109-1: EE4052

通識課程：計算機程式設計之旅

Computer Programming

Unit 15: 資料連結分析

連 豐 力

臺大電機系

Sep 2020 - Jan 2021

課程主題進度

- **U01:** 課程介紹：討論主題，作業，報告，進行方式
- **U02:** 主題，案例，程式，演算法，資源
- **U03:** 設定軟體 R 與 Rstudio
- **U04:** 數據處理與繪圖指令功能
- **U05:** 資料類別與基本運算
- **U06:** 邏輯判斷與流程控制
- **U07:** 函數：計算與排序
- **U08:** 多維度資料格式
- **U09:** 檔案資料輸入與輸出
- **U10:** 繪圖功能與文字
- **U11:** 多重繪圖與顏色
- **U12:** 影像與動畫
- **U13:** 資料間的相關性
- **U14:** 探索性資料分析
- **U15:** 資料連結分析

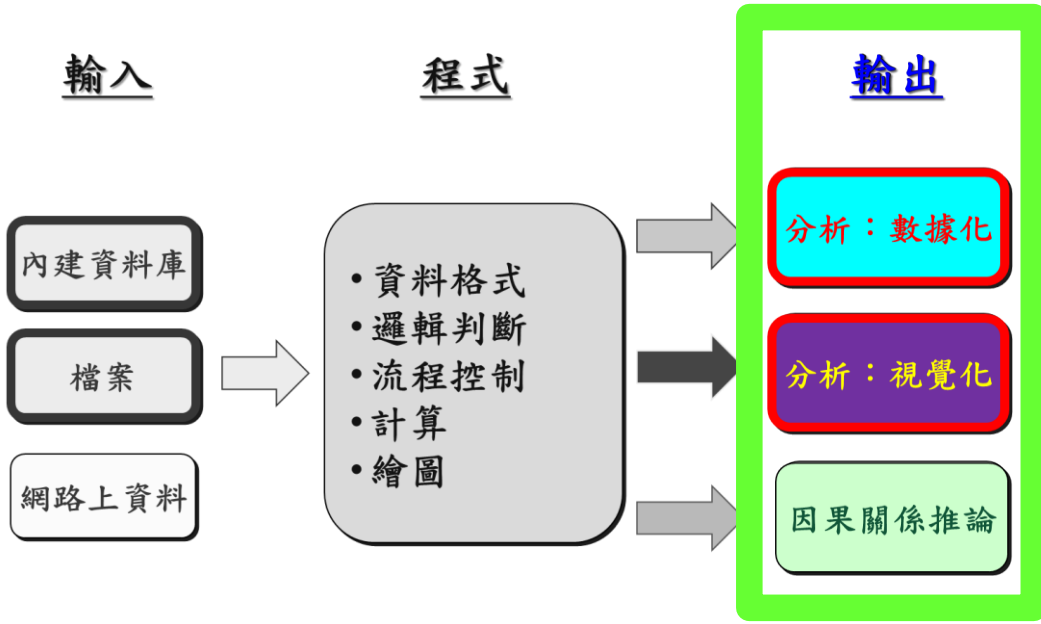

啤酒與尿布的關係

- 1990年代，美國零售龍頭業者沃爾瑪 (Wal-Mart) 的資訊工程師，
  在分析結帳數據時發現，
  每到星期五晚上，尿布和啤酒的銷售量有正向關聯性。
- 透過調查才知道，原來，美國的婦女通常在家照顧孩子，
  所以她們經常會囑咐丈夫在下班回家的路上為孩子買尿布，
  而丈夫在買尿布的同時又會順手購買自己愛喝的啤酒。
- 而且，就時間上來看，特別是在週五晚上，
  父親常常幫家裡到超市買尿布，
  順便為週末球賽會購買啤酒回家。
- 後來沃爾瑪採取合購策略，固定在每週五，
  啤酒和尿布擺設放在同一區域，
  意外讓這兩項產品的銷售量提升30%。

大綱

- 基本元素：連結規則，支持度，可靠度，提升度
- 軟體套件，核心函數，資料集
- 對產生規則進行強度控制，
  - 透過支持度，可靠度共同控制
  - 主要透過支持度控制
  - 主要透過可靠度控制
  - 主要透過提升度控制
- 改變輸出結果形式
- 連結規則的視覺化

大綱

基本元素：

連結規則

支持度

可靠度

提升度

連結規則

- 連結規則 (Association Rule)：
- 一般記為： X -> Y 的形式，用於表示資料內隱含的連結性。
- X ：先決條件，Y：對應連結結果，
- 例如：連結規則：尿布 -> 啤酒，

  表示：購買了尿布的消費者常常也會購買啤酒，

  即是這兩個購買行為之間具有一定連結性。
- 至於連結性的強度，會用：支持度，可靠度，提升度，

  等三個核心概念，來控制與評價。
- 以下，以一個數據來說明這三個概念：

  10000 個消費者，1000 個購買尿布，2000 個購買啤酒，500 個購買麵包，

  800 個同時購買尿布與啤酒，100 個同時購買尿布與麵包。

連結規則 -支持度

- 支持度 (Support)：
- 指的是：{ X, Y } 出現的可能性，即同時包含 X 與 Y 的機率：

  Support(X -> Y) = P(X, Y)
- 用以衡量所有連結規則在『量』上的多少。
- 利用最小支持度設定值 (minsup, minimum support)

  來剔除那些較低出現率的無意義規則，

  而保留下出現較為頻繁資料所隱含的規則：

  Support({X, Y}) >= minsup
- 例如：minsup = 5%，{尿布，啤酒}的支持度 = 800/10000 = 8%，

  {尿布，麵包}的支持度 = 100/10000 = 1%，
- 所以，{尿布，啤酒} 滿足了基本的數量要求，成為頻繁的集合，

  則：尿布 -> 啤酒 與 啤酒 -> 尿布，兩個規則被保留。

連結規則 - 可靠度

- 可靠度 (Confidence)：
- 表示在連結規則的先決條件 X 發生的條件下，連結結果 Y 發生的機率：

  Confidence (X -> Y) = P(Y | X) = P(X, Y) / P(X)
- 用以衡量所有連結規則在『質』上的可用性。
- 利用最小可靠度的設定值 (mincon, minimum confidence)

  來實現一些篩選，滿足：

  Confidence (X -> Y) >= mincon
- 例如：mincon = 70%，

  尿布 -> 啤酒 的可靠度= 800/1000 = 80%，

  啤酒 -> 尿布的可靠度= 800/2000 = 40%，
- 所以，尿布 -> 啤酒 滿足要求，被篩選出來的一個強連結規則。

連結規則 - 提升度

- 提升度 (Lift)：
- 表示在含有 X 的條件下，同時含有 Y 的可能性，

  與沒有這個條件下，含有 Y 的可能性之比值。

  Lift (X -> Y) = P(Y | X) / P(Y) = Confidence (X -> Y) / P(Y)
- 用以衡量所有連結規則在『質』上的可用性，與可靠度為互補指標。
- 例如：1000 個消費者，500 人購買茶葉，其中有 450 人同時購買咖啡。

  另外，50 人沒有，
- 由於 ，茶葉 -> 咖啡 的可靠度：450/500 = 90%，相當高，
- 但是：如果沒有購買茶葉的 500 人，其中同樣也有 450 人也同時購買咖啡，其可靠度也是：90%。
- 由此看來：是否購買咖啡，與有沒有購買茶葉並沒有連結，兩者是獨立的，

  其提升度為：90% / [(450 + 450) / 1000] = 1 (相互獨立)

連結規則

- 選出滿足支持度最小設定值的所有集合，即為：頻繁集合：
  - 一般設定值為： 5% ~ 10 %。
- 從頻繁集合中找出滿足最小可靠度的所有規則：
  - 通常可靠度的設定值為：70% ~ 90%。

大綱

軟體套件

核心函數

資料集

軟體套件 與 核心函數

- 專用於連結分析的軟體套件：arules 與 arulesViz
- Apriori 和 Eclat：兩個快速採擷頻繁集合與連結規則演算法的實現函數。
- install.packages("arules") # 安裝 arules 軟體套件
- library(arules) # 載入 arules 軟體套件

- apriori(data, parameter = NULL, appearance = NULL, control = NULL)
- eclat(data, parameter = NULL, control = NULL)

- parameter: support = 0.1, confidence = 0.8, maxlen = 10, minlen = 1, target = “rules” / ”frequent itemsets”
- appearance: X (lhs = “beer”), Y (rhs = “milk”)
- control: sort = 1 (昇), sort = -1 (降)

資料集

- library(arules) # 載入 arules 軟體套件
- data("Groceries") # 取得 Groceries 資料集
- summary(Groceries)

```
> summary( Groceries )

transactions as itemMatrix in sparse format with
 9835 rows (elements/itemsets/transactions) and
 169 columns (items) and a density of 0.02609146

most frequent items:
      whole milk other vegetables       rolls/buns             soda           yogurt          (Other)
            2513             1903             1809             1715             1372            34055

element (itemset/transaction) length distribution:
sizes
   1    2    3    4    5    6    7    8    9   10   11   12   13   14   15   16   17   18   19   20
2159 1643 1299 1005  855  645  545  438  350  246  182  117   78   77   55   46   29   14   14    9
  21   22   23   24   26   27   28   29   32
  11    4    6    1    1    1    1    3    1

   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
  1.000   2.000   3.000   4.409   6.000  32.000

includes extended item information - examples:
       labels  level2           level1
1 frankfurter sausage meat and sausage
2     sausage sausage meat and sausage
3  liver loaf sausage meat and sausage
```

資料集

- inspect(Groceries[1:10])

```
> inspect( Groceries[ 1:10 ] )

     items

[1]  {citrus fruit,semi-finished bread,margarine,ready soups}
[2]  {tropical fruit,yogurt,coffee}
[3]  {whole milk}
[4]  {pip fruit,yogurt,cream cheese ,meat spreads}
[5]  {other vegetables,whole milk,condensed milk,long life bakery product}
[6]  {whole milk,butter,yogurt,rice,abrasive cleaner}
[7]  {rolls/buns}
[8]  {other vegetables,UHT-milk,rolls/buns,bottled beer,liquor (appetizer)}
[9]  {pot plants}
[10] {whole milk,cereals} 1
```

資料集

- rules0 <- apriori(Groceries, parameter = list(support = 0.001, confidence = 0.5))

```
Apriori

Parameter specification:
 confidence minval smax arem  aval originalSupport maxtime support minlen maxlen target   ext
        0.5    0.1    1 none FALSE            TRUE       5   0.001      1     10  rules FALSE

Algorithmic control:
 filter tree heap memopt load sort verbose
    0.1 TRUE TRUE  FALSE TRUE    2    TRUE

Absolute minimum support count: 9

set item appearances ...[0 item(s)] done [0.00s].
set transactions ...[169 item(s), 9835 transaction(s)] done [0.00s].
sorting and recoding items ... [157 item(s)] done [0.00s].
creating transaction tree ... done [0.00s].
checking subsets of size 1 2 3 4 5 6 done [0.01s].
writing ... [5668 rule(s)] done [0.00s].
creating S4 object  ... done [0.00s].
```

資料集

- rules0
- inspect(rules0[1:10])

```
> rules0

set of 5668 rules

> inspect( rules0[ 1:10 ] )

     lhs                    rhs                  support     confidence lift
[1]  {honey}                => {whole milk}       0.001118454 0.7333333  2.870009
[2]  {tidbits}              => {rolls/buns}       0.001220132 0.5217391  2.836542
[3]  {cocoa drinks}         => {whole milk}       0.001321810 0.5909091  2.312611
[4]  {pudding powder}       => {whole milk}       0.001321810 0.5652174  2.212062
[5]  {cooking chocolate}    => {whole milk}       0.001321810 0.5200000  2.035097
[6]  {cereals}              => {whole milk}       0.003660397 0.6428571  2.515917
[7]  {jam}                  => {whole milk}       0.002948653 0.5471698  2.141431
[8]  {specialty cheese}     => {other vegetables} 0.004270463 0.5000000  2.584078
[9]  {rice}                 => {other vegetables} 0.003965430 0.5200000  2.687441
[10] {rice}                 => {whole milk}       0.004677173 0.6133333  2.400371
```

大綱

對規則的控制

透過支持度，可靠度共同控制

- support: 0.001 -> 0.005
- rules1 <- apriori(Groceries, parameter = list(support = 0.005, confidence = 0.5))
- rules1

```
> rules1

set of 120 rules
```

- confidence: 0.5 -> 0.6
- rules2 <- apriori(Groceries, parameter = list(support = 0.005, confidence = 0.6))
- rules2

```
> rules2

set of 22 rules
```

- confidence: 0.6 -> 0.64
- rules3 <- apriori(Groceries, parameter = list(support = 0.005, confidence = 0.64))
- rules3

```
> rules3

set of 4 rules
```

透過支持度，可靠度共同控制

- Support = 0.005, confidence = 0.64
- rules3 <- apriori(Groceries, parameter = list(support = 0.005, confidence = 0.64))
- rules3
- inspect(rules3)

```
> rules3

set of 4 rules
```

```
> inspect( rules3 )

    lhs                                                rhs          support     confidence lift

[1] {butter,whipped/sour cream}                     => {whole milk} 0.006710727 0.6600000  2.583008
[2] {pip fruit,whipped/sour cream}                  => {whole milk} 0.005998983 0.6483516  2.537421
[3] {pip fruit,root vegetables,other vegetables}    => {whole milk} 0.005490595 0.6750000  2.641713
[4] {tropical fruit,root vegetables,yogurt}         => {whole milk} 0.005693950 0.7000000  2.739554
```

主要透過支持度控制

- rules.sorted_sup <- sort(rules0, by = "support")
- inspect(rules.sorted_sup[1:5])

```
> inspect( rules.sorted_sup[ 1:5 ] )

    lhs                                     rhs          support    confidence lift

[1] {other vegetables,yogurt}            => {whole milk} 0.02226741 0.5128806  2.007235
[2] {tropical fruit,yogurt}              => {whole milk} 0.01514997 0.5173611  2.024770
[3] {other vegetables,whipped/sour cream} => {whole milk} 0.01464159 0.5070423  1.984385
[4] {root vegetables,yogurt}             => {whole milk} 0.01453991 0.5629921  2.203354
[5] {pip fruit,other vegetables}         => {whole milk} 0.01352313 0.5175097  2.025351
```

主要透過可靠度控制

- rules.sorted_con <- sort(rules0, by = "confidence")
- inspect(rules.sorted_con[1:5])

```
> inspect( rules.sorted_con[ 1:5 ] )

    lhs                                          rhs          support     confidence lift

[1] {rice,sugar}                              => {whole milk} 0.001220132 1          3.913649
[2] {canned fish,hygiene articles}            => {whole milk} 0.001118454 1          3.913649
[3] {root vegetables,butter,rice}             => {whole milk} 0.001016777 1          3.913649
[4] {root vegetables,whipped/sour cream,flour} => {whole milk} 0.001728521 1          3.913649
[5] {butter,soft cheese,domestic eggs}        => {whole milk} 0.001016777 1          3.913649
```

主要透過提升度控制

- rules.sorted_lift <- sort(rules0, by = "lift")
- inspect(rules.sorted_lift[1:5])

```
> inspect( rules.sorted_lift[ 1:5 ] )

    lhs                                  rhs                 support     confidence lift

[1] {Instant food products,soda}      => {hamburger meat} 0.001220132 0.6315789  18.99565
[2] {soda,popcorn}                    => {salty snack}    0.001220132 0.6315789  16.69779
[3] {flour,baking powder}             => {sugar}          0.001016777 0.5555556  16.40807
[4] {ham,processed cheese}            => {white bread}    0.001931876 0.6333333  15.04549
[5] {whole milk,Instant food products} => {hamburger meat} 0.001525165 0.5000000  15.03823
```

主要透過三度的控制


```
> inspect( rules.sorted_sup[ 1:5 ] )

    lhs                                    rhs          support    confidence lift

[1] {other vegetables,yogurt}           => {whole milk} 0.02226741 0.5128806  2.007235
[2] {tropical fruit,yogurt}             => {whole milk} 0.01514997 0.5173611  2.024770
[3] {other vegetables,whipped/sour cream} => {whole milk} 0.01464159 0.5070423  1.984385
[4] {root vegetables,yogurt}            => {whole milk} 0.01453991 0.5629921  2.203354
[5] {pip fruit,other vegetables}        => {whole milk} 0.01352313 0.5175097  2.025351
```

```
> inspect( rules.sorted_con[ 1:5 ] )

    lhs                                          rhs          support     confidence lift

[1] {rice,sugar}                              => {whole milk} 0.001220132 1          3.913649
[2] {canned fish,hygiene articles}            => {whole milk} 0.001118454 1          3.913649
[3] {root vegetables,butter,rice}             => {whole milk} 0.001016777 1          3.913649
[4] {root vegetables,whipped/sour cream,flour} => {whole milk} 0.001728521 1          3.913649
[5] {butter,soft cheese,domestic eggs}        => {whole milk} 0.001016777 1          3.913649
```

```
> inspect( rules.sorted_lift[ 1:5 ] )

    lhs                                  rhs              support     confidence lift

[1] {Instant food products,soda}      => {hamburger meat} 0.001220132 0.6315789  18.99565
[2] {soda,popcorn}                    => {salty snack}    0.001220132 0.6315789  16.69779
[3] {flour,baking powder}             => {sugar}          0.001016777 0.5555556  16.40807
[4] {ham,processed cheese}            => {white bread}    0.001931876 0.6333333  15.04549
[5] {whole milk,Instant food products} => {hamburger meat} 0.001525165 0.5000000  15.03823
```

一個例子

- 想要瞭解芥末 (mustard) 的連結規則？

- rules4 <- apriori(Groceries, parameter = list(maxlen = 2, support = 0.001, confidence = 0.1), appearance = list(rhs = "mustard", default = "lhs"))
- rules4
- inspect(rules4)

```
> inspect( rules4 )
    lhs             rhs       support     confidence lift
[1] {mayonnaise} => {mustard} 0.001423488 0.1555556  12.96516
```

大綱

改變輸出結果形式

改變輸出結果形式

- 想要知道銷售量最高的商品？
- itemsets_apr <- apriori(Groceries, parameter = list(support = 0.001, target = "frequent itemsets"), control = list(sort = -1))
- itemsets_apr
- inspect(itemsets_apr[1:5])

```
> itemsets_apr

set of 13492 itemsets

> inspect( itemsets_apr[ 1:5 ]  )

    items                support
[1] {whole milk}         0.2555160
[2] {other vegetables}   0.1934926
[3] {rolls/buns}         0.1839349
[4] {soda}               0.1743772
[5] {yogurt}             0.1395018
```

改變輸出結果形式

- 想要知道綑綁銷售策略在哪些商品中作用最顯著？
- itemsets_ecl <- eclat(Groceries, parameter = list(minlen = 1, maxlen = 3, support = 0.001, target = "frequent itemsets"), control = list(sort = -1))
- itemsets_ecl
- inspect(itemsets_ecl[1:5])

```
> itemsets_ecl

set of 9969 itemsets

> inspect( itemsets_ecl[ 1:5 ]  )

    items                          support

[1] {whole milk,honey}             0.001118454
[2] {whole milk,cocoa drinks}      0.001321810
[3] {whole milk,pudding powder}    0.001321810
[4] {tidbits,rolls/buns}           0.001220132
[5] {tidbits,soda}                 0.001016777
```

大綱

連結規則的視覺化

連結規則的視覺化

- 視覺化軟體套件：arulesViz
- install.packages("arulesViz")　　# 安裝 arulesViz 軟體套件
- library(arulesViz)　　# 載入 arulesViz 軟體套件

- rules5 <- apriori(Groceries, parameter = list(support = 0.002, confidence = 0.5))
- rules5
- plot(rules5)
- # 散點圖：支持度 vs 可靠度

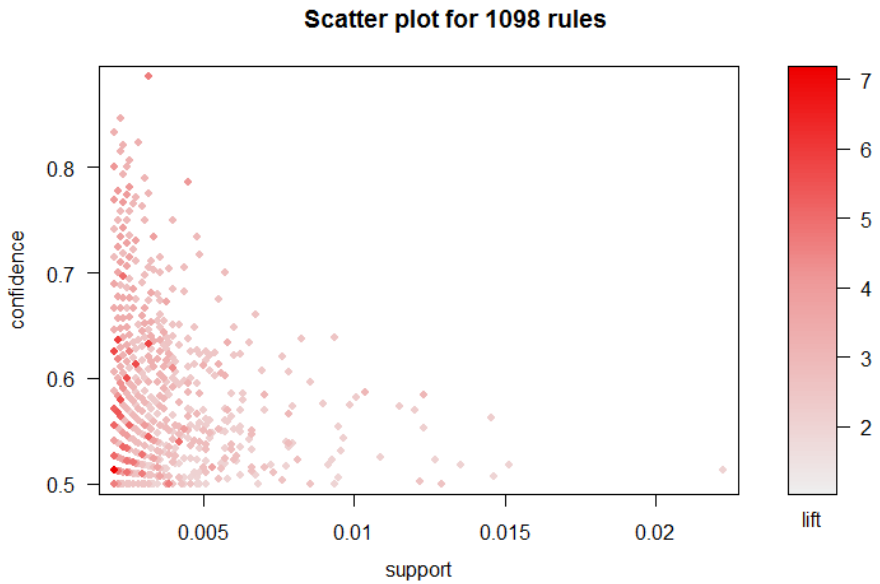

連結規則的視覺化

- plot(rules5, measure = c("support", "lift"), shading = "confidence")
- # 散點圖：支持度 vs 提升度

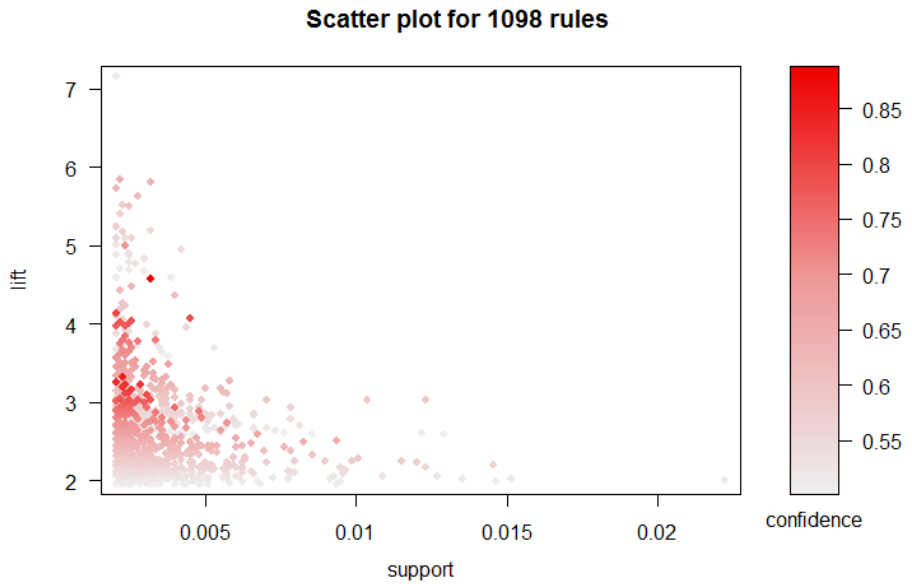

連結規則的視覺化

- plot(rules5, interactive = T)　　# 互動散點圖
- plot(rules5, control = list(main = "Two key plot"), shading = "order")
- # Two-key 散點圖 (點的顏色越深，商品的種類越多)

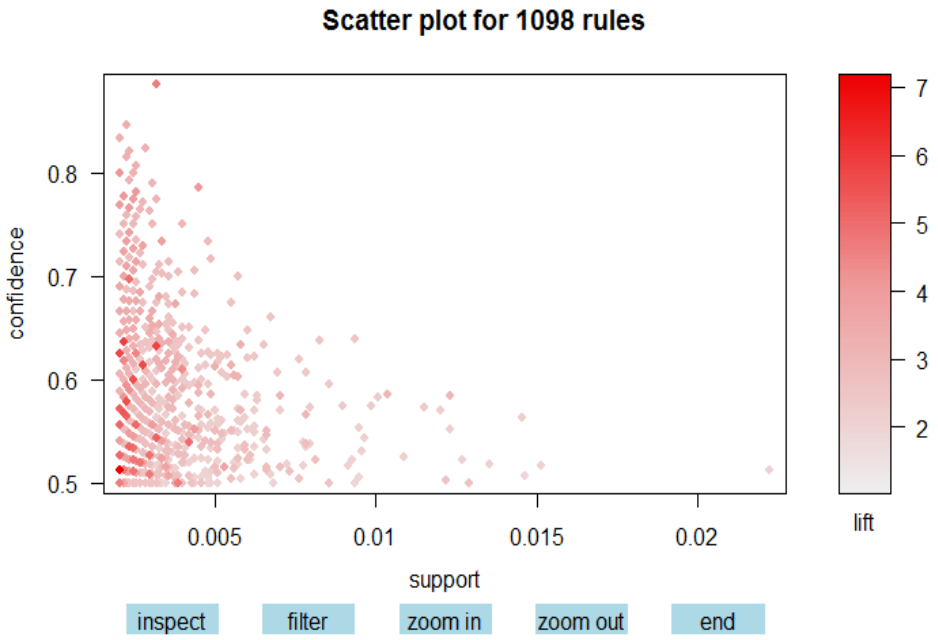

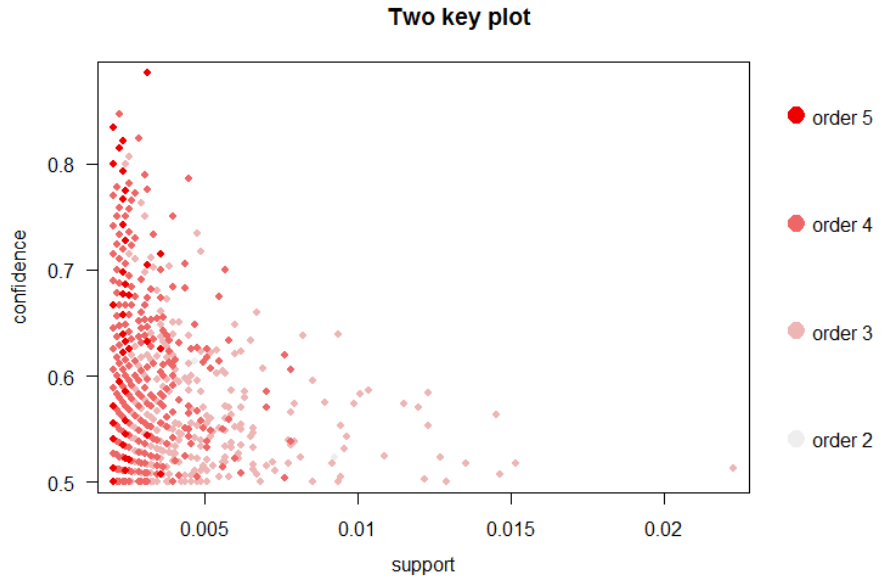

連結規則的視覺化

- plot(rules5, method = "group")
- # 群組圖：大小 (size): support, 顏色 (color): lift

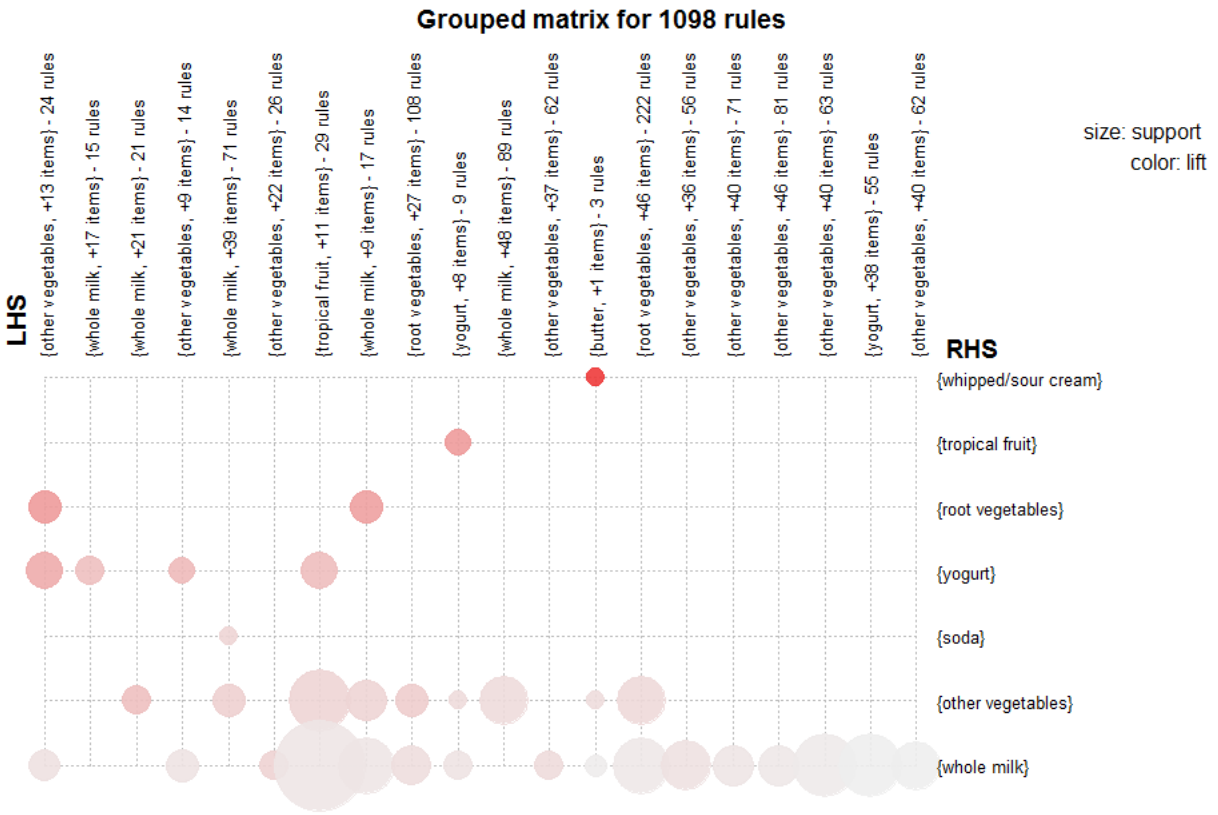

連結規則的視覺化

- plot(rules5[1:50], method = "matrix" , measure = "lift")
- plot(rules5[1:50], method = "matrix3D" , measure = "lift")
- plot(rules5[1:50], method = "paracoord")