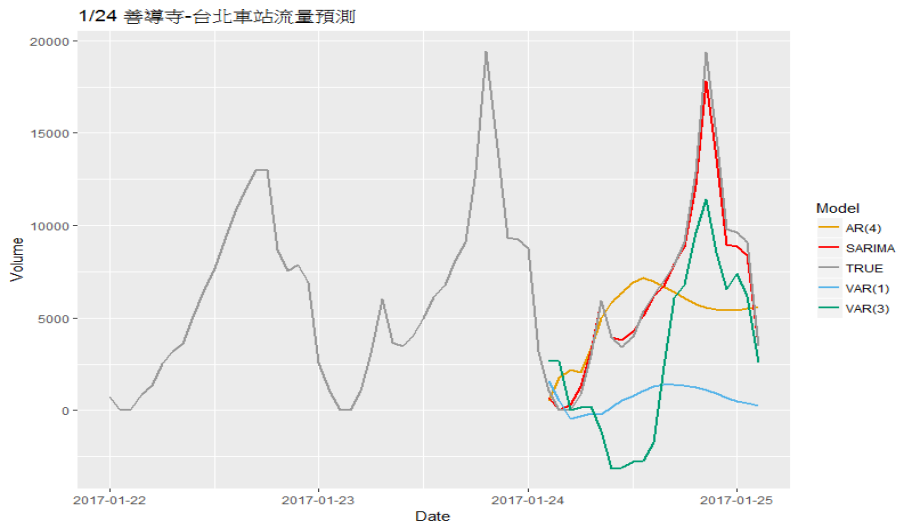
圖十一、分群結果

由圖十可以發現在 $K=5$ 之後所下降之組內平方和並不多，因此我們將群數設定為 5 群。此外，將觀察值投影至將原變數藉由主成分分析法(PCA, Principal Component Analysis)後所得之主成分 1 與 2，並將各觀測值分群結果標示(如圖十一)。由圖中可看出 5 群所對應的相對位置，群與群之間略有重疊的部分，但分群的輪廓大致清楚，而我們是將高維度的觀測值投影至平面，僅能看出在取 $K=5$ 的情況下是否將觀測值做一合理之分群，但不易分群結果有一好的解釋與分析，甚至亦無法將各群命名，因此我們在下一章節會利用其他圖像化的方式對分群結果有完整的呈現與分析。

伍、結果呈現

一、時間序列模型一日分時預測


我們除了使用 SARIMA(4,0,0) (2,0,0)₂₁ 作為預測模型外，也嘗試使用其他時間序列的預測模型，從圖十的預測結果可以發現，SARIMA 的預測結果與真值最為接近，其餘的模型基本上都沒有抓到真值曲線的樣貌，其原因我們認為是與季節性變動(天)有很大的關係。SARIMA 可以從季節性變動的特性學習到過往的曲線樣貌，但其他的模型因為沒有學習到季節性變動的這個特徵，所以預測出來的結果都會與真值差距甚遠。




圖十二、各模型在 1 月 24 日的預測結果

二、K-means 分群結果

由下圖，我們可以看到第一群的特徵是教育程度低、經濟能力低、有偶比例低，而學生比例高，因此推測這群人很可能是國中或國小學生，將這群稱作「年幼學童」。第二群教育程度與經濟能力低，學生比例少了一點，但青壯年比例高了一些，將這群稱為「收入較低上班族」。第三群的特徵很明顯的是教育程度跟經濟能力高的一群，青壯年比例低，但學生比例只比平均高一些，所以這群可能包含了老年人口(65 歲以上)，而女性比例多了一些，可以將這群稱為「經濟能力好的高知識非上班族女性」。第四群的特徵大多在平均值附近，只有教育程度是高一些的，我們將這群稱為「一般大眾」。第五群的特徵較為明顯，學生比例(8 到 24 歲人口)少、青壯年(25 到 65 歲人口)比例高，而有偶比例也高，可以將這群稱作「已婚上班族」。



圖十三、全部群體圖



圖十四、分群結果—第一群體



圖十五、分群結果—第二群體




圖十六、分群結果—第三群體



圖十七、分群結果—第四群體



圖十八、分群結果—第五群體



圖十九、各群每月搭乘捷運次數的盒狀圖

表五、各群每月搭乘捷運次數

分群	平均一個月搭捷運次數 (中位數)
總	8.459 (mid=5.037)
(1) 年幼學童	6.595 (mid=3.610)
(2) 收入較低上班族	11.624 (mid=8.544)
(3) 經濟能力好的高 知識非上班族女性	10.721 (mid=6.860)
(4) 一般大眾	10.909 (mid=6.557)
(5) 已婚上班族	6.243 (mid=3.398)

從圖十九中我們可以看出每個客群搭乘捷運的次數雖然都有一些離群值，但第 2、3、4 群的平均搭乘次數是比第 1、5 群高的。

而由表五，不論是由平均數或中位數來看，第 2、3、4 群的搭乘次數是較全部人的次數高，而第 1、5 群則比全部人的低。而我們的解釋為，第一群人因為主要為國中國小的學生，而這群學生的學校通常就在家附近，不需使用捷運，所以不常搭乘是合理的；第二群人因為是經濟能力較低的上班族，所以可能經常以捷運等大眾運輸工具為通勤方式上下班。第三群人的搭乘次數高可能是因為，這一群人為教育程度高學生或年長女性，因為並非上班族，所以這群的經濟能力應該是家庭的經濟能力而非工作收入，而學生較常搭捷運是合理的，而年長女性也通常是搭乘大眾運輸工具的；第四群人因為是普通的上班族及學生，所以經常使用捷運是合理的；第五群人是已結婚的青壯年人口或是上班族，搭乘捷運次數較低的原因可能為上彎是與配偶開

車出門，或是因為要帶小孩去學校而開車；

陸、後續改善

在建立模型時，我們有試著把其他影響因素，如氣溫、雨量等，放入模型中進行預測，但結果都與只使用時間序列模型的結果沒有太多的差別，這可能是因為目前我們只拿 2017 年一月份的資料作分析與預測，因此導致我們資料數不夠多，不足以用假設檢定來驗證是否氣溫低與降雨真的會影響區間累積人次的多寡。

柒、未來展望與結論

- 1. 輔助交通決策：**了解該時段該路線乘客流量，各站進出站人數，有利於進行各種決策。例如，可在預測流量大之車站，即時增加公眾運輸的量，以紓解人潮。
 - 2. 增進區域治理安全：**不管是無意或是蓄意，日常違規、甚至犯罪行為往往發生在相對壅擠的區域。從乘客爭吵到嚴重如捷運鄭捷慘案、國際恐怖攻擊，人群聚集之地總是首選。如果能夠透過此訊息，作為增減警備人員的依據，機動調派人力，除了使效率極大化，亦能有效降低事故發生率。
 - 3. 搭乘參考：**使乘客可以依照該捷運站壅塞程度，選擇要不要搭乘（例如，因為害怕大眾運輸壅擠，而不搭乘的孕婦、年長者、傷患等等，同樣的，他們能藉由此選擇較通暢的時段搭乘；或是原本預期搭計程車，發現捷運沒什麼人而去搭，提高捷運搭乘率）。
 - 4. 提高經濟效益：**常見之商業行為，如發傳單、街頭藝人等，可透過使用捷運的使用人口結構來規劃要進行的內容，如因為年長女性經嘗試用捷運，所以可以放置許多與日常生活較相關的廣告宣傳。公司規模的活動，亦可有效利用此資訊，挖掘潛在訊息，便於擬定各項財務決策，降低企業風險與提高獲利可能，像是捷運站(非車上)的廣告，若是以知道哪幾站的使用人口結構為公司的主要顧客群，就可以只買那幾站的廣告權，減少成本。
- 除此之外，捷運公司也可以利用浮動票價的方式提供優惠方案，提高捷運的載客率；而在載客數過量的時段，也可以藉由提早預知而實施良好的配套措施，提供乘客一個更舒適的乘車環境。