The Big Data Marketing Analytics
大數據行銷分析

行銷理論、商業與人生
學術與實務的對話

- **Concept, Technology, and Application**

曹修源

23/12/2023

NCHU Marketing 國立中興大學行銷學系
Department of Marketing, National Chung Hsing University

Curtin University

USC University of Southern California

CONCEPT

Big Data Marketing Analytics

The Data Deluge

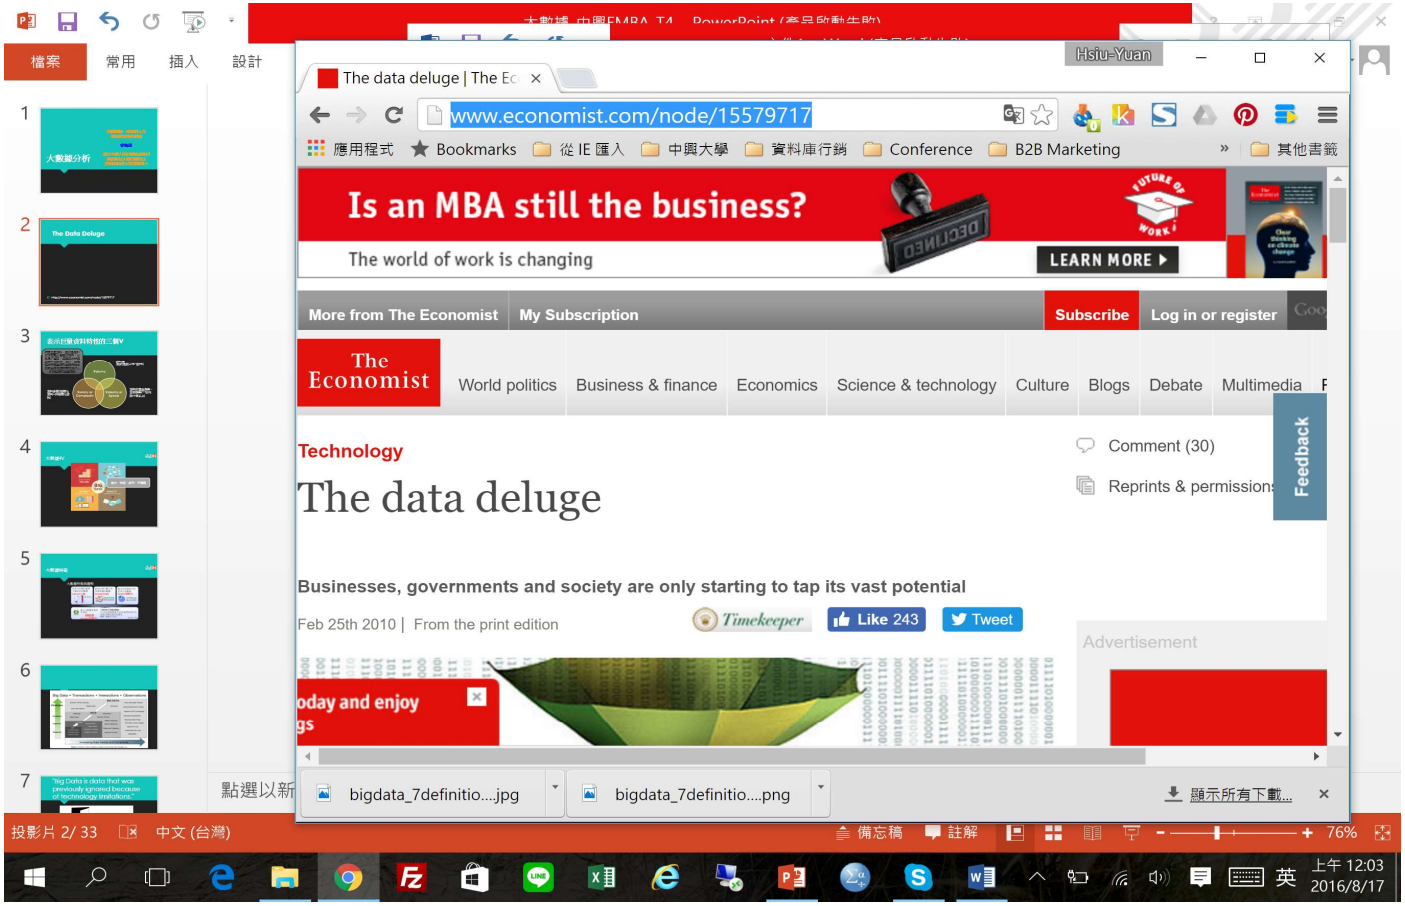

- http://www.economist.com/node/15579717

The Big Data

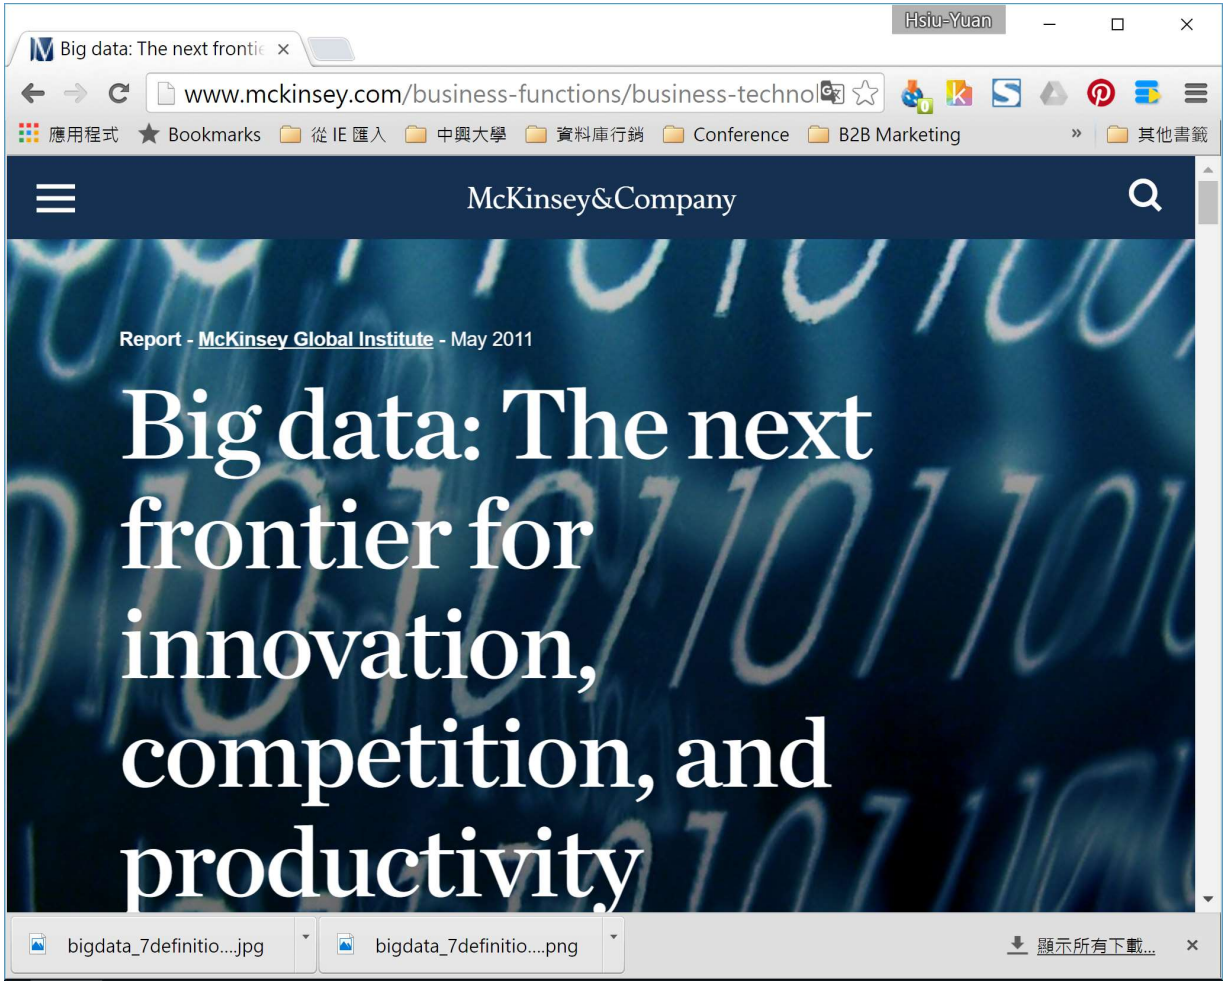

http://www.mckinsey.com/business-functions/business-technology/our-insights/big-data-the-next-frontier-for-innovation

Business Intelligent

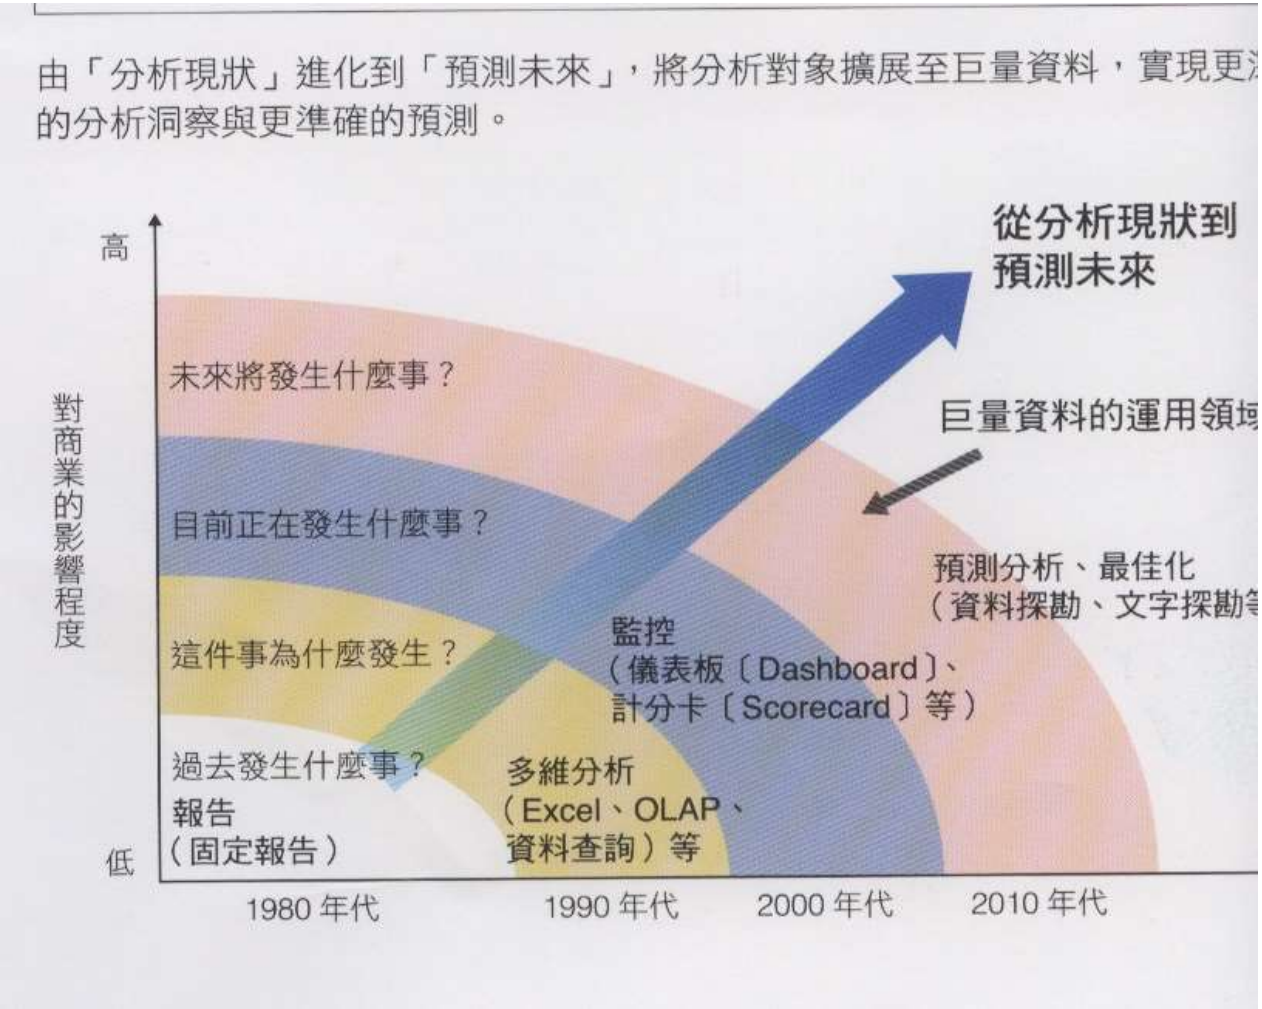

巨量資料特性的4V

資料量

資料的產生頻率、
更新頻率
(一秒內數十條以上)

資料多樣
(結構化資料+
非結構化資料)

不確定性

APPLICATION

Big Data Marketing Analytics

巨量資料運用案例

- 精準推薦商品或服務
- 行為定位廣告
- 運用地點資訊的行銷
- 揪出盜刷
- 顧客流失分析
- 預測設備故障
- 驗出異常
- 改善服務
- 預測路況
- 預測電力需求
- 預測感冒流行
- 預測股市行情
- 郵資成本的優化

大數據運用 數據驅動決策

阿里巴巴 Alibaba.com

以大數據分析為商業核心驅動力，打造以消費者為導向之電商系統

單日RMB350億營業額 2013光棍節創下世界紀錄	每分賣4.8萬件商品 總商品數超過8億件	超過5億會員數 每日訪客數為臺灣人口三倍

大數據運用 預測與推薦

大數據運用 數據分析行為

decide. + ebay

Decide is now part of the eBay family. Thank you to all our supporters who made it possible.

大數據運用 輿論分析與預測

Sentiment v.s Stock Market

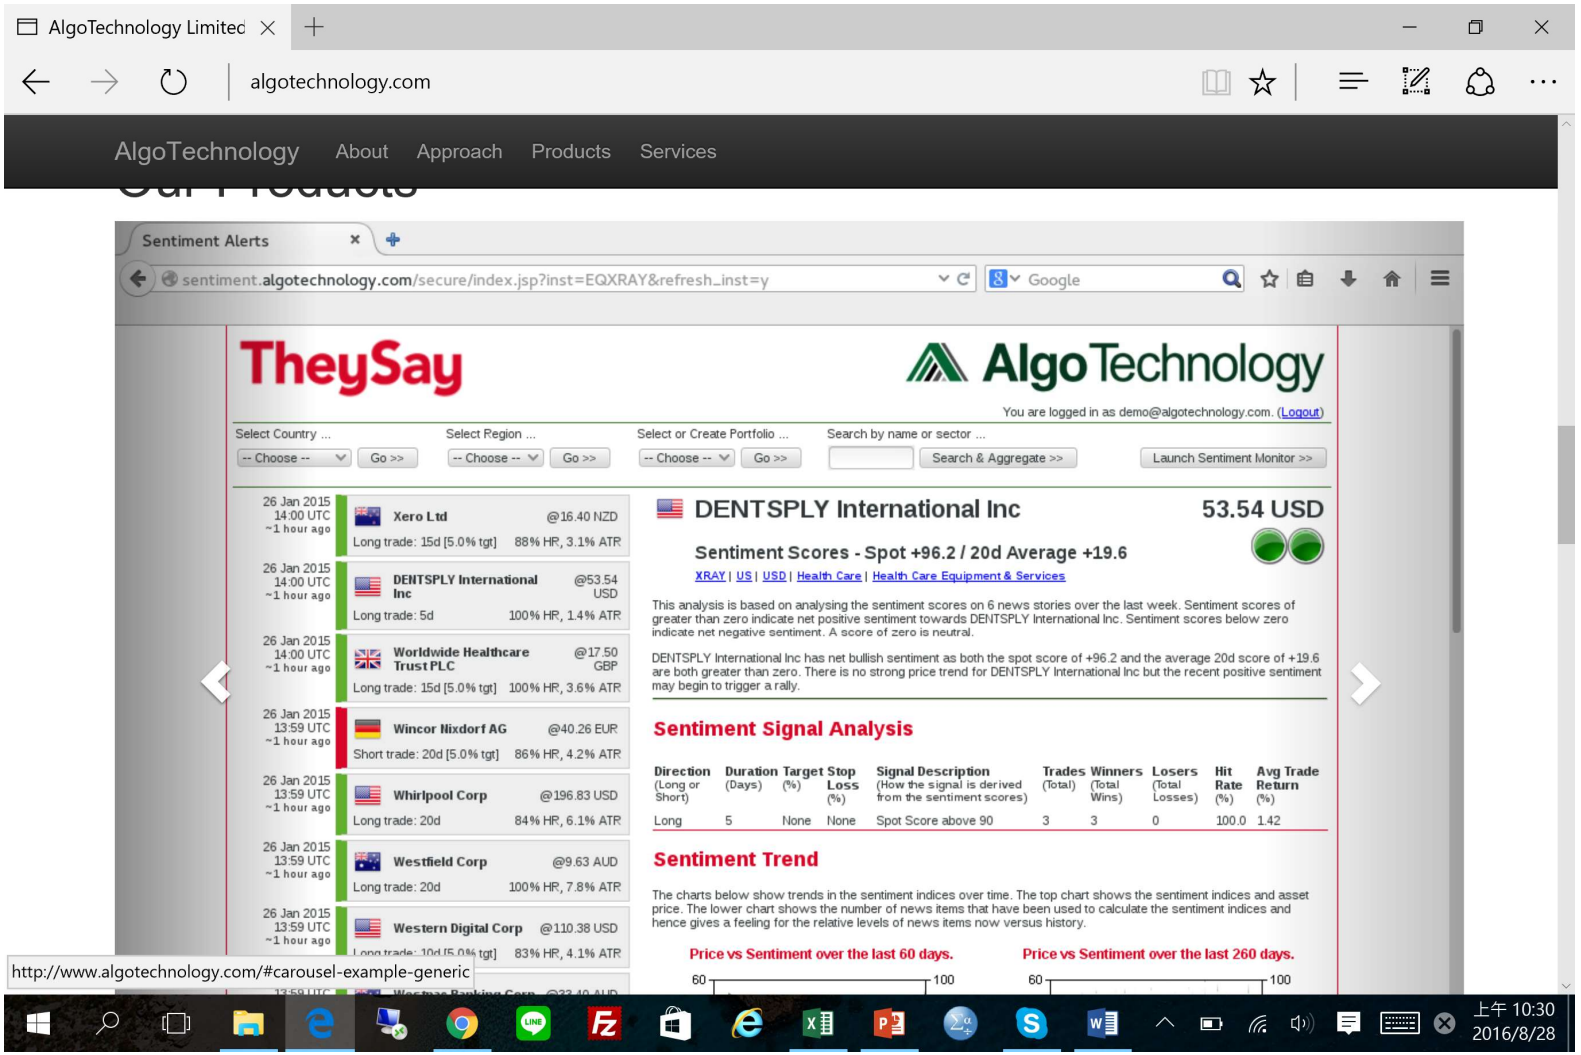

http://www.algotechnology.com/

大數據運用深度

1. 對過去/現況的掌握
2. 發現行為模式
3. 預測
4. 優化

TECHNOLOGY

Big Data Marketing Analytics

資料科學處理流程

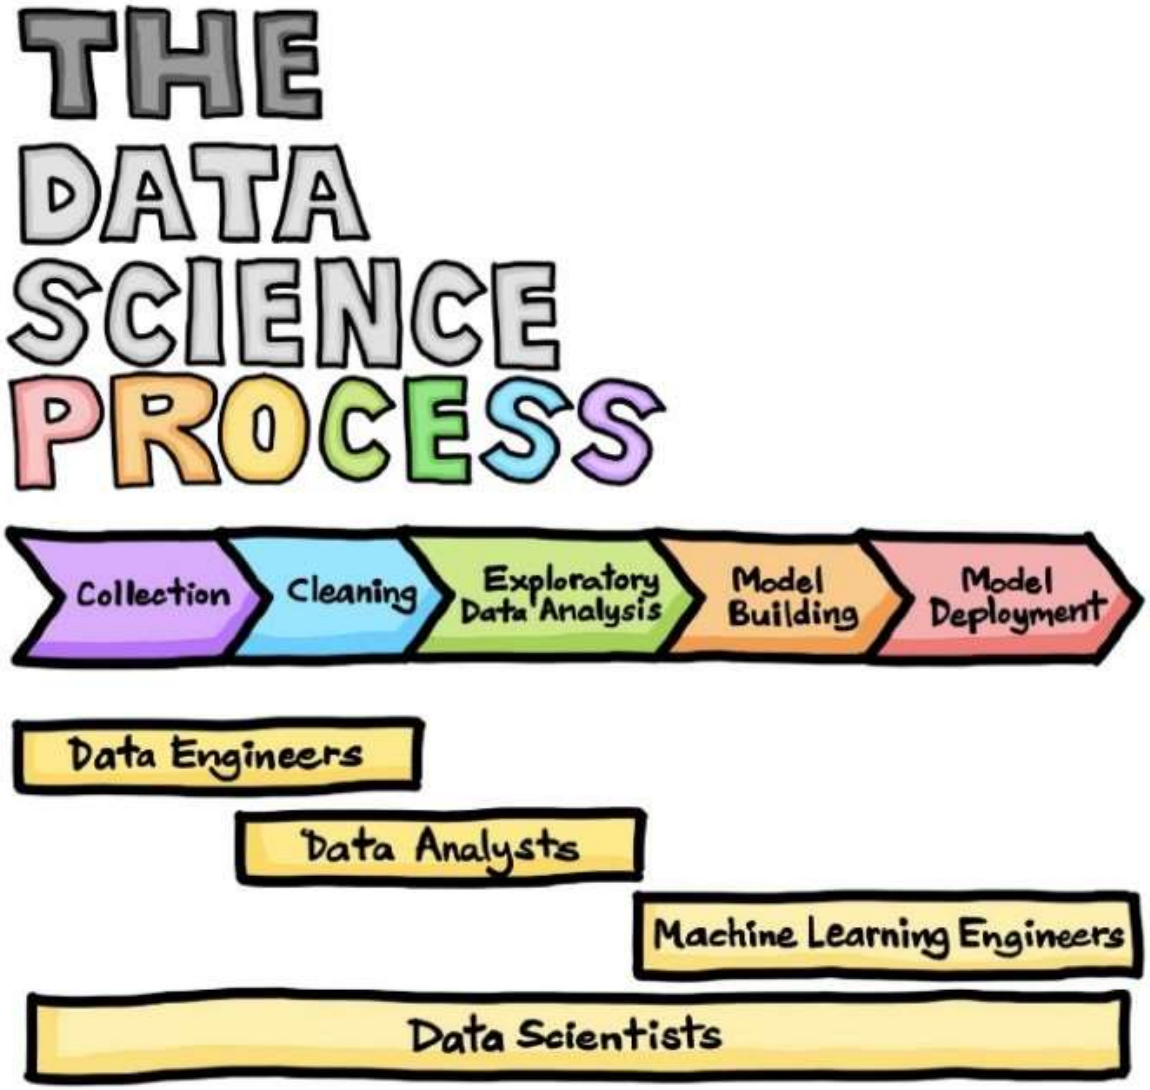

Data science life cycle. (Drawn by Chanin Nantasenamat in collaboration with Ken Jee)

資料科學處理流程

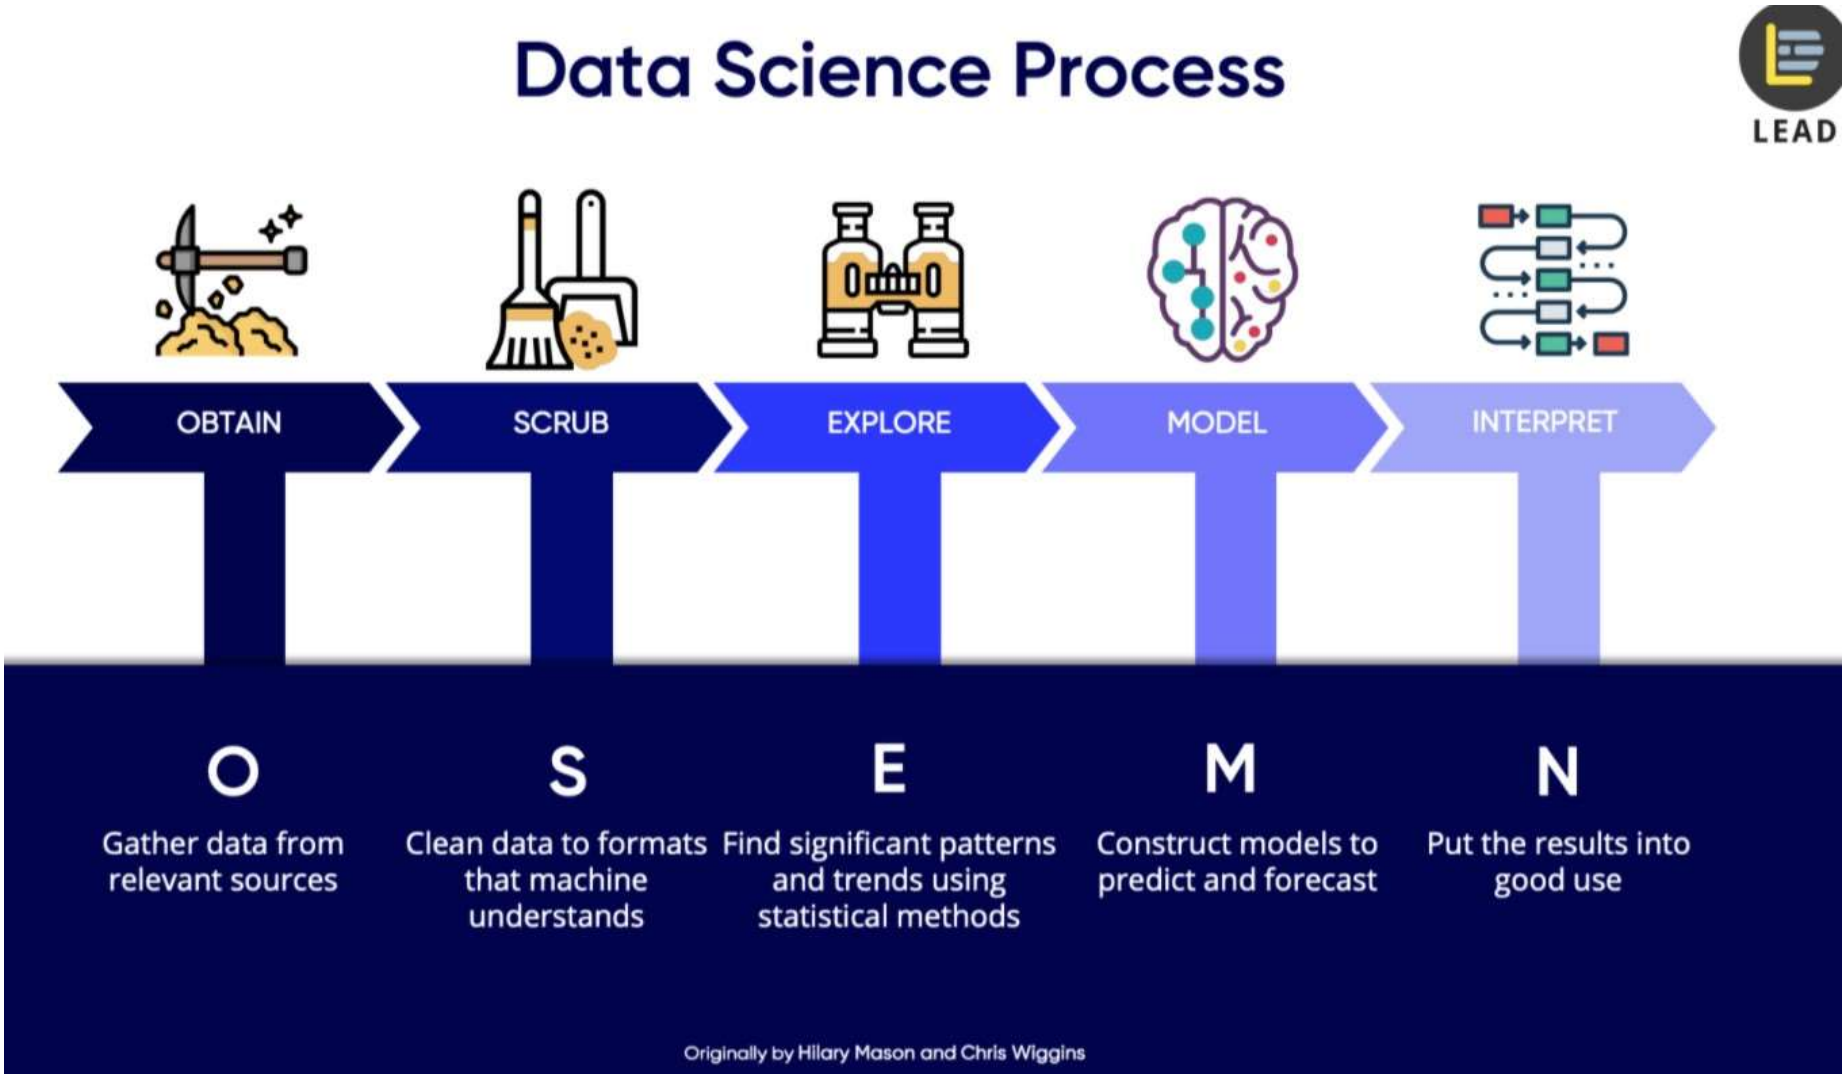
Data Science Process
LEAD
OBTAIN
SCRUB
EXPLORE
MODEL
INTERPRET
O
Gather data from relevant sources
S
Clean data to formats that machine understands
E
Find significant patterns and trends using statistical methods
M
Construct models to predict and forecast
N
Put the results into good use
Originally by Hilary Mason and Chris Wiggins

大數據分析相關技術

分群(Clustering)

分類(Classification)

預測(Prediction)

關聯規則(Association)

文字分析(Text Mining)

機器學習(Machine Learning)

行銷分析
Marketing Analytics

Basic Concept you need to know

分類還是分群

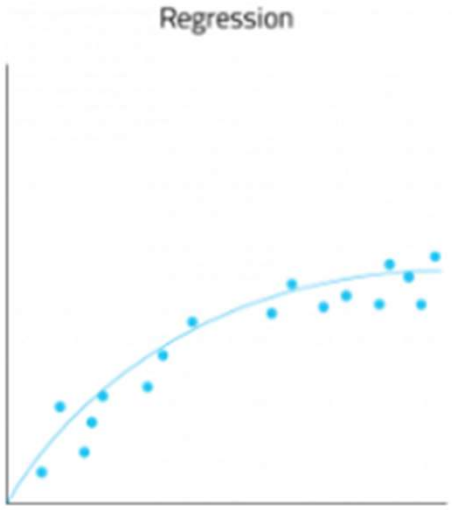

CLUSTERING

- Data is not labeled
- Group points that are "close" to each other
- Identify structure or patterns in data
- Unsupervised learning

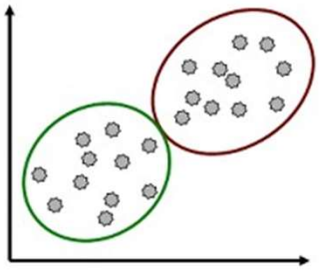

CLASSIFICATION

- Labeled data points
- Want a "rule" that assigns labels to new points
- Supervised learning

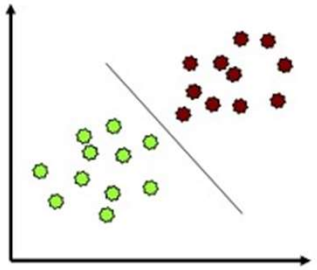

變異還是偏誤

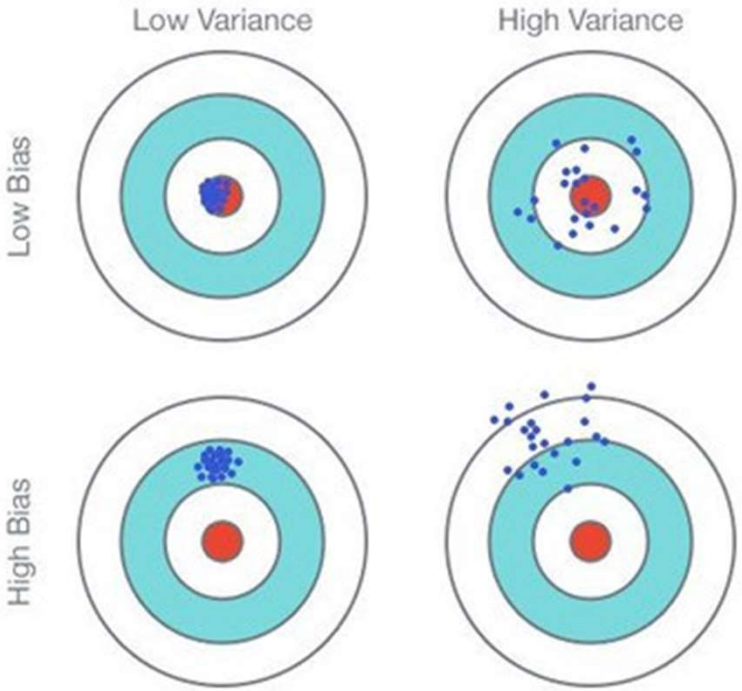
Low Variance
High Variance
Low Bias
High Bias

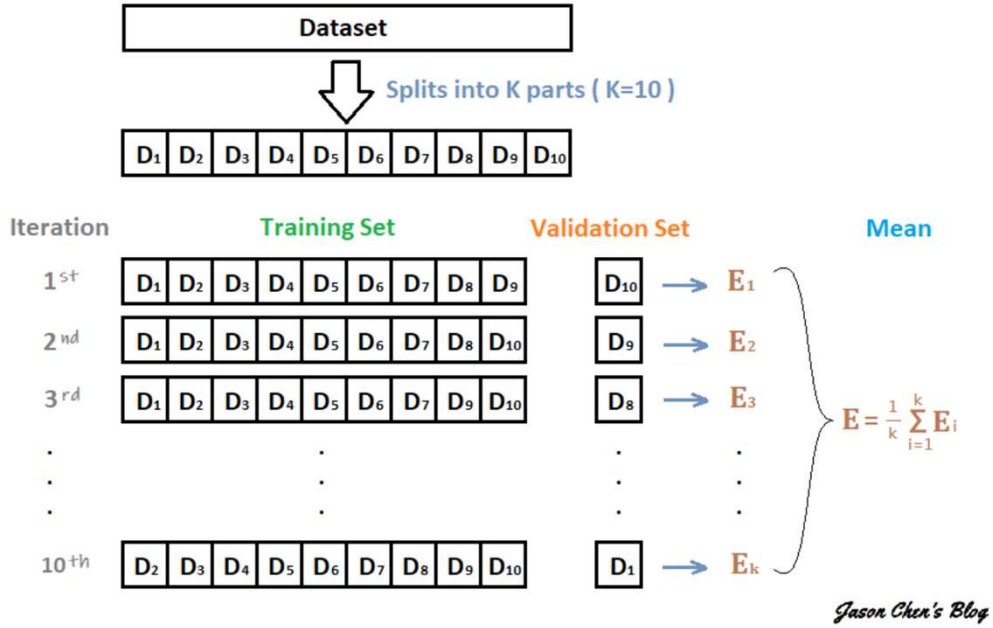
Dataset
Splits into K parts (K=10)
D1 D2 D3 D4 D5 D6 D7 D8 D9 D10
Iteration
Training Set
Validation Set
Mean
1st
2nd
3rd
10th
E = 1/k Σ Ei
Jason Chen's Blog

何謂距離

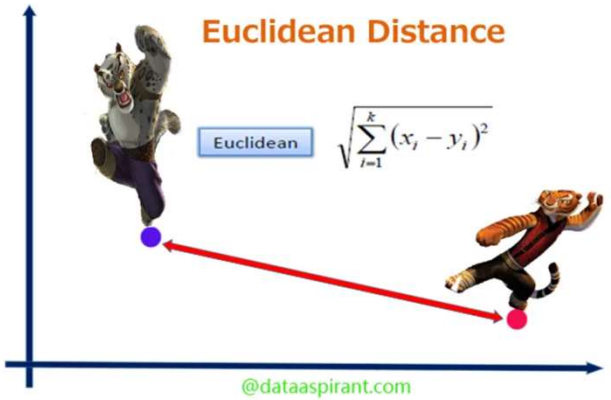
Euclidean Distance
Euclidean
$\sqrt{\sum_{i=1}^{k}(x_i - y_i)^2}$
@dataaspirant.com

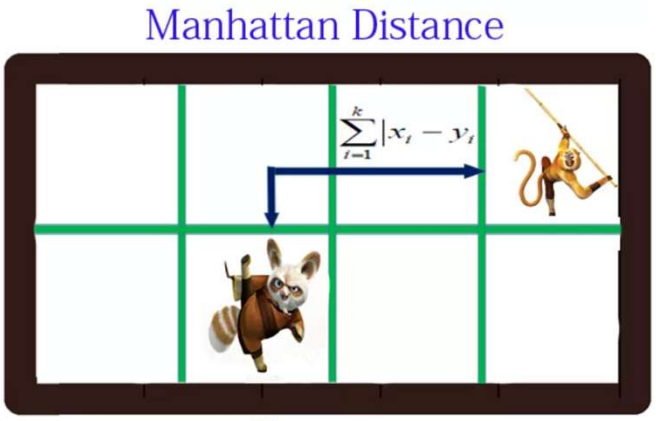
Manhattan Distance
$\sum_{i=1}^{k}|x_i - y_i$

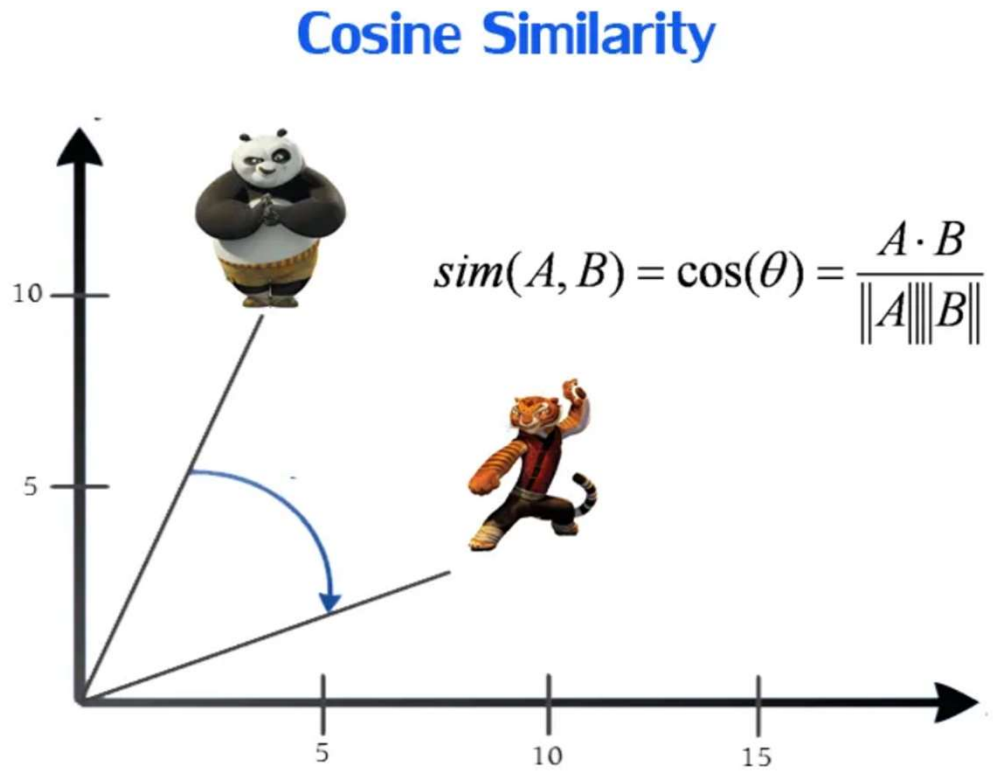
Cosine Similarity
$sim(A,B) = \cos(\theta) = \frac{A \cdot B}{\|A\|\|B\|}$
10
5
5
10
15

機器學習演算法

1. Gathering Data.
2. Preparing Data.
3. Model Selection.
4. Training.
5. Evaluation.
6. Prediction.

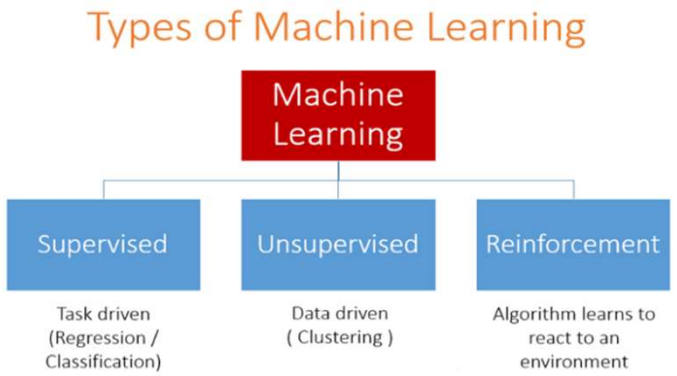

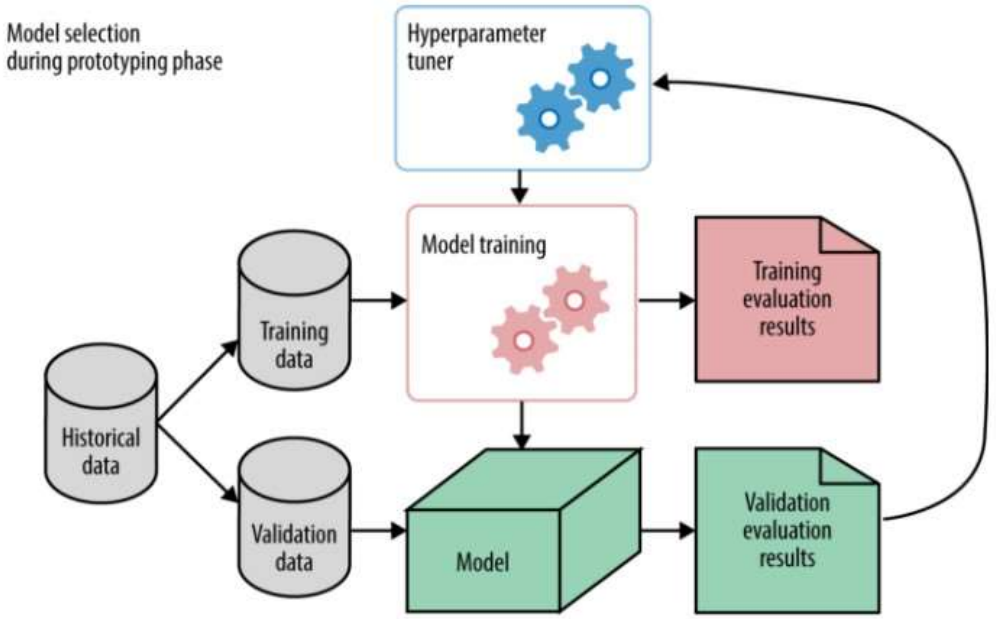

分類分群還是預測

Prediction (numerical)	Classification (categorical)	Clustering (categorical)
Supervised	**Supervised**	**Unsupervised**
Linear Regression	Logistic Regression	K-Means
Multiple Regression	KNN -K Nearest Neighbor	Hierarchical
Ridge Regression	Naïve Bayes	Neural Networks
Lasso Regression	Decision Trees	
Bayesian	Ensemble Trees	
Neural Networks	SVM -Support Vector Machines	
Quantum Computing	Neural Networks	

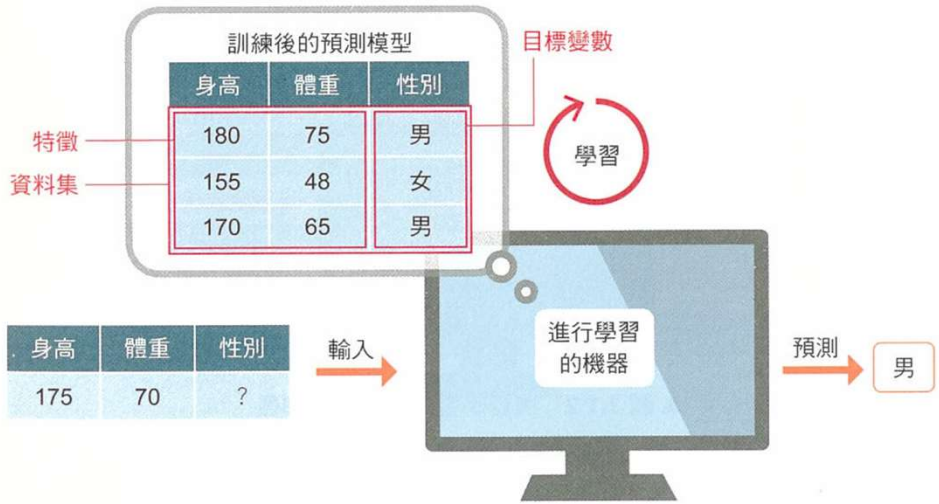

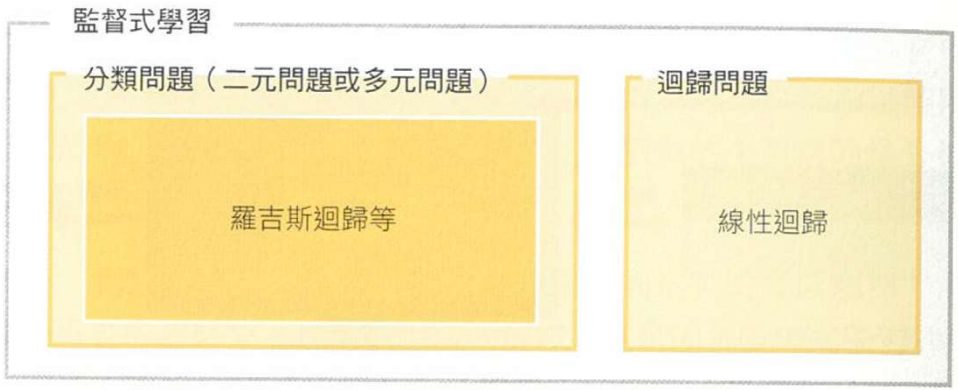

顯著性還是混淆矩陣

Confusion Matrix- (*Also called fittin*

		Predicted class: *P*	Predicted class: *N*
Actual Class	*P*	True Positives (TP)	False Negatives (FN)
	N	False Positives (FP)	True Negatives (TN)

- 正確率（Accuracy）：$\frac{TP + TN}{TP + TN + FP + FN}$
- 精確率（Precision）：$\frac{TP}{TP + FP}$
- 召回率（Recall）：$\frac{TP}{TP + FN}$
- F1 值（F1-Score）：2×（精確率 × 召回率）/（精確率＋召回率）

大數據分析相關工具與步驟

- 程式語言:
  - R / Python
- Excel Addon:
  - XLSTAT
  - XLMINER
- 分析軟體:
  - IBM SPSS / IBM SPSS Modeller
  - Microsoft Azure Machine Leraning
- 機器學習分析平台
  - DataRobot
  - Paperspace Gradient
  - IBM Cognos Analytics

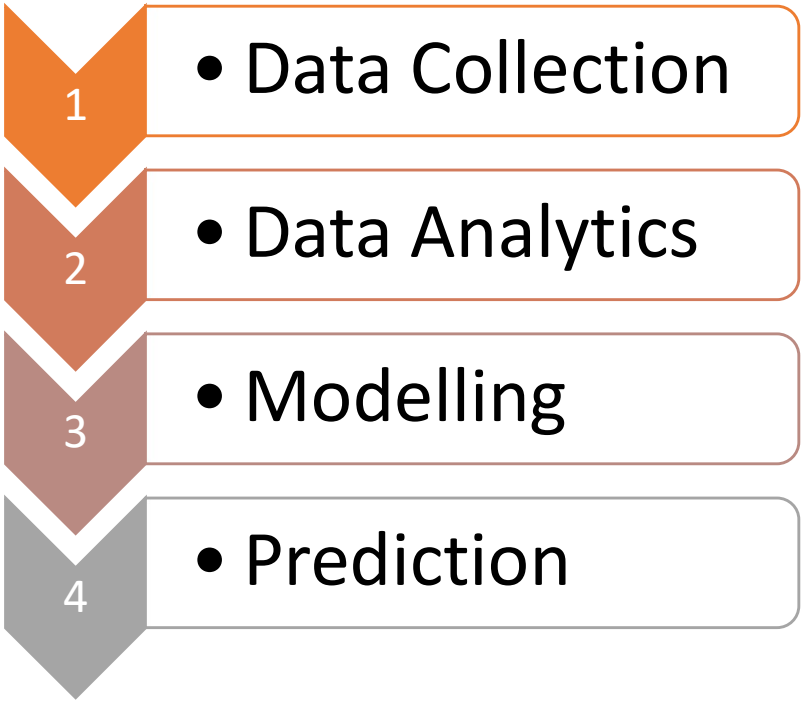

Ten Machine Learning Algorithms You Should Know to Become a Data Scientist

機器學習演算法

Clustering / Segmentation (範例一)

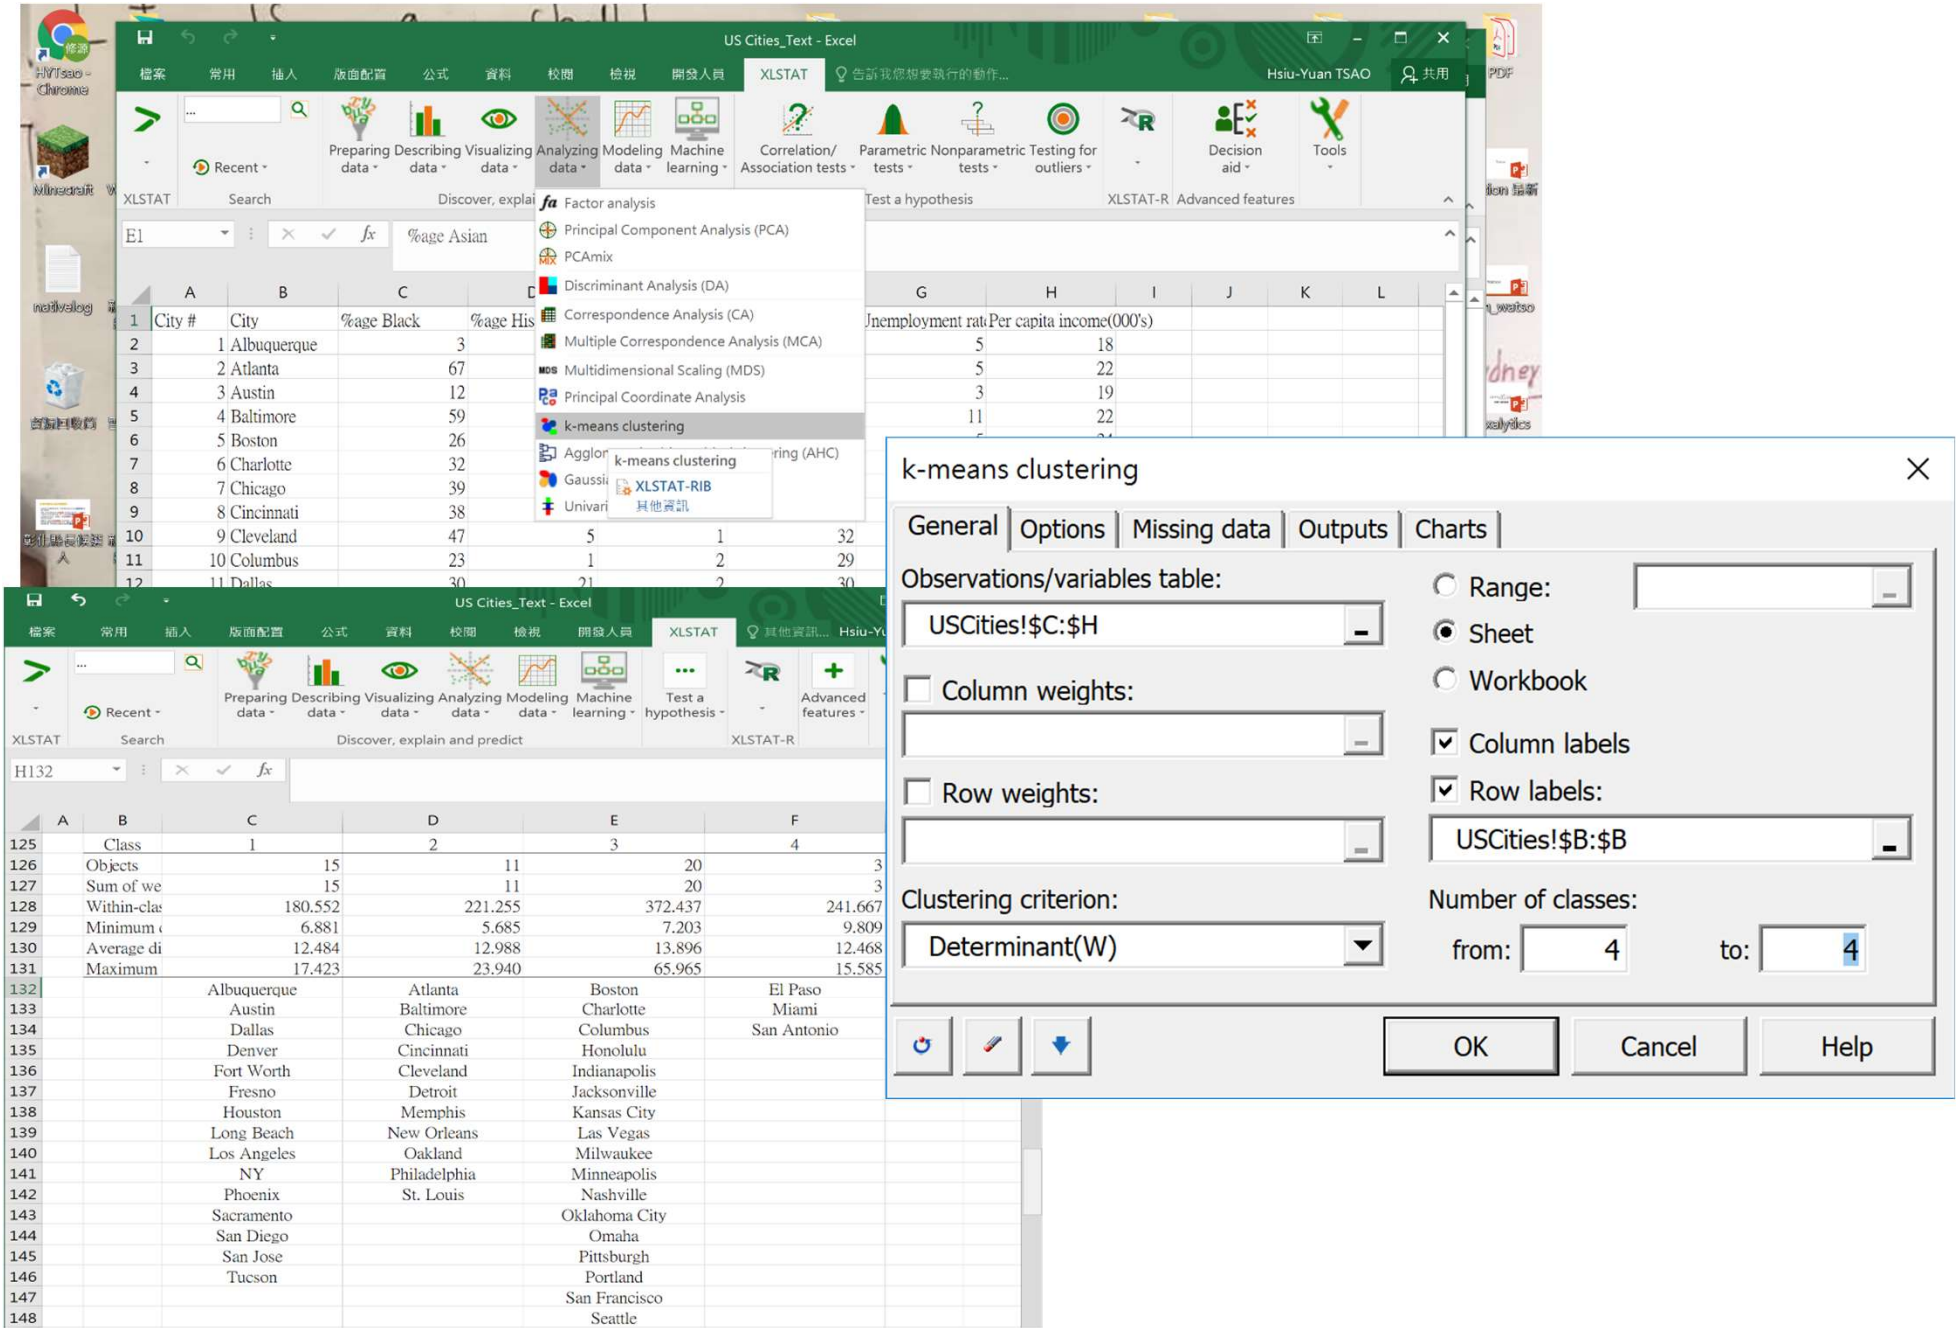

Clustering / Segmentation(範例二)

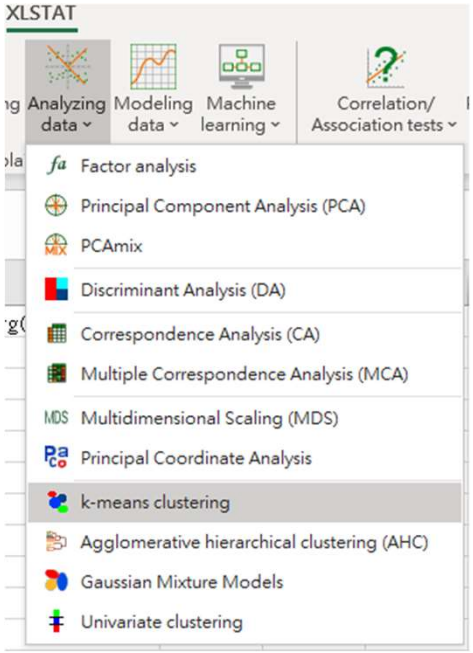

	CustomerID	TotalSales	OrderCount	AvgOrderValue
1	12346	77183.6	1	77183.6
2	12347	4085.18	6	680.8633333
3	12348	1797.24	4	449.31
4	12349	1757.55	1	1757.55
5	12350	334.4	1	334.4
6	12352	2506.04	8	313.255
7	12353	89	1	89
8	12354	1079.4	1	1079.4
9	12355	459.4	1	459.4
10	12356	2811.43	3	937.1433333
11	12357	6207.67	1	6207.67
12	12358	484.86	1	484.86
13	12359	6372.58	4	1593.145
14	12360	2662.06	3	887.3533333
15	12361	189.9	1	189.9
16	12362	4697.19	9	521.91
17	12363	552	2	276

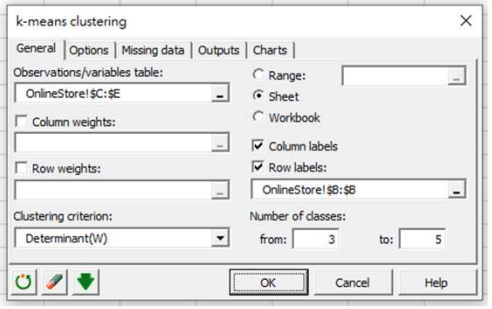

Evolution of variances:

ariance\Clas:	4	5	6
Within-clas	9,873,172.72	8,843,801.88	8,449,023.09
Between-cl	61,536,875.05	62,566,245.90	62,961,024.68
Total	71410047.773	71410047.773	71410047.773

Central objects:

Class	TotalSales	OrderCount	AvgOrderValue
1 (14088)	50491.810	13.000	3883.985
2 (14223)	991.130	3.000	330.377
3 (13001)	9227.810	12.000	768.984
4 (17450)	192988.390	45.000	4288.631

What a beautiful world!

Principal Component Analysis

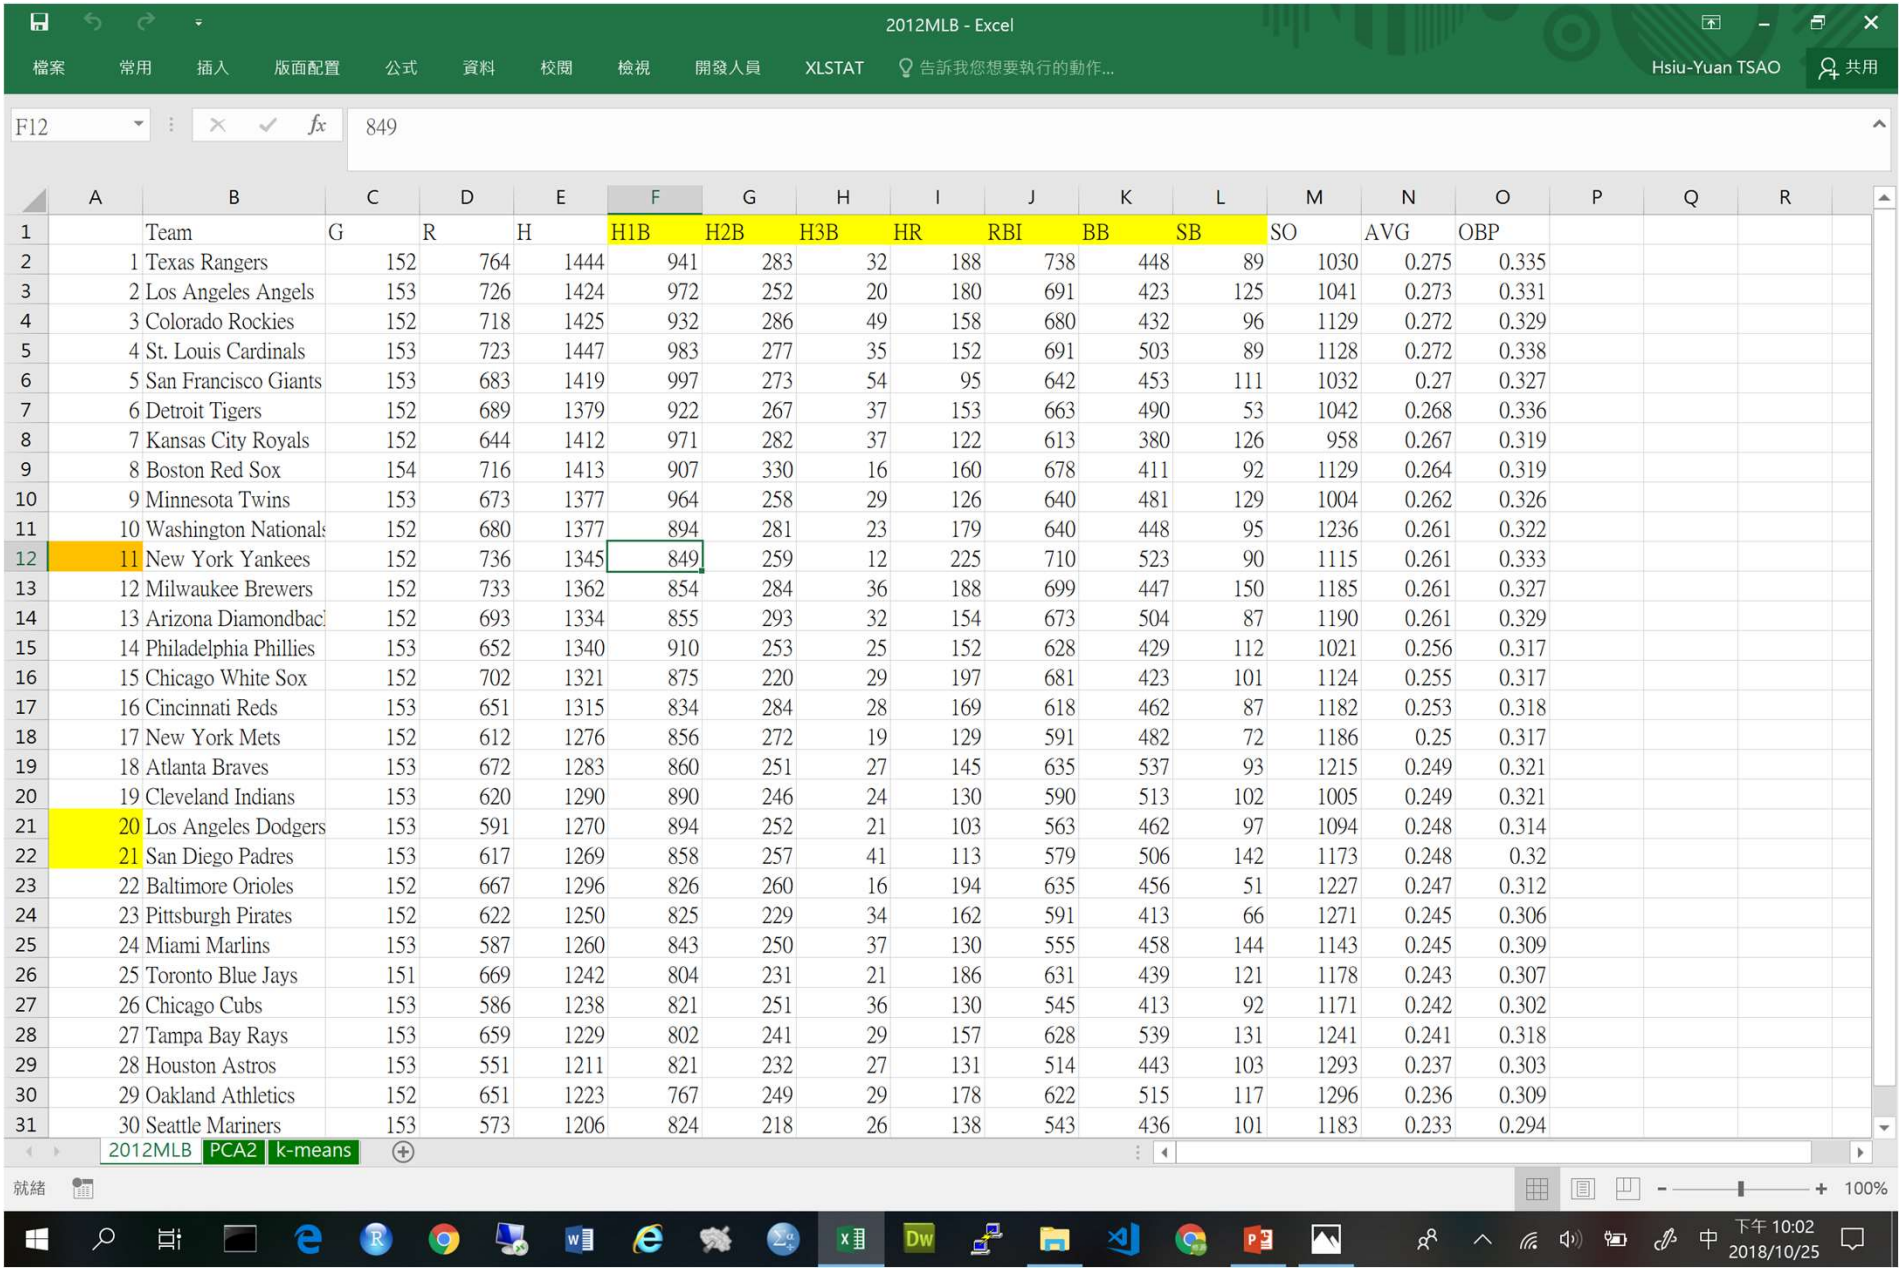

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
1		Team	G	R	H	H1B	H2B	H3B	HR	RBI	BB	SB	SO	AVG	OBP			
2	1	Texas Rangers	152	764	1444	941	283	32	188	738	448	89	1030	0.275	0.335			
3	2	Los Angeles Angels	153	726	1424	972	252	20	180	691	423	125	1041	0.273	0.331			
4	3	Colorado Rockies	152	718	1425	932	286	49	158	680	432	96	1129	0.272	0.329			
5	4	St. Louis Cardinals	153	723	1447	983	277	35	152	691	503	89	1128	0.272	0.338			
6	5	San Francisco Giants	153	683	1419	997	273	54	95	642	453	111	1032	0.27	0.327			
7	6	Detroit Tigers	152	689	1379	922	267	37	153	663	490	53	1042	0.268	0.336			
8	7	Kansas City Royals	152	644	1412	971	282	37	122	613	380	126	958	0.267	0.319			
9	8	Boston Red Sox	154	716	1413	907	330	16	160	678	411	92	1129	0.264	0.319			
10	9	Minnesota Twins	153	673	1377	964	258	29	126	640	481	129	1004	0.262	0.326			
11	10	Washington Nationals	152	680	1377	894	281	23	179	640	448	95	1236	0.261	0.322			
12	11	New York Yankees	152	736	1345	849	259	12	225	710	523	90	1115	0.261	0.333			
13	12	Milwaukee Brewers	152	733	1362	854	284	36	188	699	447	150	1185	0.261	0.327			
14	13	Arizona Diamondbacl	152	693	1334	855	293	32	154	673	504	87	1190	0.261	0.329			
15	14	Philadelphia Phillies	153	652	1340	910	253	25	152	628	429	112	1021	0.256	0.317			
16	15	Chicago White Sox	152	702	1321	875	220	29	197	681	423	101	1124	0.255	0.317			
17	16	Cincinnati Reds	153	651	1315	834	284	28	169	618	462	87	1182	0.253	0.318			
18	17	New York Mets	152	612	1276	856	272	19	129	591	482	72	1186	0.25	0.317			
19	18	Atlanta Braves	153	672	1283	860	251	27	145	635	537	93	1215	0.249	0.321			
20	19	Cleveland Indians	153	620	1290	890	246	24	130	590	513	102	1005	0.249	0.321			
21	20	Los Angeles Dodgers	153	591	1270	894	252	21	103	563	462	97	1094	0.248	0.314			
22	21	San Diego Padres	153	617	1269	858	257	41	113	579	506	142	1173	0.248	0.32			
23	22	Baltimore Orioles	152	667	1296	826	260	16	194	635	456	51	1227	0.247	0.312			
24	23	Pittsburgh Pirates	152	622	1250	825	229	34	162	591	413	66	1271	0.245	0.306			
25	24	Miami Marlins	153	587	1260	843	250	37	130	555	458	144	1143	0.245	0.309			
26	25	Toronto Blue Jays	151	669	1242	804	231	21	186	631	439	121	1178	0.243	0.307			
27	26	Chicago Cubs	153	586	1238	821	251	36	130	545	413	92	1171	0.242	0.302			
28	27	Tampa Bay Rays	153	659	1229	802	241	29	157	628	539	131	1241	0.241	0.318			
29	28	Houston Astros	153	551	1211	821	232	27	131	514	443	103	1293	0.237	0.303			
30	29	Oakland Athletics	152	651	1223	767	249	29	178	622	515	117	1296	0.236	0.309			
31	30	Seattle Mariners	153	573	1206	824	218	26	138	543	436	101	1183	0.233	0.294			

Principal Component Analysis

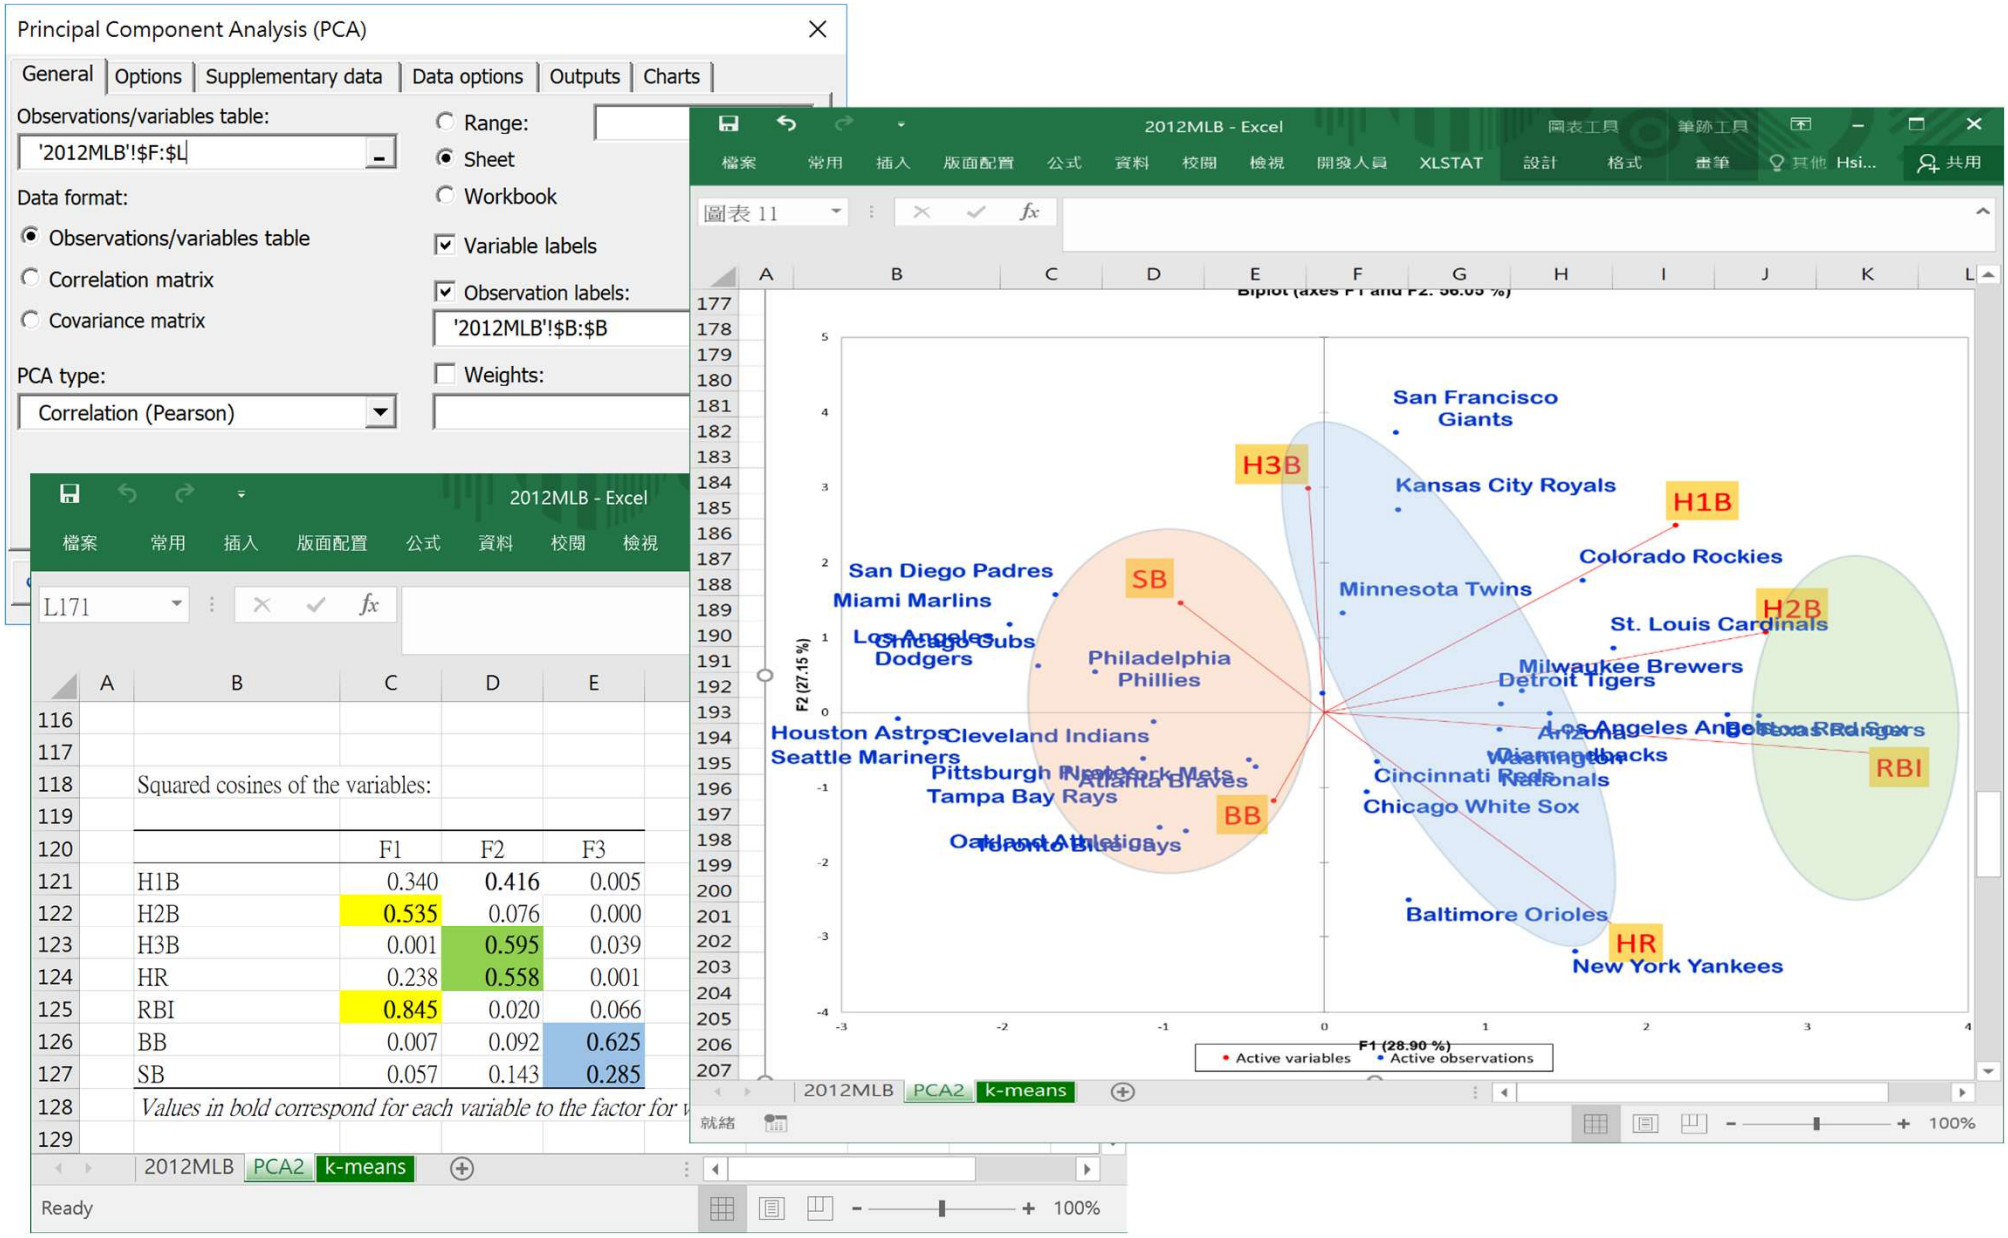

Correspondence Analysis (CA) /Positioning

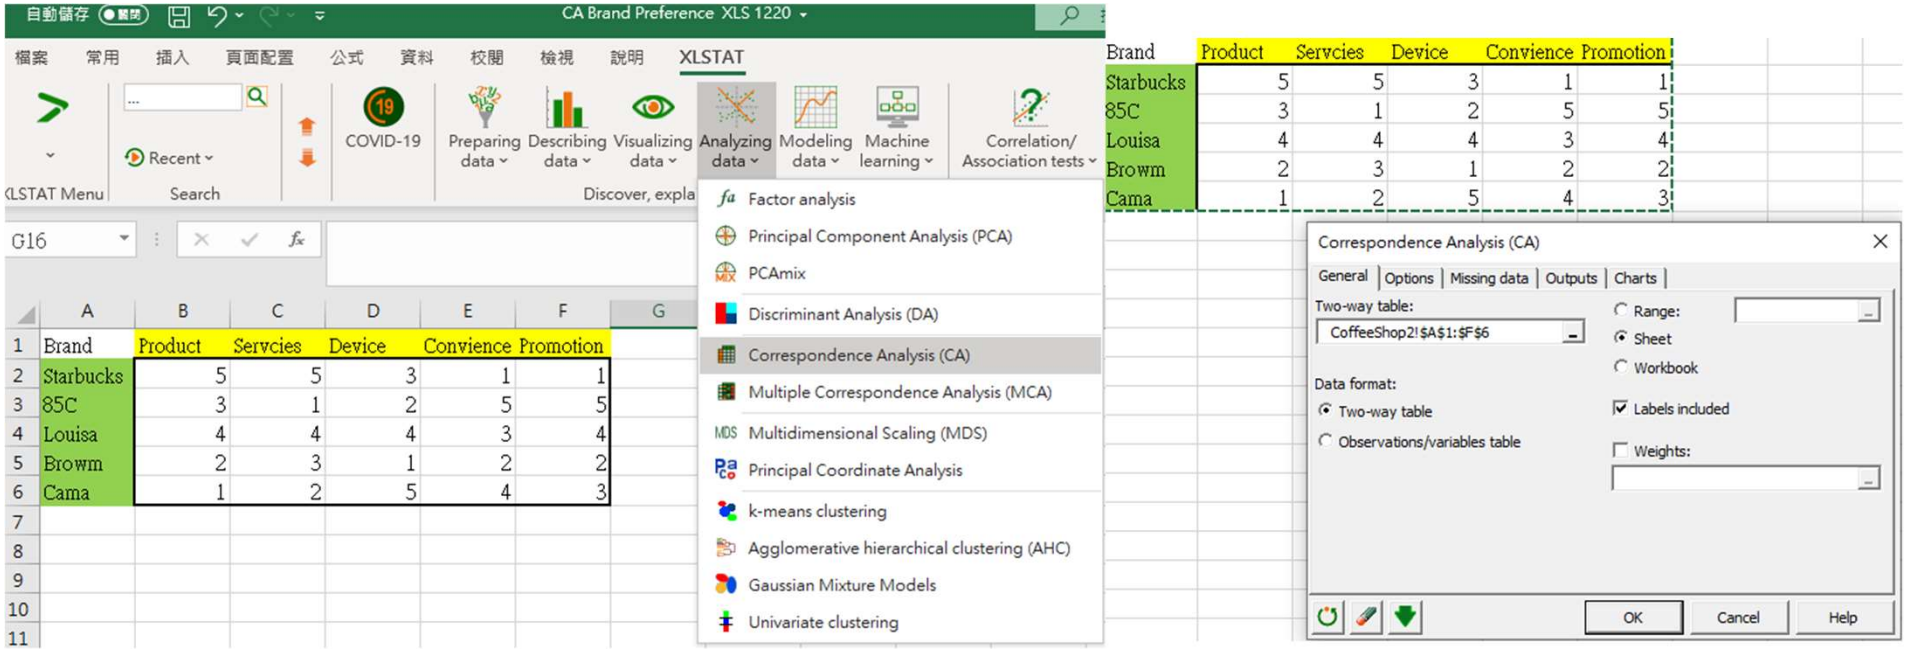

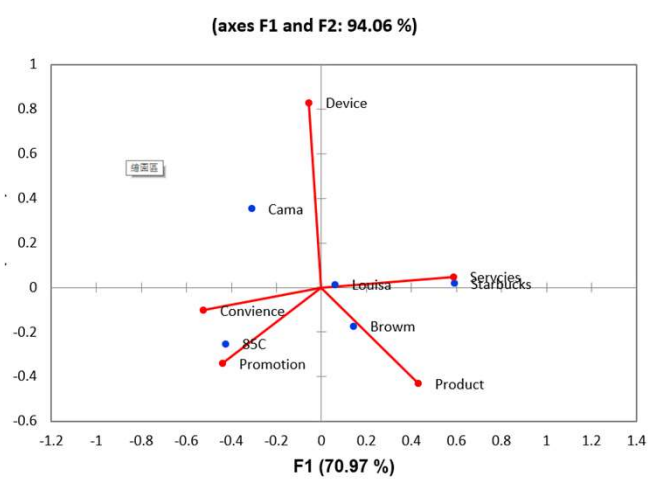

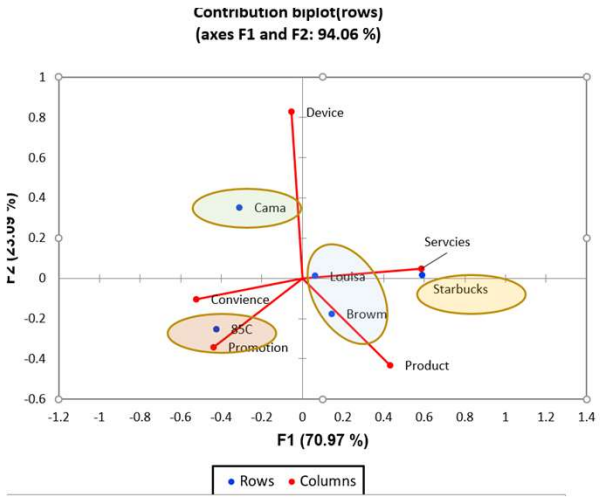

Mult iDimensional Scaling

Brand	Product	Servcies	Device	Convience	Promotion
Starbuck	4.2	3.92	3.98	3.68	4.07
85C	4.1	3.95	3.98	3.65	4.04
Crown	4.18	3.2	3.56	3.7	3.97
Browm	3.05	3.06	3.07	2.77	3.08
CafeOne	2.99	3	3	2.75	3

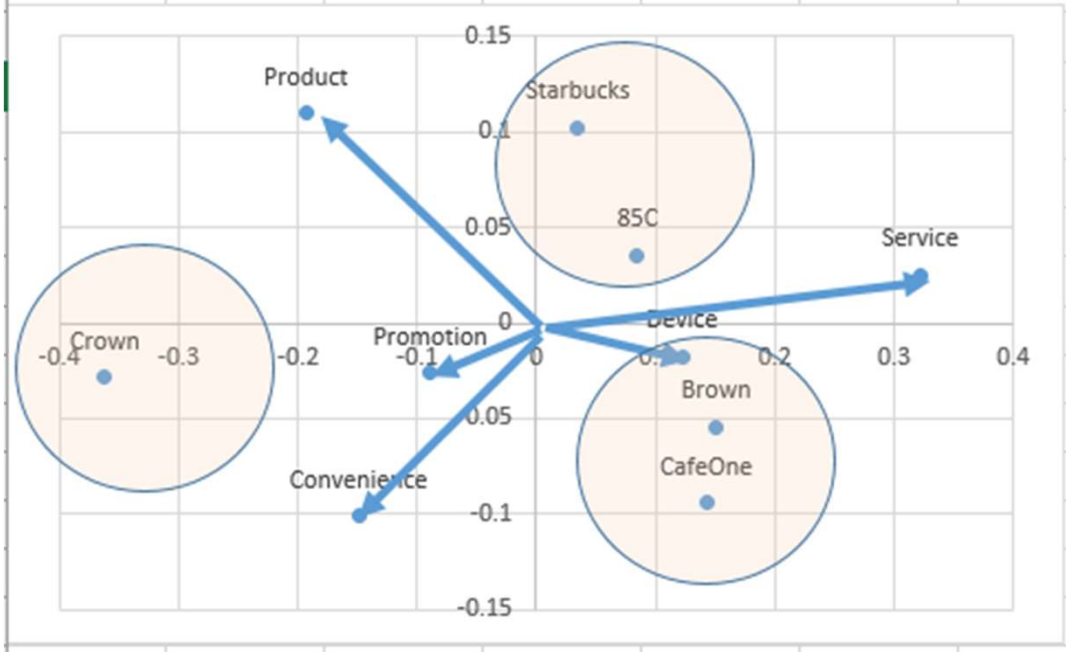

Configuration:

	Dim1	Dim2
Starbuck	0.605	0.817
85C	0.495	0.825
Crown	0.739	-0.010
Browm	-0.888	-0.755
CafeOne	-0.951	-0.877
Product	-0.531	0.099
Servcies	0.500	0.177
Device	0.139	0.122
Convience	0.174	-0.485
Promotion	-0.281	0.087

Step 1: Compute row and column averages

	Big	Athletic	Friendly	Trainab	Resourc	Animal	Lucky	Average
Dog	80	20	90	90	5	100	40	61
Cat	50	40	40	70	10	100	40	50
Rat	10	70	20	90	80	99	40	58
Cockroach	0	80	2	20	95	20	40	37
Wallaby	35	52	38	47	48	80	40	49
Average	35	52	38	63	48	80	40	51

35*61/52

Step 2: Compute the *expected values*

	Big	Athletic	Friendly	Trainab	Resourc	Animal	Lucky
Dog	42	63	45	76	57	95	48
Cat	34	51	37	62	47	78	39
Rat	40	60	44	73	55	92	46
Cockroach	25	38	27	46	34	58	29
Wallaby	33	50	36	61	45	76	38

38=80-42

Step 3: Compute the *residuals*

Dog	38	-43	45	14	-52	5	-8
Cat	16	-11	3	8	-37	22	1
Rat	-30	10	-24	17	25	7	-6
Cockroach	-25	42	-25	-26	61	-38	11
Wallaby	2	2	2	-14	3	4	2

Step 4: Plotting labels with similar residuals close together

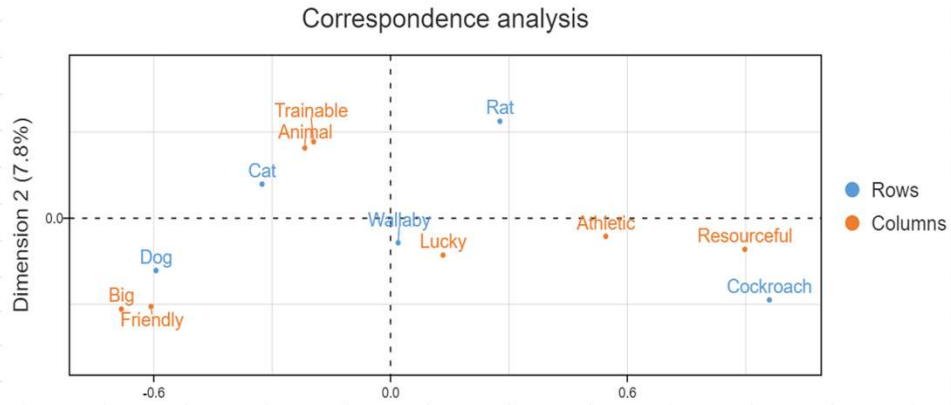

Step 5: Interpreting the relationship between row and column labels

1. Look at the length of the line connecting the row label to the origin. Longer lines indicate that the row label is highly associated with some of the column labels (i.e., it has at least one high residual).
2. Look at the length of the label connecting the column label to the origin. Longer lines again indicate a high association between the column label and one or more row labels.
3. Look at the angle formed between these two lines. Really small angles indicate association. 90 degree angles indicate no relationship. Angles near 180 degrees indicate negative associations.

强度

方向

Multi Dimensional Scaling(MDS)

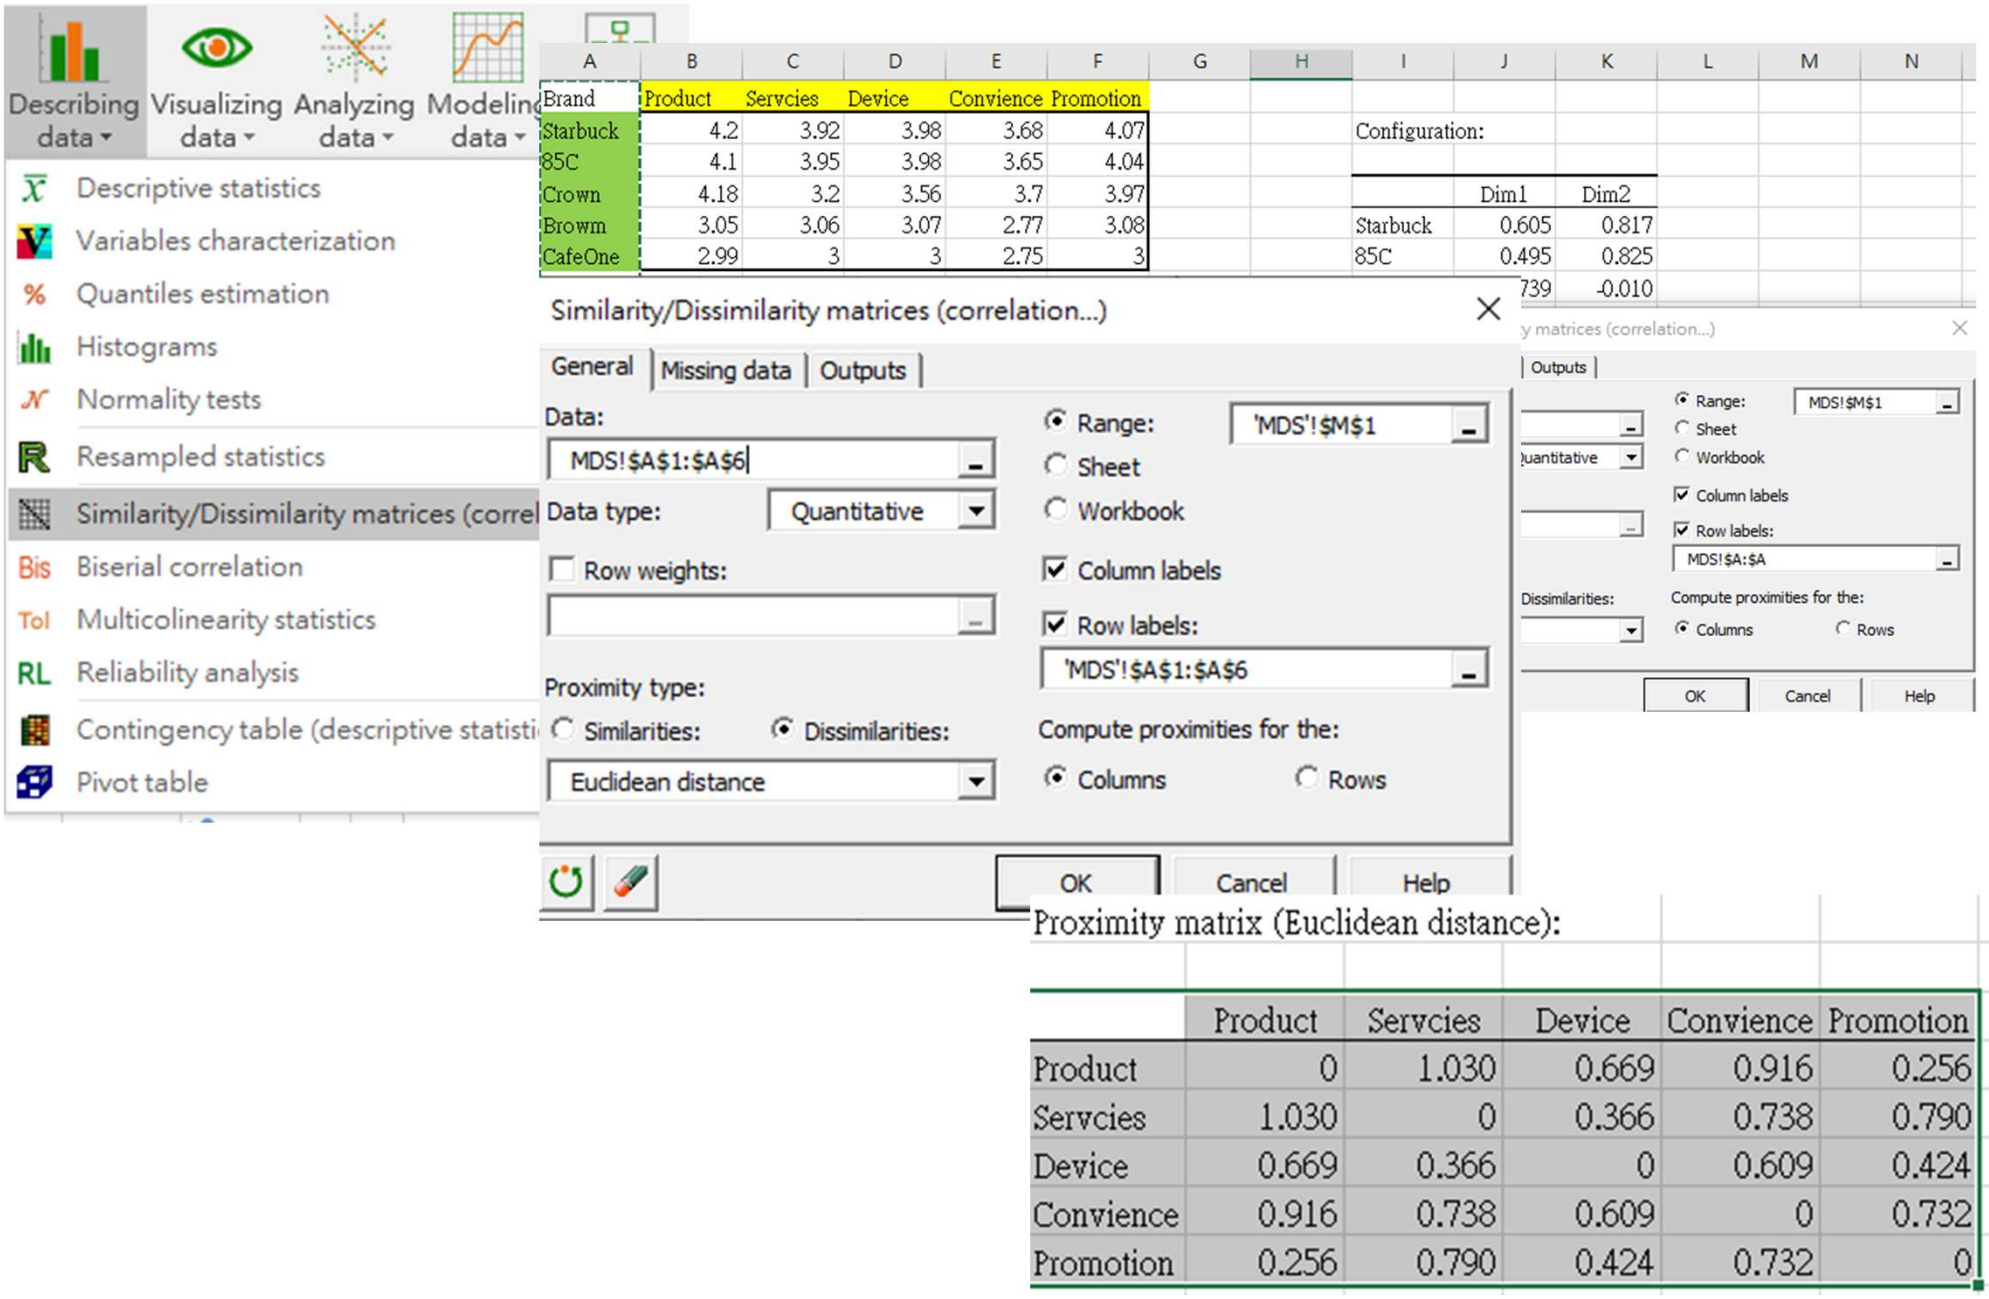

Proximity matrix (Euclidean distance):

	Product	Servcies	Device	Convience	Promotion
Product	0	1.030	0.669	0.916	0.256
Servcies	1.030	0	0.366	0.738	0.790
Device	0.669	0.366	0	0.609	0.424
Convience	0.916	0.738	0.609	0	0.732
Promotion	0.256	0.790	0.424	0.732	0

Multi Dimensional Scaling(MDS)

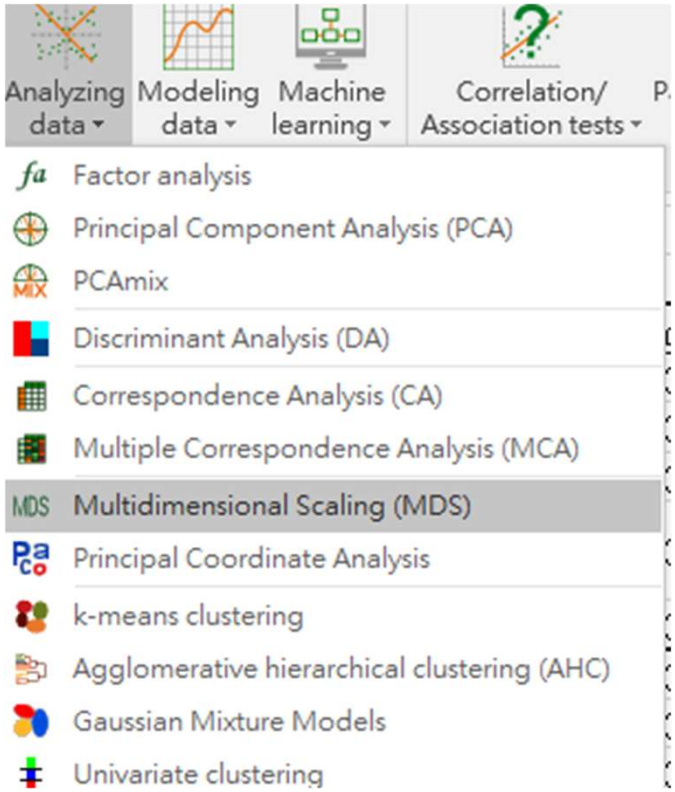

Proximity matrix (Euclidean distance):

	Product	Servcies	Device	Convience	Promotion
Product	0	1.030	0.669	0.916	0.256
Servcies	1.030	0	0.366	0.738	0.790
Device	0.669	0.366	0	0.609	0.424
Convience	0.916	0.738	0.609	0	0.732
Promotion	0.256	0.790	0.424	0.732	0

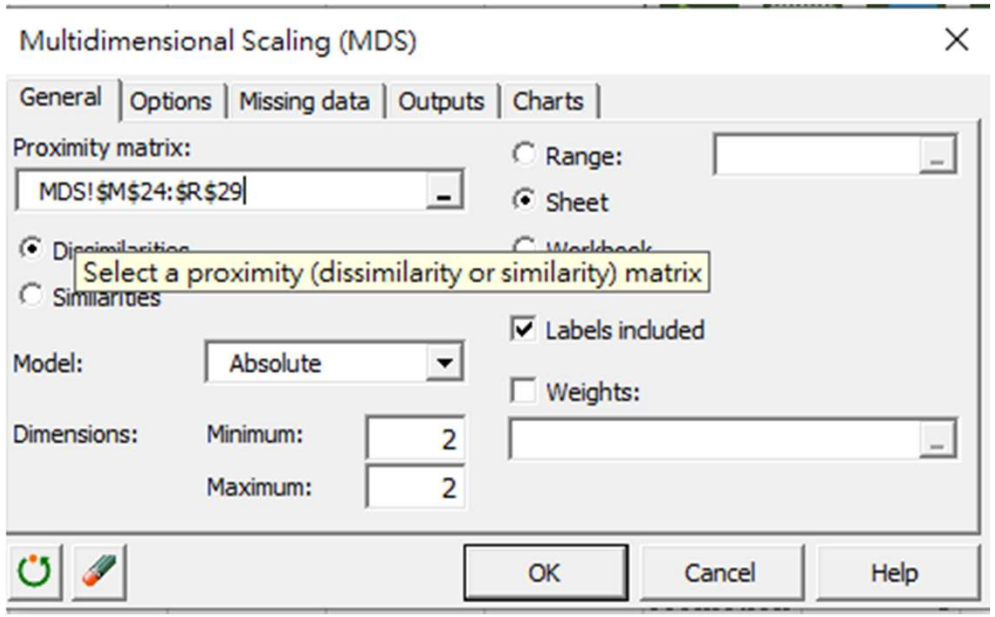

	Dim1	Dim2
Product	0.356	-0.407
Servcies	-0.100	0.521
Device	0.035	0.181
Convience	-0.507	-0.095
Promotion	0.215	-0.200

Multi Dimensional Scaling(MDS)

Proximity matrix (Euclidean distance):

	Starbuck	85C	Crown	Browm	CafeOne
Starbuck	0	0.113	0.840	2.168	2.298
85C	0.113	0	0.868	2.102	2.233
Crown	0.840	0.868	0	1.787	1.901
Browm	2.168	2.102	1.787	0	0.137
CafeOne	2.298	2.233	1.901	0.137	0

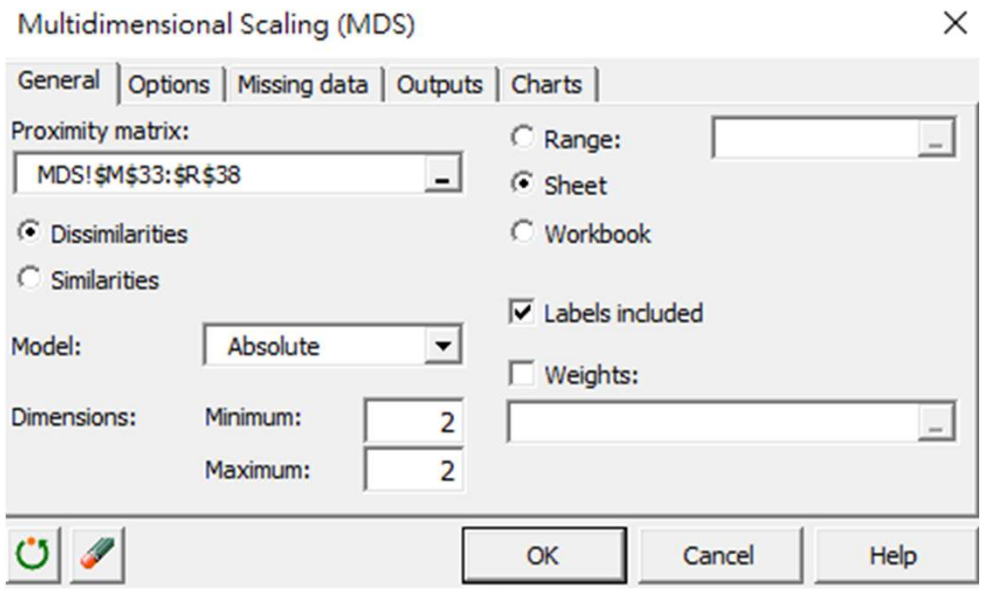

	Starbuck	85C	Crown	Browm	CafeOne
Starbuck	0	0.113	0.840	2.168	2.298
85C	0.113	0	0.868	2.102	2.233
Crown	0.840	0.868	0	1.787	1.901
Browm	2.168	2.102	1.787	0	0.137
CafeOne	2.298	2.233	1.901	0.137	0

	Dim1	Dim2
Starbuck	1.005	0.154
85C	0.961	0.053
Crown	0.336	0.658
Browm	-1.082	-0.434
CafeOne	-1.219	-0.431

	Dim1	Dim2
Starbuck	1.005	0.154
85C	0.961	0.053
Crown	0.336	0.658
Browm	-1.082	-0.434
CafeOne	-1.219	-0.431
Product	0.356	-0.407
Servcies	-0.100	0.521
Device	0.035	0.181
Convience	-0.507	-0.095
Promotion	0.215	-0.200

Multi Dimensional Scaling(MDS)

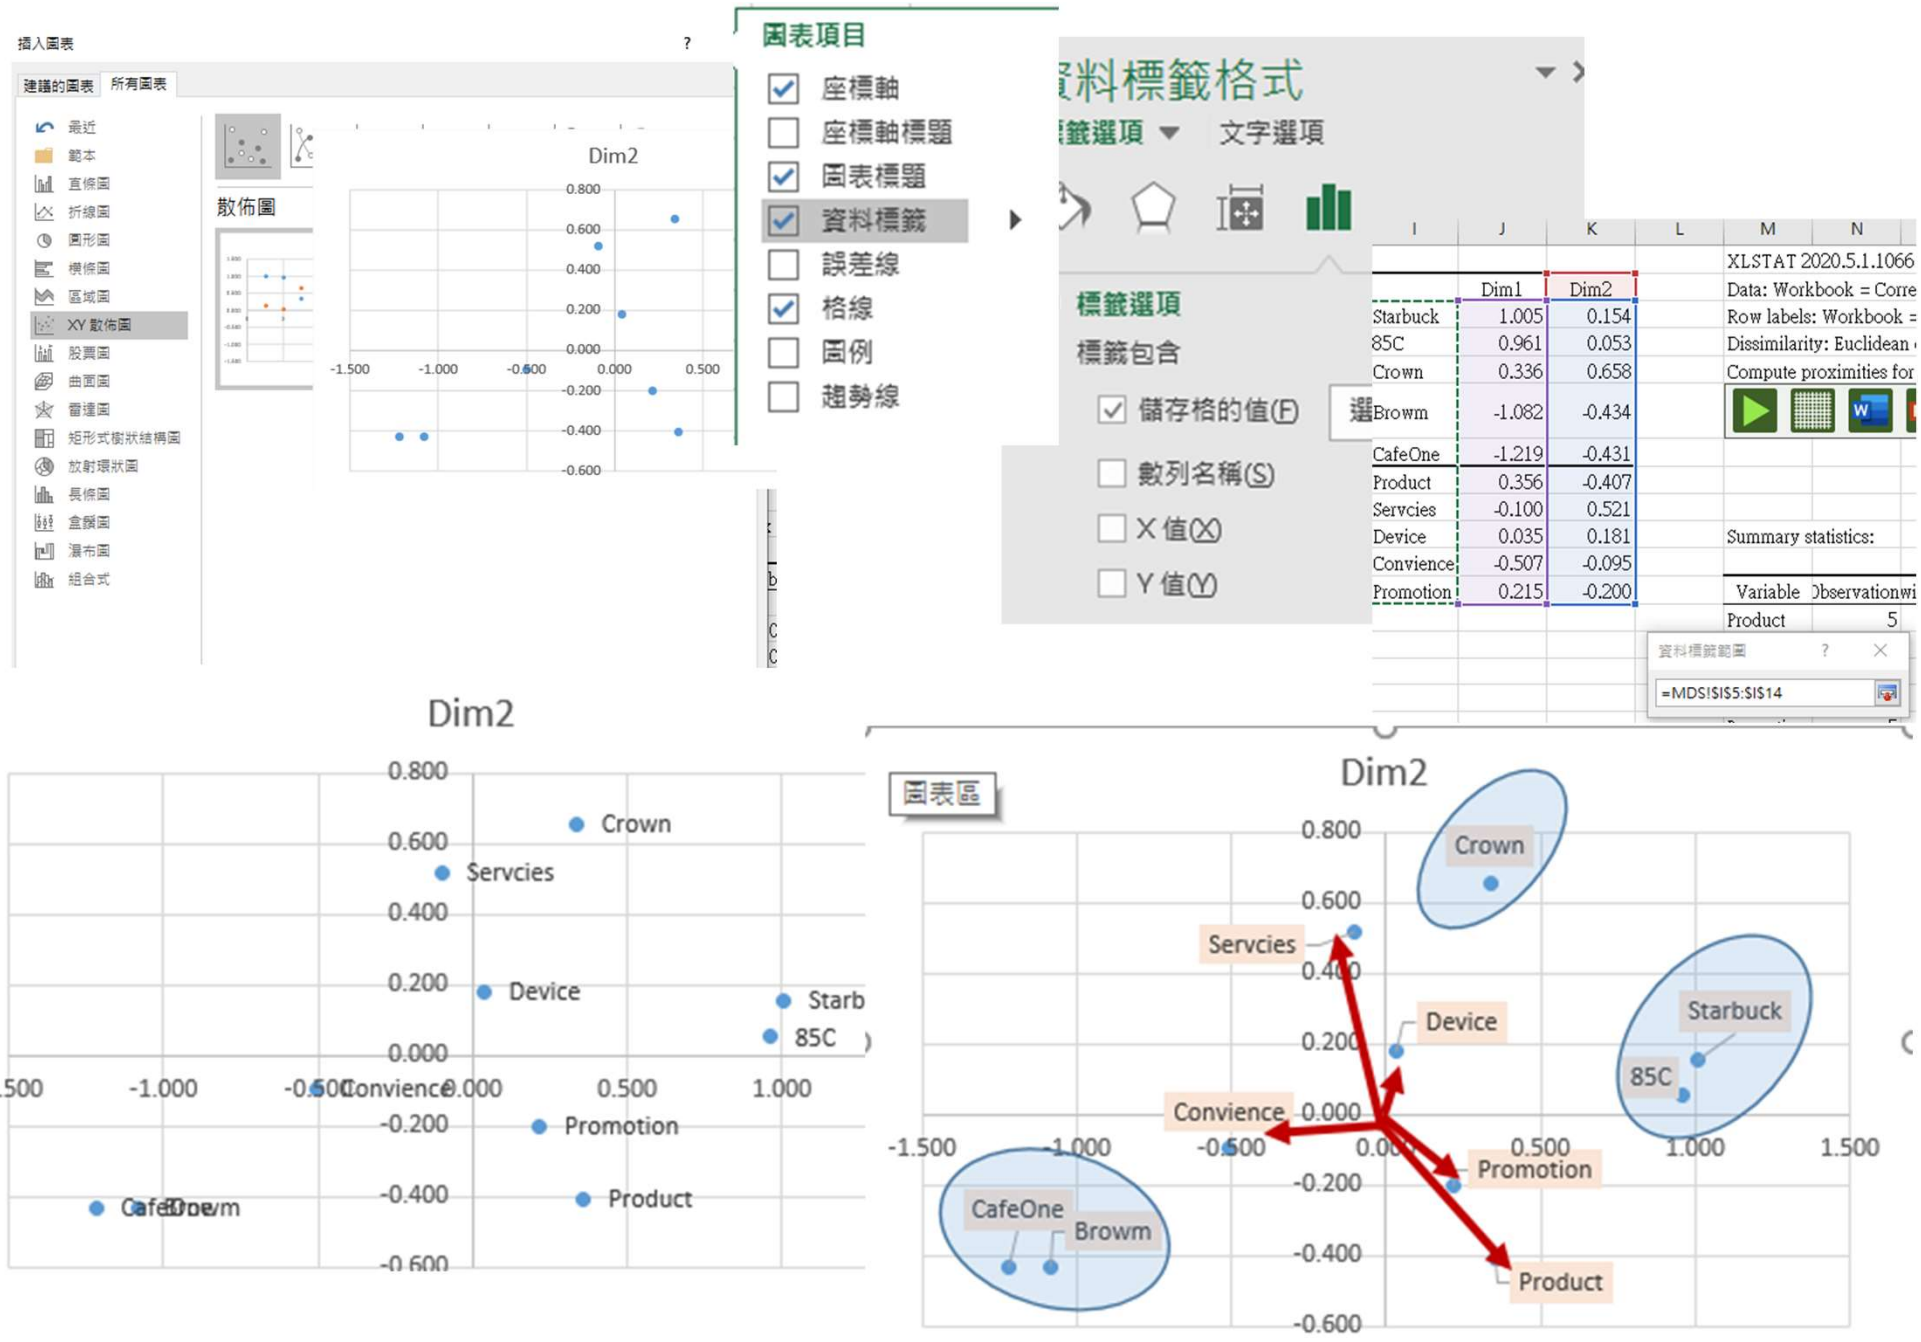

Association Rule (關聯法則)

	柳橙汁	碳酸飲料	清潔劑	牛奶	洗衣精	底片	洋芋片
1	1	1	1	0	0	0	0
2	1	0	1	1	0	0	0
3	1	1	0	0	1	0	0
4	0	1	0	0	0	1	0
5	0	1	0	0	0	0	1

分析工具:

XLSTA (example)
WEKA (example)
R

Association Rule (關聯法則)

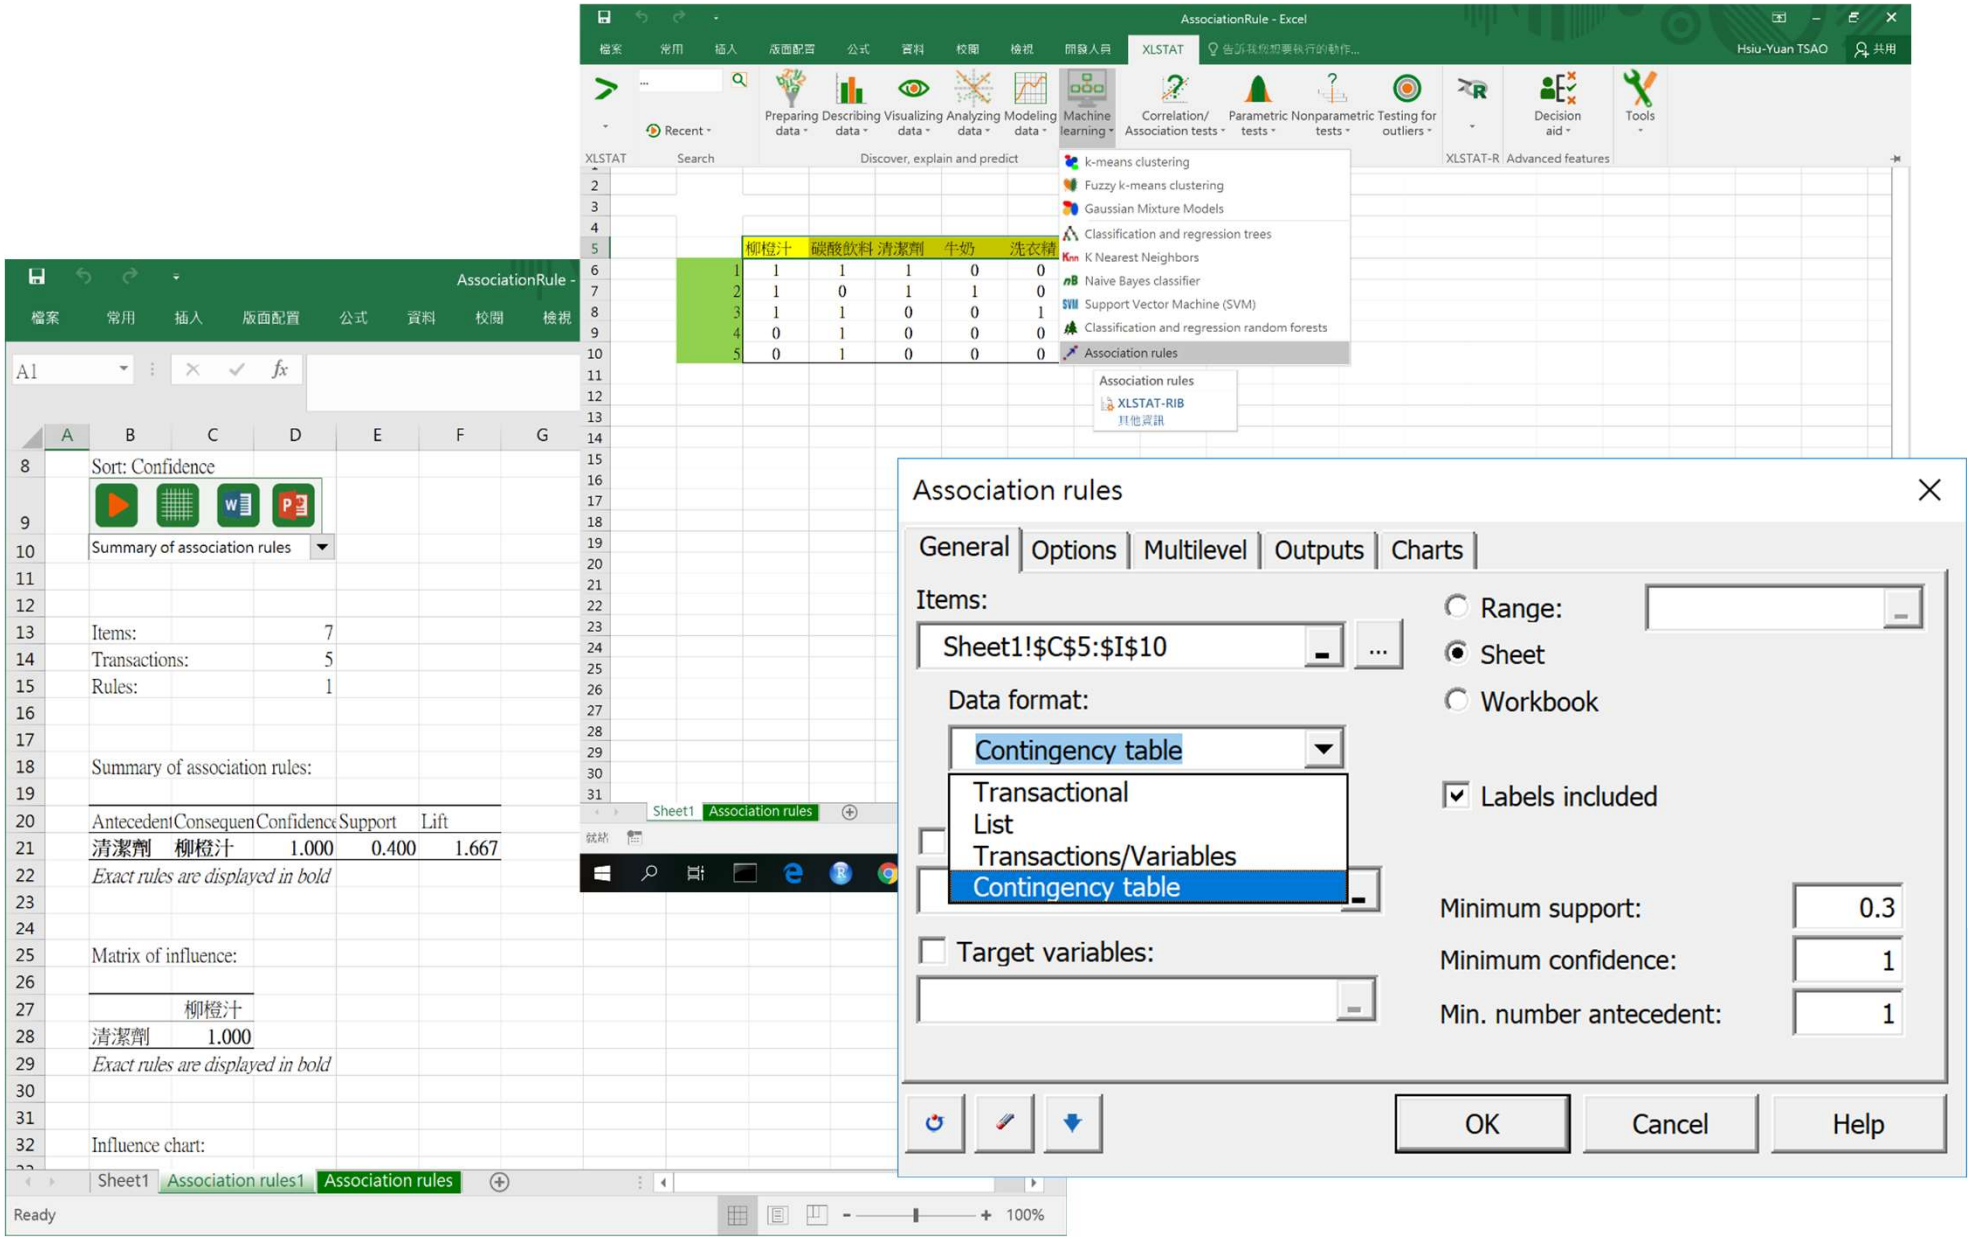

機器學習範例

https://studio.azureml.net

Azure Machine Learning Studio

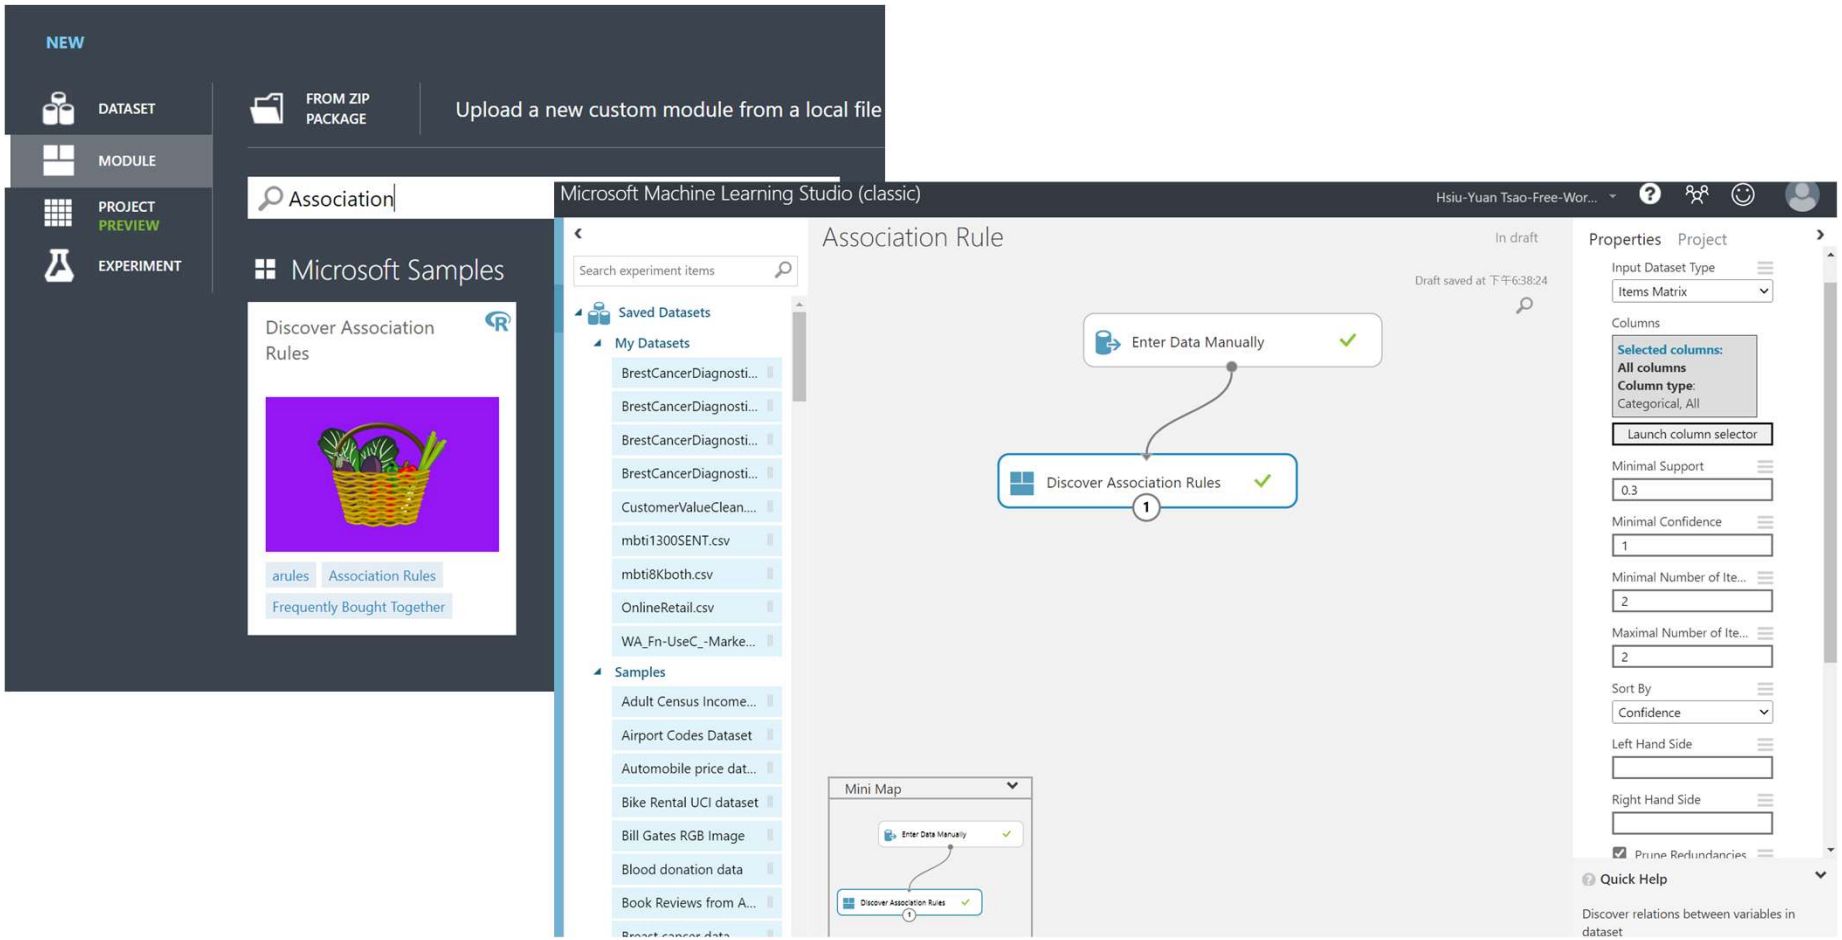

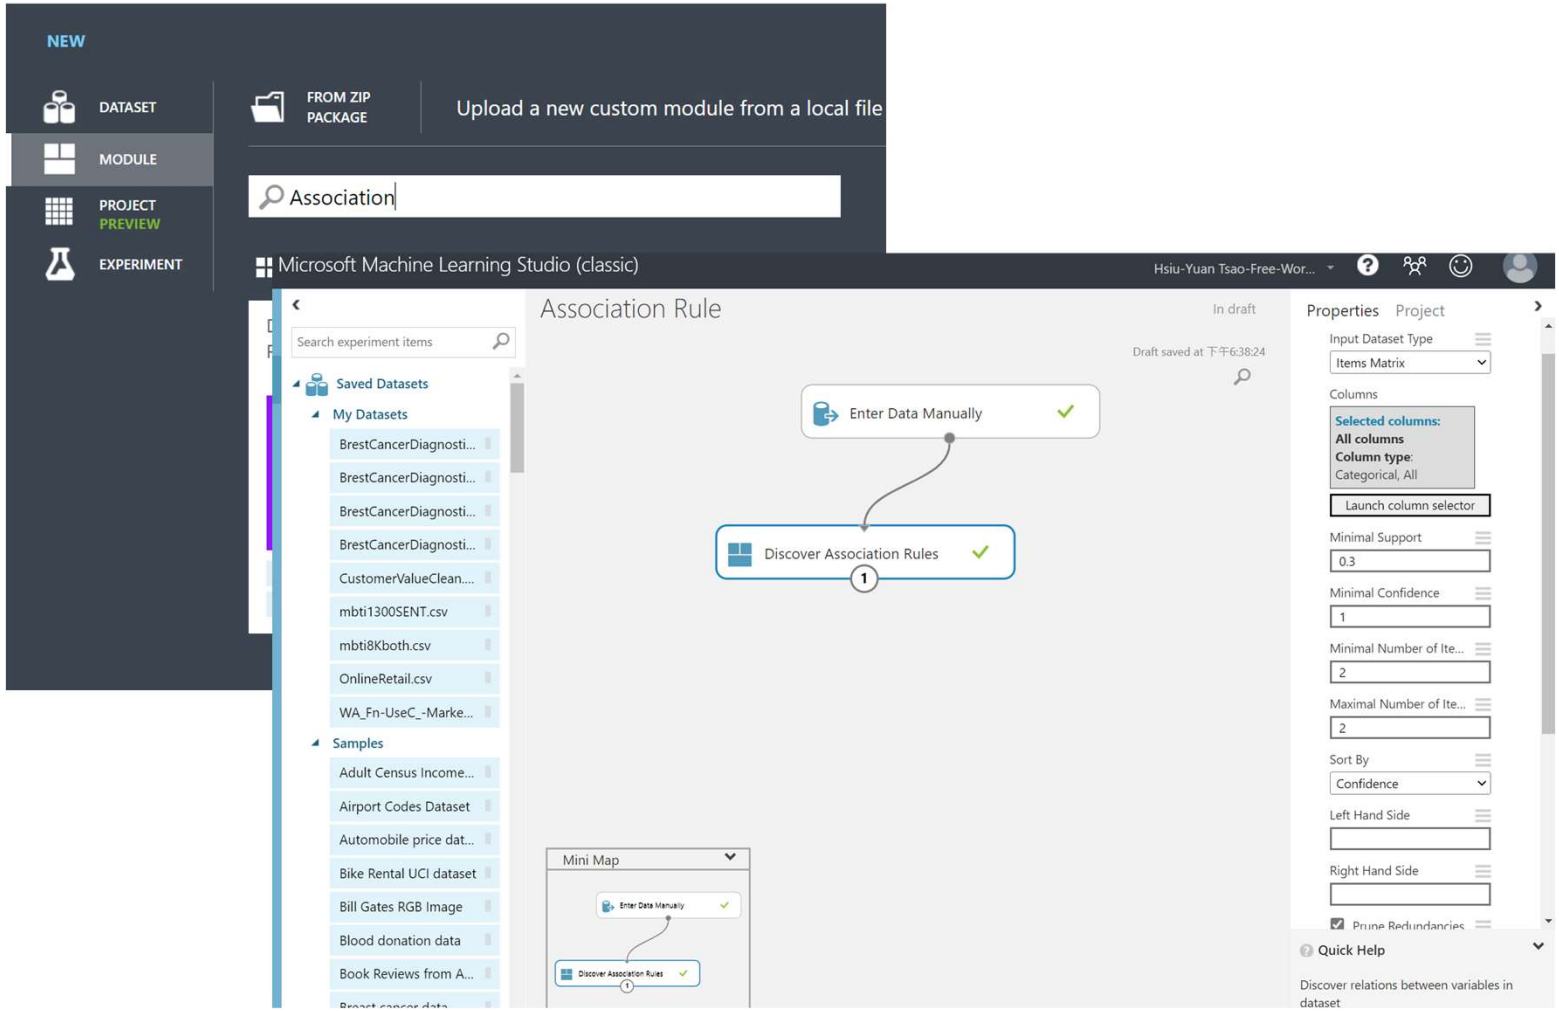
NEW
DATASET
MODULE
PROJECT
PREVIEW
EXPERIMENT
FROM ZIP
PACKAGE
Upload a new custom module from a local file
Association
Microsoft Machine Learning Studio (classic)
Hsiu-Yuan Tsao-Free-Wor...
Search experiment items
Saved Datasets
My Datasets
BrestCancerDiagnosti...
BrestCancerDiagnosti...
BrestCancerDiagnosti...
BrestCancerDiagnosti...
CustomerValueClean....
mbti1300SENT.csv
mbti8Kboth.csv
OnlineRetail.csv
WA_Fn-UseC_-Marke...
Samples
Adult Census Income...
Airport Codes Dataset
Automobile price dat...
Bike Rental UCI dataset
Bill Gates RGB Image
Blood donation data
Book Reviews from A...
Association Rule
In draft
Draft saved at 下午6:38:24
Enter Data Manually
Discover Association Rules
1
Mini Map
Properties
Project
Input Dataset Type
Items Matrix
Columns
Selected columns:
All columns
Column type:
Categorical, All
Launch column selector
Minimal Support
0.3
Minimal Confidence
1
Minimal Number of Ite...
2
Maximal Number of Ite...
2
Sort By
Confidence
Left Hand Side
Right Hand Side
Prune Redundancies
Quick Help
Discover relations between variables in dataset

Recommended System KNN推薦系統

Customer	Age	Income	Purchase Product
1	45	46000	Book
2	39	100000	TV
3	35	38000	DVD
4	69	150000	Car Cover
5	58	51000	???

Step 1: Determine the Distance Formula
Distance= SQRT(((58- AGE)/(69-35))^2) + (51000- Income) / (150000 - 38000))^2)

Step 2: Calcuate the Score				
Customer	Age	Income	Purchase Product	
1	0.38495	46	Book	1
2	0.709711	100	TV	3
3	0.686356	38	DVD	2
4	0.941276	150	Car Cover	4
5	0	51	???	

KNN Example

Decision Tree (決策樹)
信用評等範例

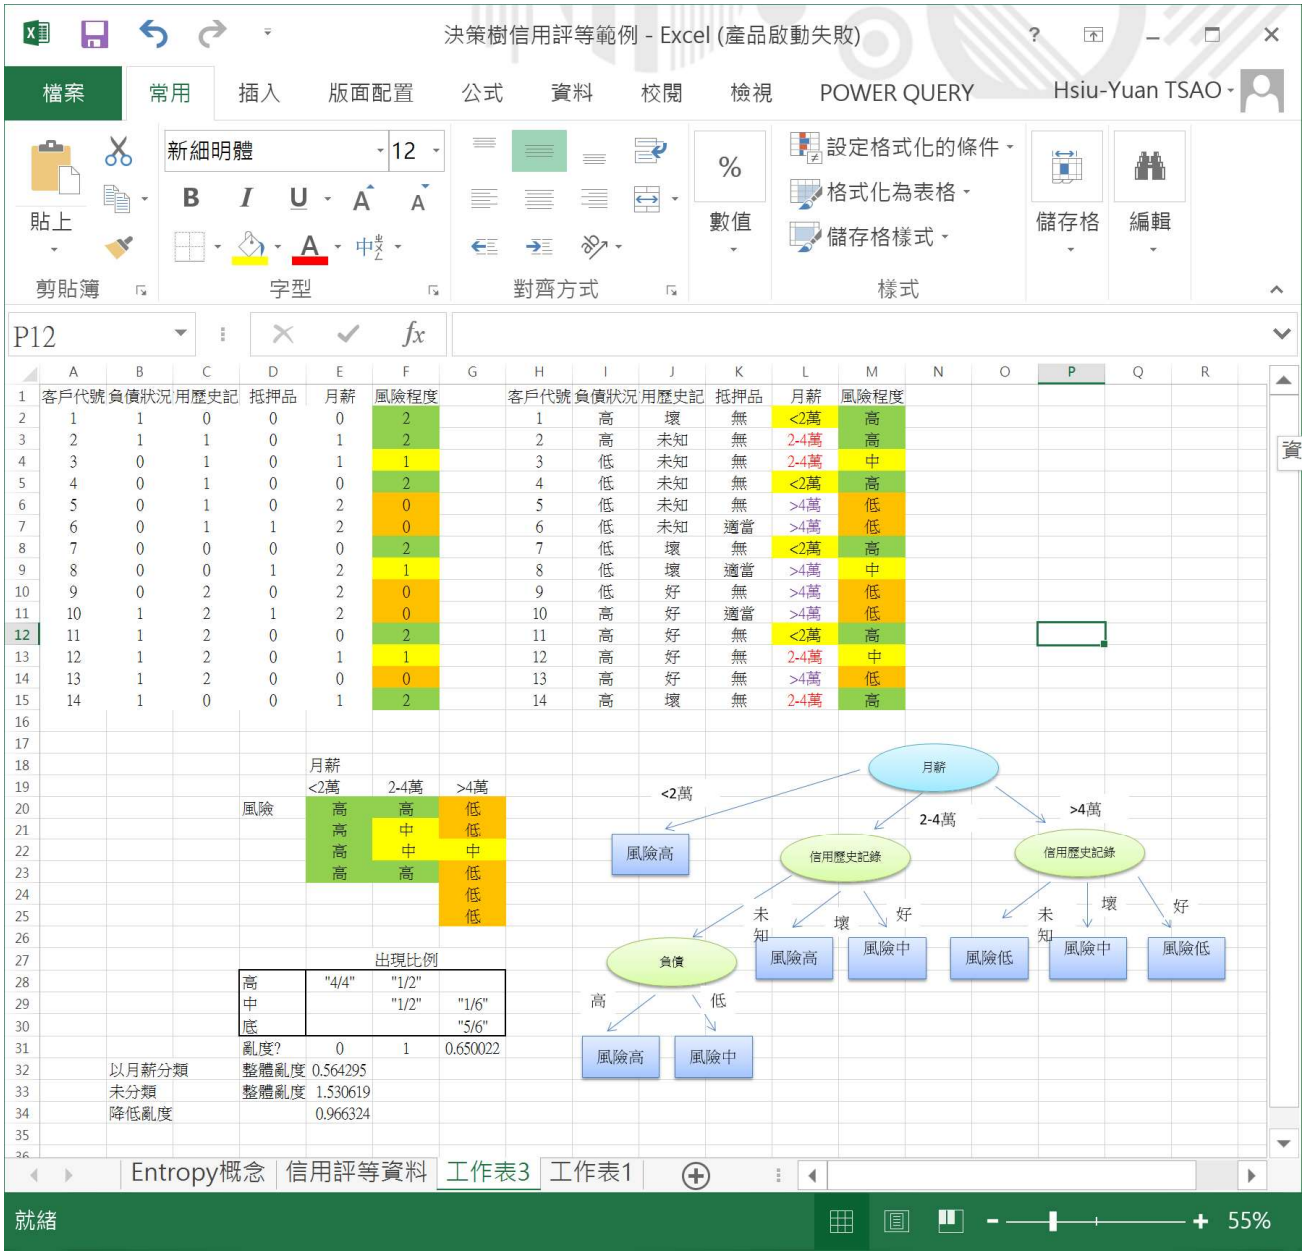

資訊與熵

對大多數的讀者來說，熱力學是一門抽象難懂的學問，
有關熱力學難懂的笑話很多，最常被引用的一段是：
「三個話題：政治、宗教及熱力學是不宜與朋友談論的。」

	a^x=b	log(x,b)				
	10^2	2				
	100					
x	0.00001	0.25	0.5	0.75	1	
log(x,2)	-16.60964047	-2	-1	-0.41504	0	

公正銅板出現正反機率為1/2		
正	"(1/2)*LOG(1/2,2)'	0.5
反	"(1/2)*LOG(1/2,2)'	0.5
Entropy		1

何者亂度較大?

何謂亂度?

不公正銅板出現正機率為3/4		
正	"(3/4)*LOG(3/4,2)"	0.311278
反	"(1/4)*LOG(1/4,2)'	0.5
Entropy		0.811278

不公正銅板出現正機率為100%		
正	"(1)*LOG(1,2)"	0
反	"(0)*LOG(0,2)'	0
Entropy		0

客戶代號	負債狀況	信用歷史記錄	抵押品	月薪	風險程度
1	高	壞	無	<2萬	高
2	高	未知	無	2-4萬	高
3	低	未知	無	2-4萬	中
4	低	未知	無	<2萬	高
5	低	未知	無	>4萬	低
6	低	未知	適當	>4萬	低
7	低	壞	無	<2萬	高
8	低	壞	適當	>4萬	中
9	低	好	無	>4萬	低
10	高	好	適當	>4萬	低
11	高	好	無	<2萬	高
12	高	好	無	2-4萬	中
13	高	好	無	>4萬	低
14	高	壞	無	2-4萬	高

風險程度

高	中	低			
"6/14"	"3/14"	"5/14"			
0.43	0.21	0.36	1.00		
Entropy=?					
0.52388247	0.476226947	0.53051	1.530619	亂度大嗎?	何謂亂度?

客戶代號	負債狀況	用歷史記	抵押品	月薪	風險程度
1	1	0	0	0	2
2	1	1	0	1	2
3	0	1	0	1	1
4	0	1	0	0	2
5	0	1	0	2	0
6	0	1	1	2	0
7	0	0	0	0	2
8	0	0	1	2	1
9	0	2	0	2	0
10	1	2	1	2	0
11	1	2	0	0	2
12	1	2	0	1	1
13	1	2	0	0	0
14	1	0	0	1	2

客戶代號	負債狀況	用歷史記	抵押品	月薪	風險程度
1	高	壞	無	<2萬	高
2	高	未知	無	2-4萬	高
3	低	未知	無	2-4萬	中
4	低	未知	無	<2萬	高
5	低	未知	無	>4萬	低
6	低	未知	適當	>4萬	低
7	低	壞	無	<2萬	高
8	低	壞	適當	>4萬	中
9	低	好	無	>4萬	低
10	高	好	適當	>4萬	低
11	高	好	無	<2萬	高
12	高	好	無	2-4萬	中
13	高	好	無	>4萬	低
14	高	壞	無	2-4萬	高

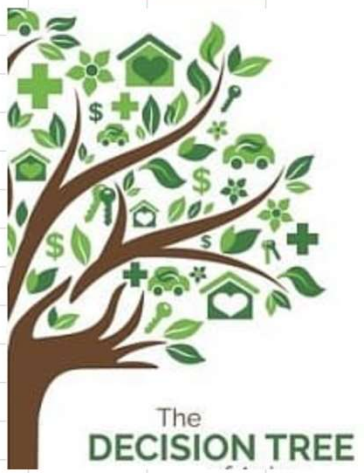

	月薪		
	<2萬	2-4萬	>4萬
風險	高	高	低
	高	中	低
	高	中	中
	高	高	低
			低
			低

		出現比例		
	高	"4/4"	"1/2"	
	中		"1/2"	"1/6"
	底			"5/6"
	亂度?	0	1	0.650022
以月薪分類	整體亂度	0.564295		
未分類	整體亂度	1.530619		
降低亂度		0.966324		

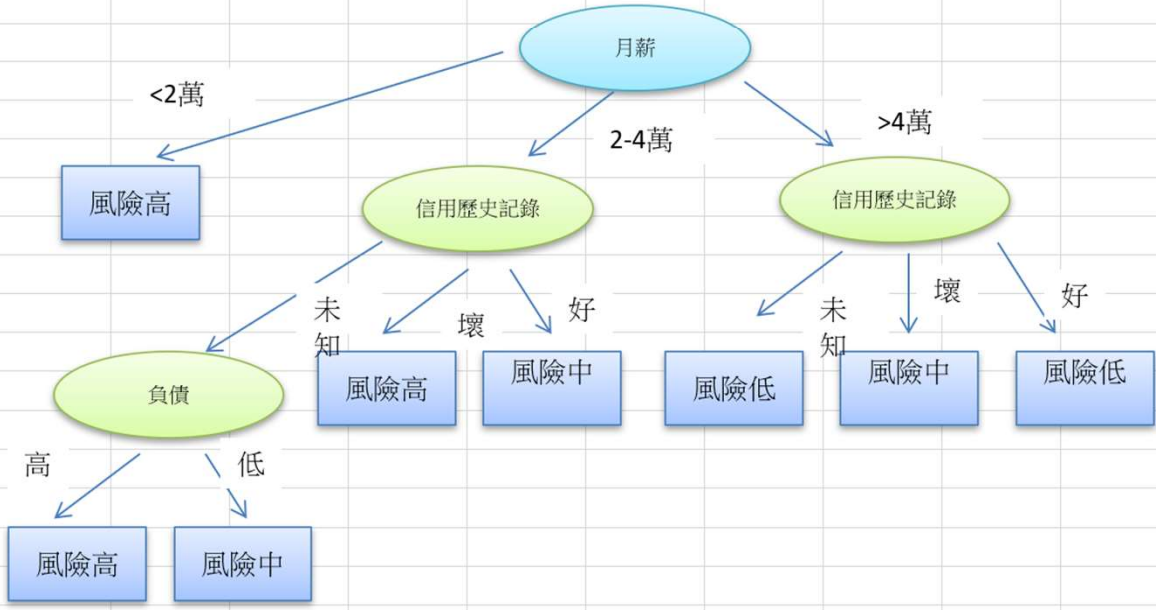

常見的決策樹演算法比較

演算法	資料屬性	分割規則	修剪樹規則
ID3	離散型	Entropy, Gain Ratio	Predicted Error Rate
C4.5	離散型	Gain Ratio	Predicted Error Rate
CHAID	離散型	Chi-Square Test	No Pruning
CART	離散與連續型	Gini Index	Entire Error Rate (Training and Predicted)

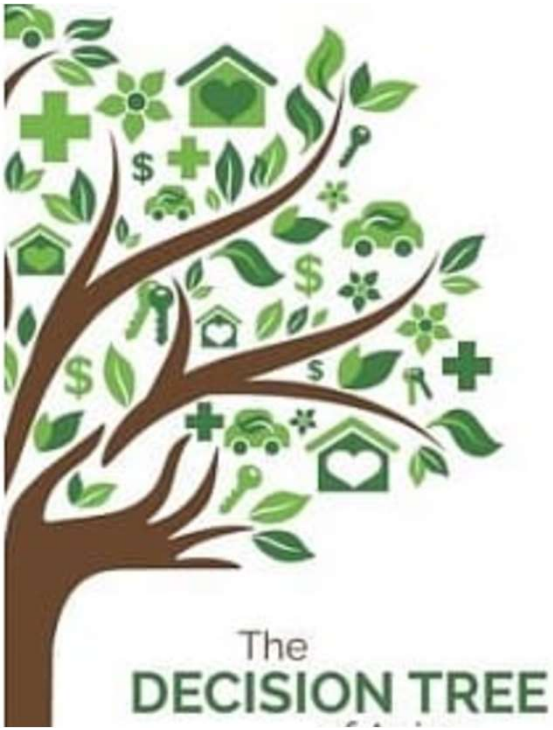

To give a proper background for `rpart` *package and* `rpart` *method with* `caret` *package:*

1. If you use the `rpart` package directly, it will construct the complete tree by default. If you want to prune the tree, you need to provide the optional parameter `rpart.control` which controls the fit of the tree. R documentation below, eg.:

```
rpart(formula, data, method, control = prune.control)

prune.control = rpart.control(minsplit = 20,
                minbucket =  round(minsplit/3), cp = 0.01,
                maxcompete = 4, maxsurrogate = 5, usesurrogate = 2,
                xval = 10, surrogatestyle = 0, maxdepth = 30 )
```

these are the hyper parameters you can tune to obtain a pruned tree.

One followed way is to not provide the ***cp*** i.e complexity parameter and perform cross validation (xval), something like:

```
rpart.control(minsplit = 20, minbucket = round(minsplit/3), xval = 10)
```

complexity parameter *(cp)* can be thought of as a measure of *complexity/ no of splits* of your model and you want to increase complexity until your model generalizes to new observations. i.e. *regularization*

Therefore evaluate the *cross validated error vs cp* and choose the *cp* that gives the good value (cp_good).

Finally, add it as your control parameter i.e. *rpart.control(cp = cp_good)* or use the prune function i.e. *prune(fit, cp = cp_good)* to get the desired tree.

2. `caret` package on the other hand already implements the `rpart` method with `cp` as the tuning parameter. `caret` by default will prune your tree based on a default run it makes on a default parameter grid (even if you don't supply any `tuneGrid` and `trControl` while training your model:

```
model <- train(data,
               labels,
               method = "rpart")
```

決策樹挑選變數常用的測量值

常見的資訊量（衡量資料純度）：

- **Entropy (熵):**

$$I_H(t) = -\sum_{i=1}^{c} p(i|t) \log_2 p(i|t)$$

其中，H代表Homogeneity(同質性)。
當Entropy=0表示completely homogeneous(pure)，而當Entropy=1則表示資料為50%-50%之組成，是不純的(impurity)。

- **Gini Impurity (Gini不純度):**

$$I_G(t) = \sum_{i=1}^{c} p(i|t)(1 - p(i|t)) = 1 - \sum_{i=1}^{c} p(i|t)^2$$

其中，G則代表Gini Impurity。

- **Information Gain (資訊增益):** 則衡量節點切割前後資料純度的變化。節點的選擇，當選IG值越大的變數為佳。

$$IG = Info(D) - Info_A(D)$$

其中，$Info(D)$為原始資料純度，而$Info_A(D)$則表示使用A規則切割後的資料純度。

$$Info_A(D) = \sum_{j=1}^{m} \frac{N_j}{N_p} Info(D_j)$$

當m=2，即為二元分類時，

$$IG = Info(D) - \frac{N_{left}}{N_p} Info(D_{left}) - \frac{N_{right}}{N_p} Info(D_{right})$$

There are two main ways to do hyper parameter tuning using the `train()` :

1. Set the `tuneLength`
2. Define and set the `tuneGrid`

Grid Search: Automatic Grid

There are two ways to tune an algorithm in the Caret R package, the first is by allowing the system to do it automatically. This can be done by setting the tuneLength to indicate the number of different values to try for each algorithm parameter.

This only supports integer and categorical algorithm parameters, and it makes a crude guess as to what values to try, but it can get you up and running very quickly.

The following recipe demonstrates the automatic grid search of the size and k attributes of LVQ with 5 (*tuneLength=5*) values of each (25 total models).

```
# ensure results are repeatable
set.seed(7)
# load the library
library(caret)
# load the dataset
data(iris)
# prepare training scheme
control <- trainControl(method="repeatedcv", number=10, repeats=3)
# train the model
model <- train(Species~., data=iris, method="lvq", trControl=control, tuneLength=5
# summarize the model
print(model)
```

The final values used for the model were size = 10 and k = 1.

Grid Search: Manual Grid

The second way to search algorithm parameters is to specify a tune grid manually. In the grid, each algorithm parameter can be specified as a vector of possible values. These vectors combine to define all the possible combinations to try.

The recipe below demonstrates the search of a manual tune grid with 4 values for the size parameter and 5 values for the k parameter (20 combinations).

Grid search with the caret r package

```
set.seed(7)
# load the library
library(caret)
# load the dataset
data(iris)
# prepare training scheme
control <- trainControl(method="repeatedcv", number=10, repeats=3)
# design the parameter tuning grid
grid <- expand.grid(size=c(5,10,20,50), k=c(1,2,3,4,5))
# train the model
model <- train(Species~., data=iris, method="lvq", trControl=control, tuneGrid=gri
# summarize the model
print(model)
```

The final values used for the model were size = 50 and k = 5.

CARET Package

機器學習演算法資料前處理心法

To increase the predictive power by modifying variables or
creating new variables from existing variables.
This specific task is called Feature Engineering .

This is perhaps the single most important activity in the entire process and decides the success or failure
of a classification problem.

This part can not be put into any template
as it varies on a case by case basis and one requires a lot of experience and domain expertise
to gain a mastery of this skill.

機器學習演算法資料前處理心法 – 訓練與測試集

```
#============== 產生 訓練資料及測試資料集 =================
# Create the training and test datasets
set.seed(100)

# Step 1: Get row numbers for the training data
trainRowNumbers <- createDataPartition(credit$Response, p=0.8, list=FALSE)

# Step 2: Create the training  dataset
trainData <- credit[trainRowNumbers,-1]

# Step 3: Create the test dataset
testData <- credit[-trainRowNumbers,-1]

# Store X (自變數) and Y (依變數)for later use.
x = trainData[, -4]
y = trainData$Response
```

```
library(caTools)

sample <- sample.split(df$Customer, SplitRatio = .7)

trainX <- as.matrix(subset(encodedDF, sample == TRUE))
trainY <- as.double(as.matrix(subset(df$Engaged, sample == TRUE)))

testX <- as.matrix(subset(encodedDF, sample == FALSE))
testY <- as.double(as.matrix(subset(df$Engaged, sample == FALSE)))
```

```
set.seed(123)
train_sample <- sample(1000, 900)
credit_train <- credit[train_sample, ]
credit_test <- credit[-train_sample, ]
```

機器學習演算法資料前處理心法 – 交叉驗證(Cross Validation)

```
#-----------------------------------------------------------------
#我們爲了避免模型過度擬合(overfitting)，故要利用K-fold Cross-Validation#
#的方法進行交叉驗證，我們使用caret這個套件，而K先設定為10次~
#-----------------------------------------------------------------
train_control <- trainControl(method="cv", number=10)
train_control.model <- train(default~.,
                             data=credit_train,
                             method="C5.0",
                             trControl=trai

train_control.model
```

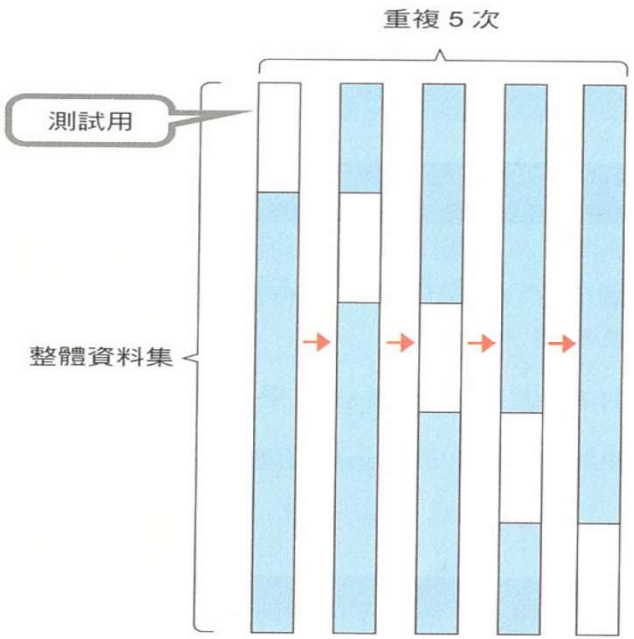

▲ 圖 4.1.6　交叉驗證

機器學習演算法資料前處理心法

Categorical

Some algorithms (ex: decision tree) can work with categorical data directly.

Many machine learning algorithms cannot operate on label data directly. They require all input variables and output variables to be numeric.
Logistic regression will not accept categorical variables .
For this we need to transform those variables using "one hot encoding"
In traditional term used in Statistics named "Dummy Variable"

Numerical

It is always advisable to standardize the numeric variables before feeding them to a PCA algorithm/Kmean or a Neural Network model

(Efficient vs. Limitation)

One-Hot-Encoding– option 1

```
# Using model.matrix
new_df <- df
new_df$city <- factor(new_df$city, exclude = NULL)
new_df$hml <- factor(new_df$hml, exclude = NULL)
new_df <- model.matrix(~.-1, data = new_df[, c("city", "hml")],
                       contrasts.arg = list(
                         city = contrasts(new_df$city, contrasts = FALSE),
                         hml = contrasts(new_df$hml, contrasts = FALSE)
                       ))
head(new_df[, 1:3])
##   cityAlameda cityAmes cityApple Valley
## 1           0        0                0
## 2           0        0                0
## 3           0        0                0
## 4           0        0                0
## 5           0        0                0
## 6           0        0                0
```

One-Hot-Encoding option 2

```
library(caret)
## Loading required package: lattice
## Loading required package: ggplot2
new_df <- df
new_df$city <- factor(new_df$city, exclude = NULL)
new_df$hml <- factor(new_df$hml, exclude = NULL)
new_df$city <- addNA(new_df$city)
new_df$hml <- addNA(new_df$hml)
dv <- caret::dummyVars(" ~ city + hml", data = new_df)
new_df <- data.frame(predict(dv, newdata = df))
head(new_df[, 1:3])
##   city.Alameda city.Ames city.Apple.Valley
## 1            0         0                0
## 2            0         0                0
## 3            0         0                0
## 4            0         0                0
## 5            0         0                0
## 6            0         0                0
detach("package:caret", unload = TRUE)
```

One-Hot-Encoding option 3

```
library(vtreat)
tz <- vtreat::designTreatmentsZ(df, c("city", "hml"))
## [1] "vtreat 1.5.1 inspecting inputs Mon Feb 03 00:16:33 2020"
## [1] "designing treatments Mon Feb 03 00:16:33 2020"
## [1] " have initial level statistics Mon Feb 03 00:16:33 2020"
## [1] " scoring treatments Mon Feb 03 00:16:33 2020"
## [1] "have treatment plan Mon Feb 03 00:16:34 2020"
new_df <- vtreat::prepare(tz, df, extracols = "target")
head(new_df[, 1:5])
##   city_catP hml_catP city_lev_NA city_lev_x_Alameda city_lev_x_Ames
## 1    0.0090   0.3174           0                  0                0
## 2    0.0094   0.3090           0                  0                0
## 3    0.0106   0.3090           0                  0                0
## 4    0.0116   0.3236           0                  0                0
## 5    0.0106   0.3236           0                  0                0
## 6    0.0094   0.3090           0                  0                0
detach("package:vtreat", unload = TRUE)
```

standardize the numeric variables

```
rankDF <- customerDF %>%
  mutate(TotalSales=rank(TotalSales),
         OrderCount=rank(OrderCount, ties.method="first"),
         AvgOrderValue=rank(AvgOrderValue))
```

```
normalizedDF <- rankDF %>%
  mutate(TotalSales=scale(TotalSales),
         OrderCount=scale(OrderCount),
         AvgOrderValue=scale(AvgOrderValue))
```

Ensemble Machine Learning

集成學習

Bagging

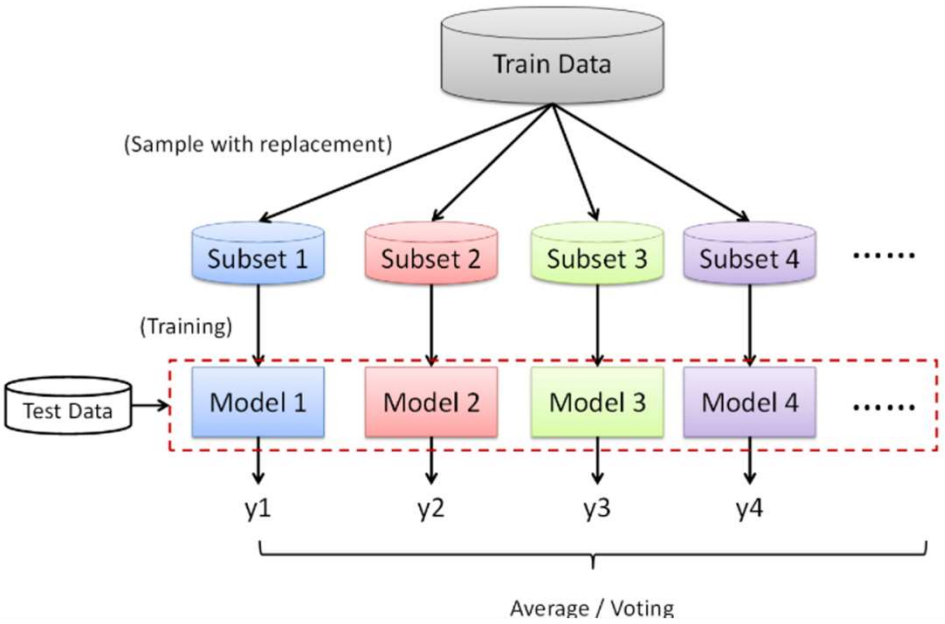

- Bootstrap aggregating (Bagging)，從字面上來看，就是將資料裝成一個袋子一個袋子(Bag)，然後將每個袋子的結果結合在一起。
- 演算法上，是將樣本重複抽樣(取後放回)，產生多個子資料集(Subsets)後，依序建立多個模型，最後再將所有模型的結果彙整在一起。

Boosting

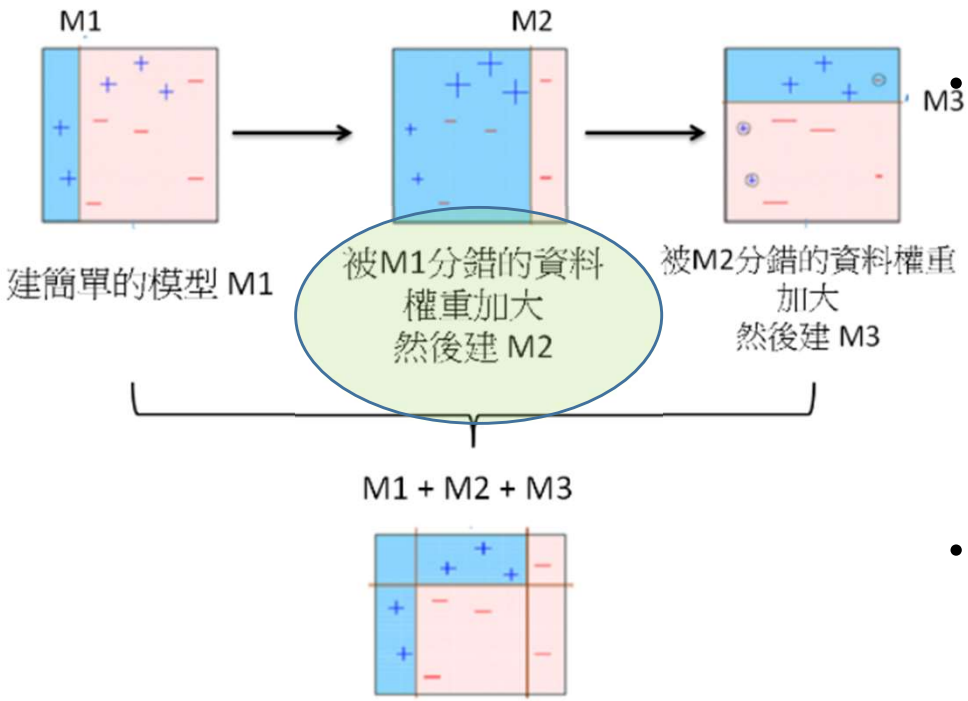

- 「三個臭皮匠，勝過一個諸葛亮」
- M1 M2 M3 如果太複雜(太強)，那彼此之間就會互相干擾，影響最後預測/分類結果；唯有彼此都是「弱模型」，才能好好專注在自己本身的預測/分類，然後再把彼此的成果結合一起，這就是 Boosting 的概念。
- XGboost 被譽為是「Kaggle 神器」。原因無他，就是因為每年的得名隊伍，使用 XGboost 的團隊基幾乎大多數！

Stacking

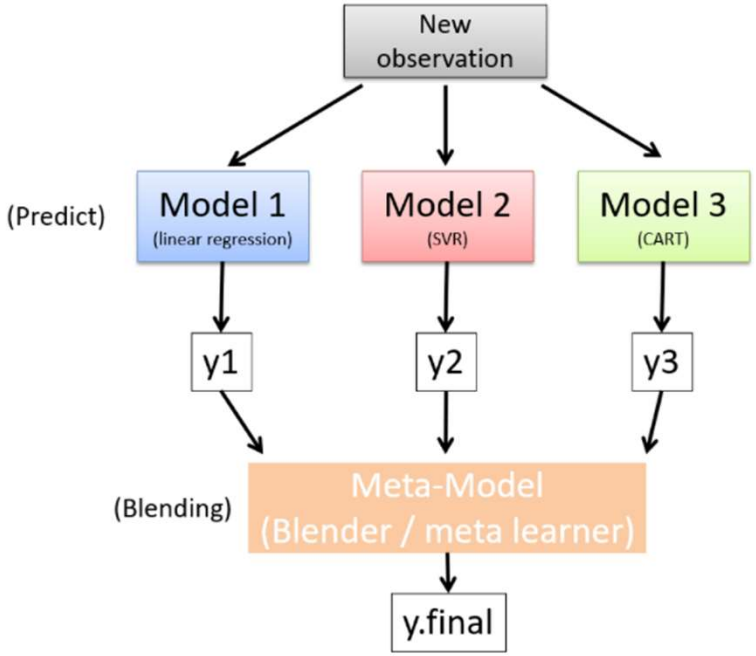

- 「在訓練**多個模型**、得到多個預測值/分類結果後，與其使用投票法(hard voting)或平均法(average)將這些結果整合(ensemble)起來，為何不多訓練一個模型來做這樣的整合呢？」

How to Discovery Insight via Text Mining

行銷理論、商業與人生
學術與實務的對話

曹修源 教授

04/2021

- Concept, Technology, and Application

NCHU Marketing 國立中興大學行銷學系
Department of Marketing, National Chung Hsing University

Curtin University

USC University of Southern California

Framework of Textual Analytics

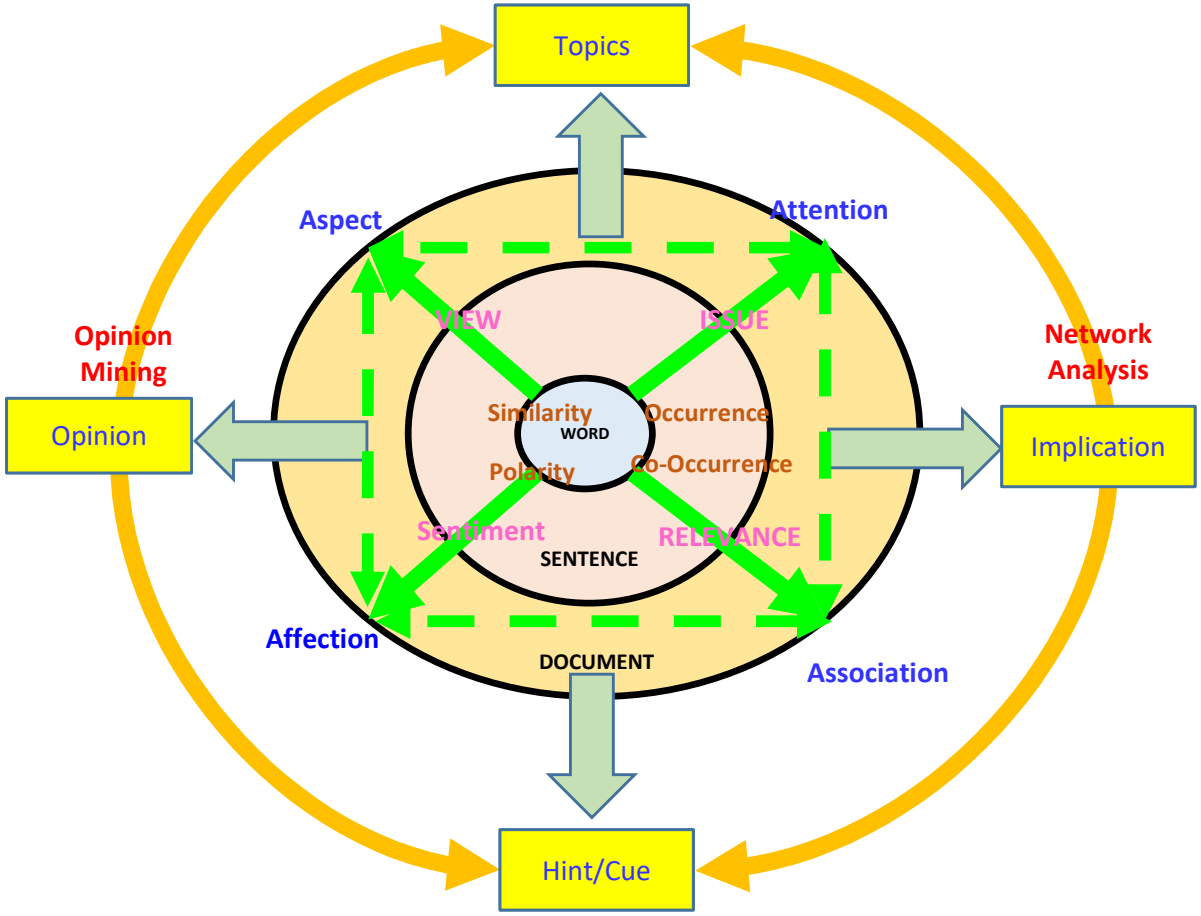

The Structural Textual Data Analytics

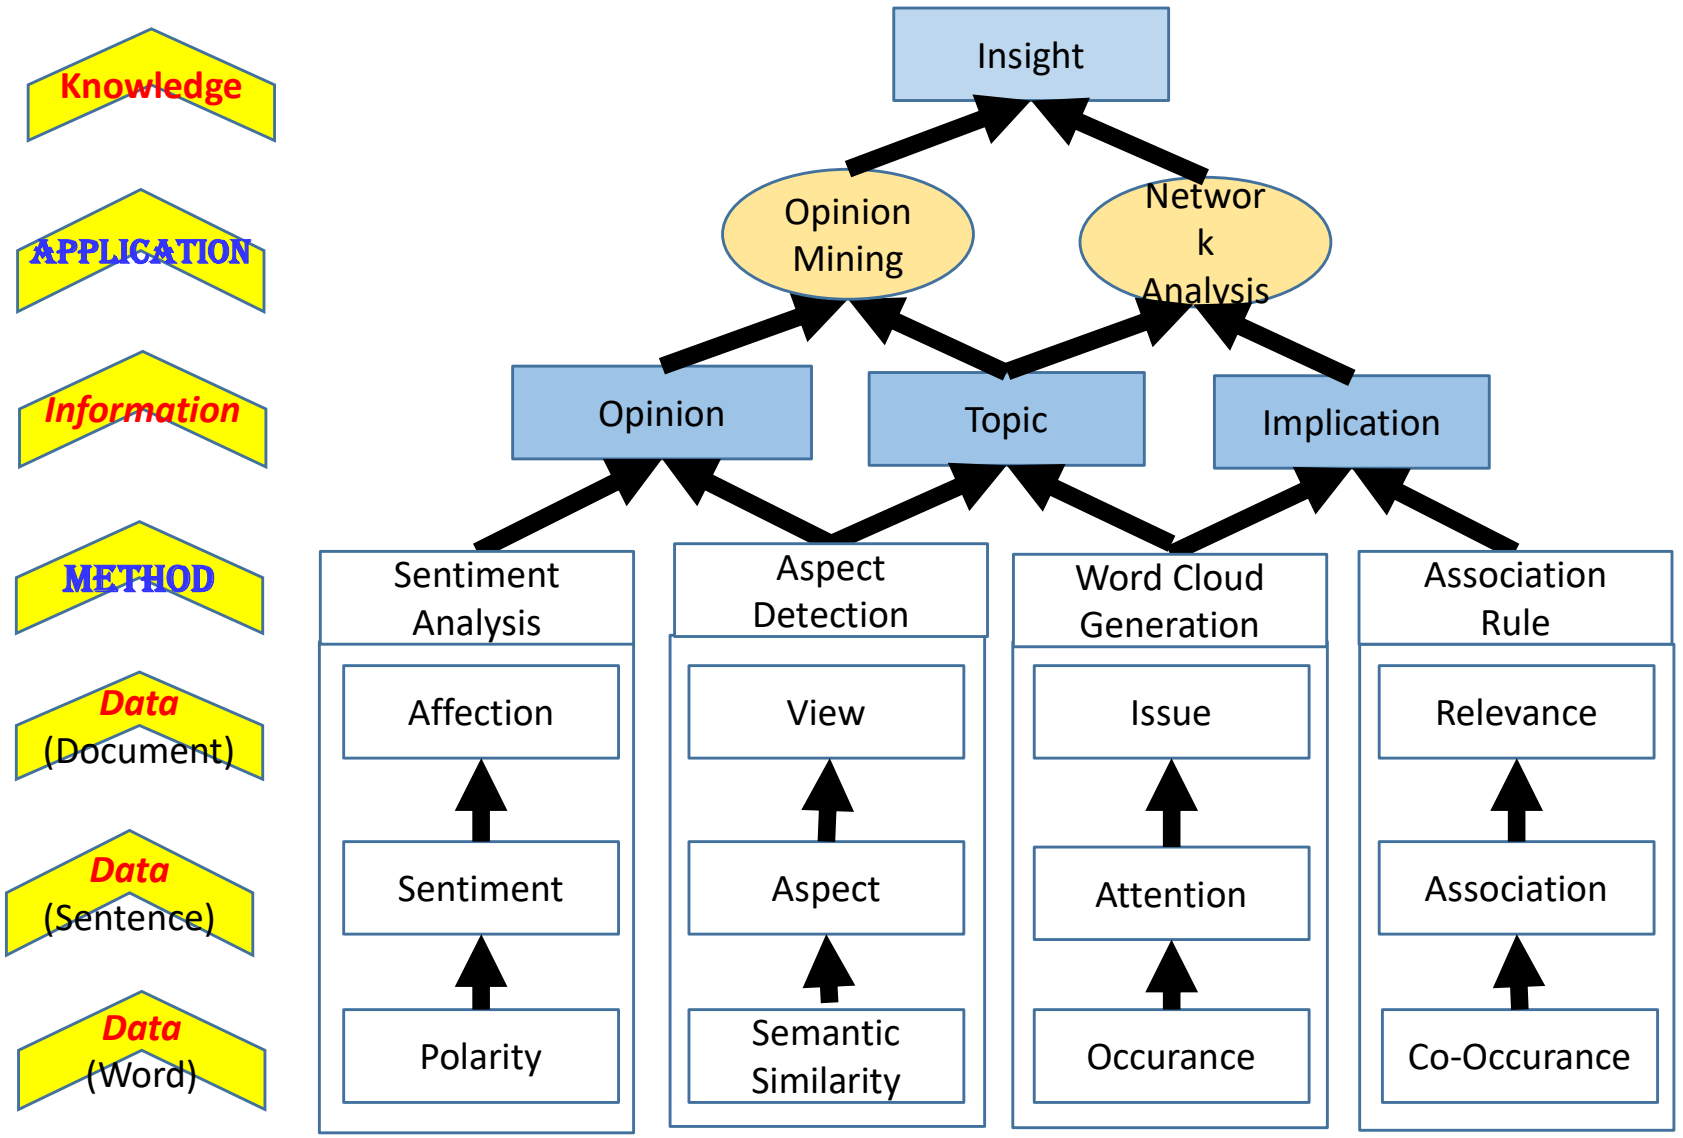

From Text to Action(FTTA3A)

-- Aspect, Affection and Attention

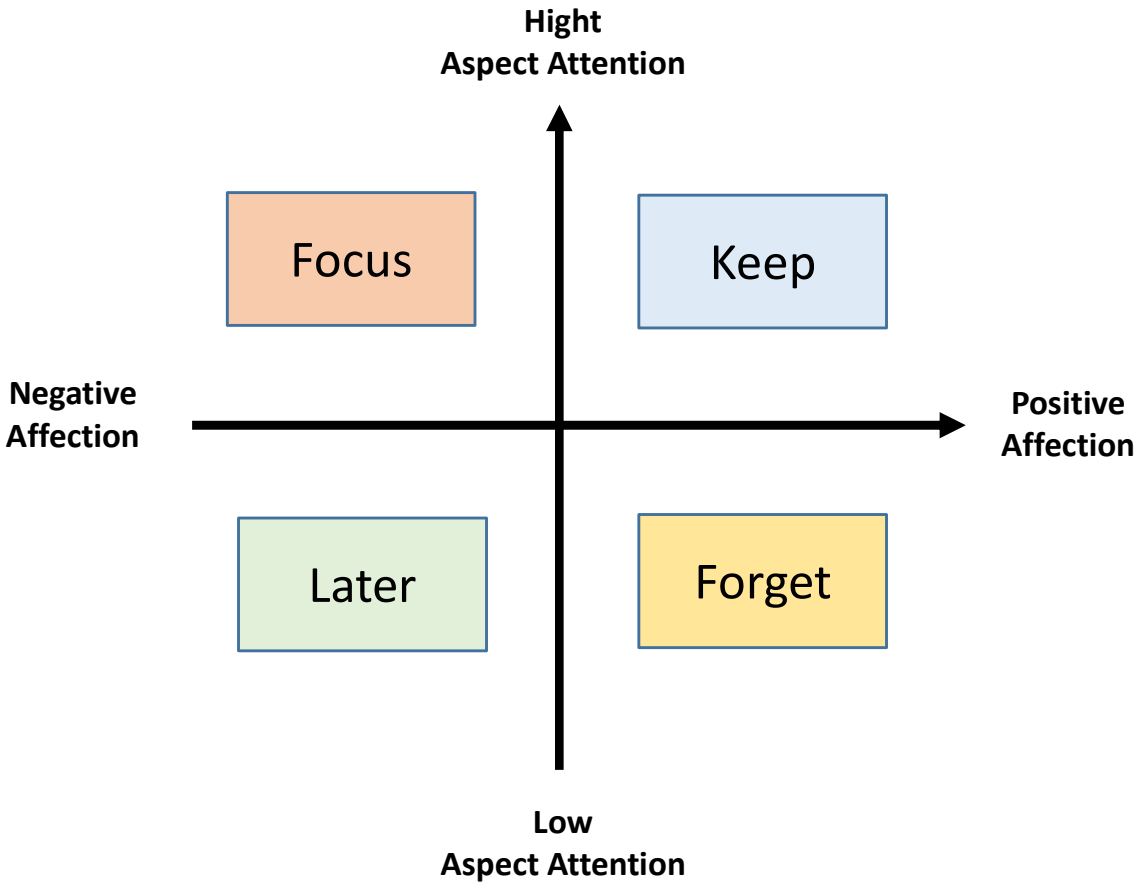

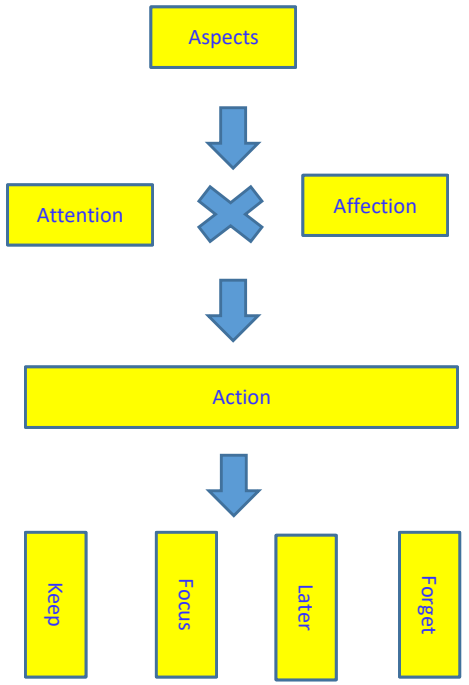

Structural Textual Data Discovery (STDD4A)
-- Aspects, Affection, Attention, and Association

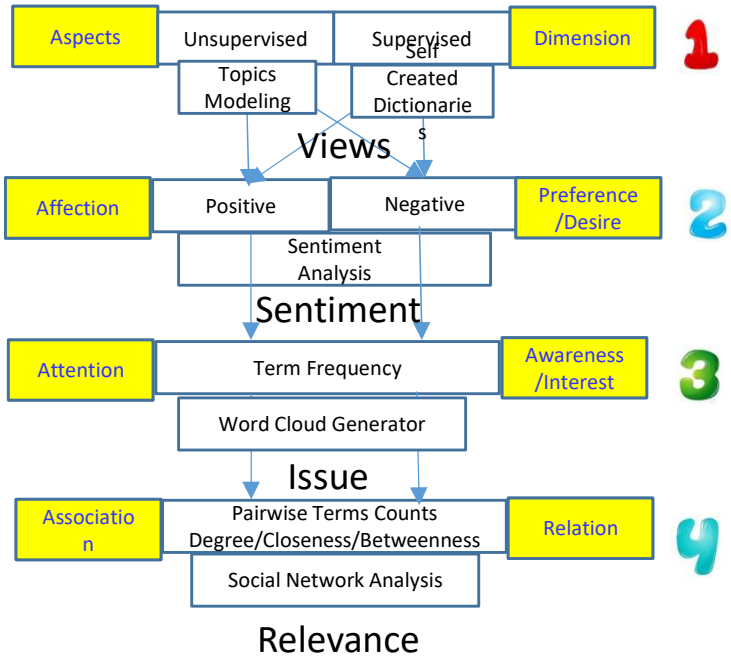

1 Classification of textual data based on Aspects using dictionaries developed via Unsupervised or Supervised method in Document Level

2 Calculating Sentiment Score of each Sentences and Labeling/Classification of Sentences into Positive or Negative groups in Sentences Level

3 Counting the Term Frequency in Words Level for different Aspect/Affection groups of textual data respectively

4 Counting the Pairwise Term Counts in Words Level for different Aspect/Affection groups of textual data respectively and calculating Degree/Closeness/Betweenness for evaluation of Relationship of Pairwise Terms

Topics Modeling
Aspect Semi-Auto Detention:
Ex: Sports, Science,
Food Topics

Self Created Dictionaries
Existed Dimensions of
Marketing Scale:
Ex: Competence, Excitement , Ruggedness,
Sincerity, Sophistication of
Brand Personality

Structural Textual Data Discovery (STDD4A)

-- Aspects, Affection, Attention, and Association

研究問題:
研究對象: Subject E*L*O*P*T 群體
研究方法:

資料來源
資料蒐集
資料準備

Los Angeles/Spring Break/Family Travelers/ Accommodation

-地點
-價格
-服務
- .....

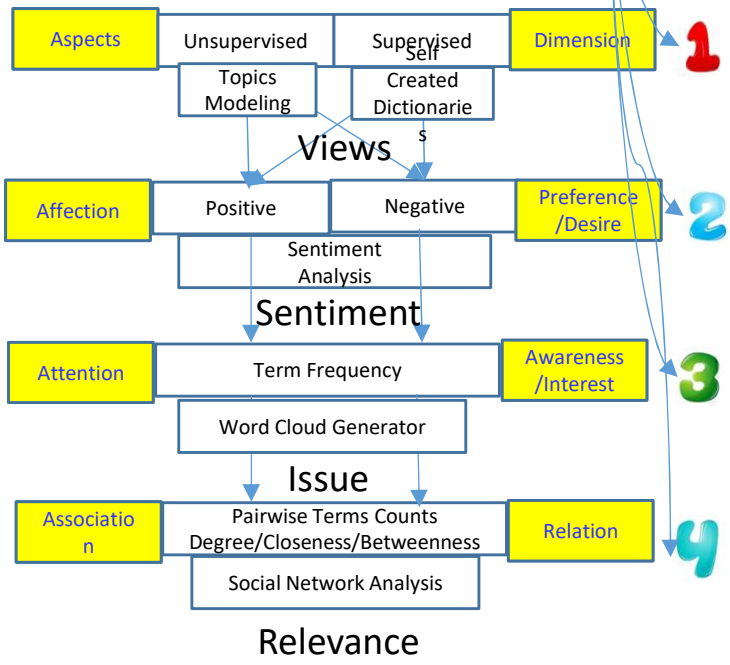

1 分析的觀點與角度(Aspect/Features/Dimensions)
(1)探索就透過電腦演算法Topics Modeling
(2)驗證就行銷構面建立構面字集

2 針對每個研究對象個別群體，進行情緒分析
(1)分類並標註正負面
(2)標註情緒強度(-5~+5)

3 針對每個研究對象個別群體，已標註情緒極性之類別，進行該類別字詞出現頻率(Term Frequency/Occurence)

4 根據3 所產生之焦點字詞，進行字詞共現性(Co-Occurrence),及社會網路分析，程度中心性、 集中性、中介中心性分析

How to Discovery Insigh

First, we define the factor $Subject_{elopt}$ as the multiple combination of Event, Location, Object, People, and Time for the Subjects from which we discovering insight

$Subject_{elopt}$ = f(事件[Event] En * 地點[Location]Ln * 物件[Object]On * 人物[People]Pn * 時間[Time]Tn)

assume:

1.E, L, O, P, T for possible focal groups cross Event, Location, Object , People ,Time
2.n of En, Ln, On, Pn, are index n_{th} element of the list of E, L, O, P, T respectively
3.elopt can be any one of combination of list of E,L,O,P,T

Second, we define Insight $_{eloptAx}$ as the Insight discovering from any one of combination of list of E,L,O,P,T

Insight $_{eloptAx}$ = STDD(Z_{tlpeo})

assume: x of Ax ranging from 1~4 , for Aspect, Affection, Attention, Association respectively

The Example of Deploying the STDD4A in Marketing Discipline

The Application of STDD4A					
Marketing Task	Marketing Measure	Text Analytics	Marketing Analytics	Example	Literatures
Branding	Brand Attitude	Aspect (View) Affection (Sentiment)	Scale(Dimensional) Likers(Preference/Attitude)	Brand Personality	Tsao, J., Campbell, C. L., Ferraro, C., Mavrommatis, A. & Lu, S. (2020). A machine-learning based approach to measuring constructs through text analysis. European Journal of Marketing, 54 (3), pp. 511-524.
Communication	Advertising Effectiveness	Aspect (View) Affection (Sentiment) Attention(Issue)	Scale(Dimensional) Likers(Preference/Attitude) Open Question (What mostly like/ What mostly dislike/	AIDA	
Marketing Research	Satisfaction	Aspect (View) Affection(Sentiment) Attention(Issue) Association(Relevance)	Scale(Dimensional) Likers(Preference/Attitude) Open Question (What mostly like/ What mostly dislike/ Why)	Service Quality Customer Satisfaction	

文字探勘見解剖析

探勘方法

- 文字分析
  - 文字出現頻率 -> 文字雲(焦點)
  - 字詞共線性-> 社會網絡 (關聯)
  - 字詞的正負向情緒-> 情緒分析(偏好)
- 文件分類
  - 主題萃取
- 摘要自動化
  - 重要文意萃取

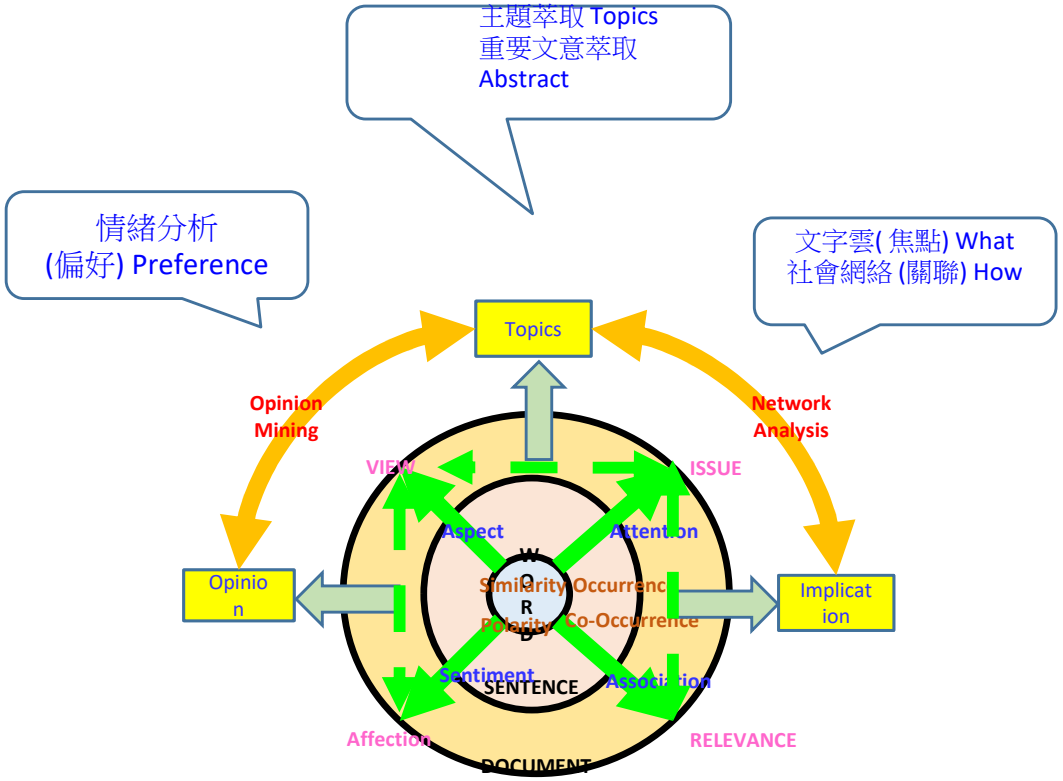

剖析對像

- 時間
- 地點
- 人物
- 事件
- 物件

- 競爭分析
  - 品牌
  - 定位
  - 市場區隔
- 消費者偏好(情緒分析)
  - 喜歡的是甚麼(What)
  - 不喜歡的什麼
  - 多喜歡(How)
  - 多不喜歡

- 行銷溝通效果衡量
  - 廣告效果
  - 新產品試銷
- 公關
  - 聲量(焦點)
  - 情緒(偏好)
  - 主題(議題)
  - 趨勢(時間)
  - 預警(危機訊號)

Big Text Analytics
Product Positioning

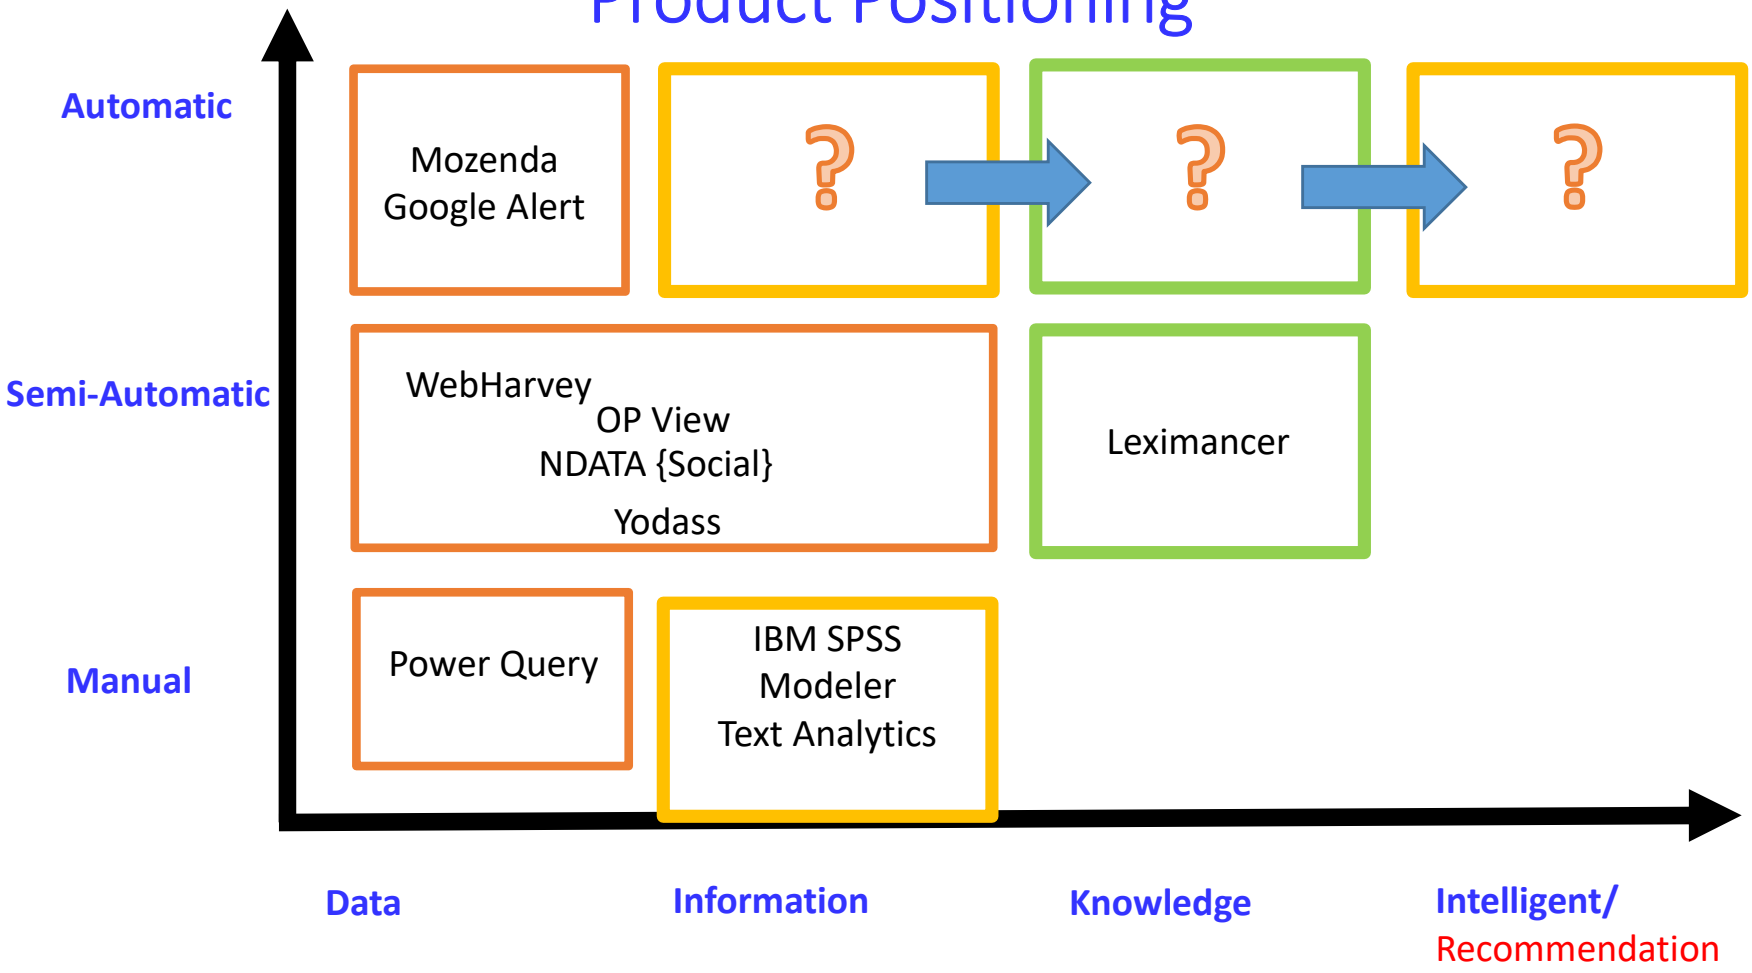

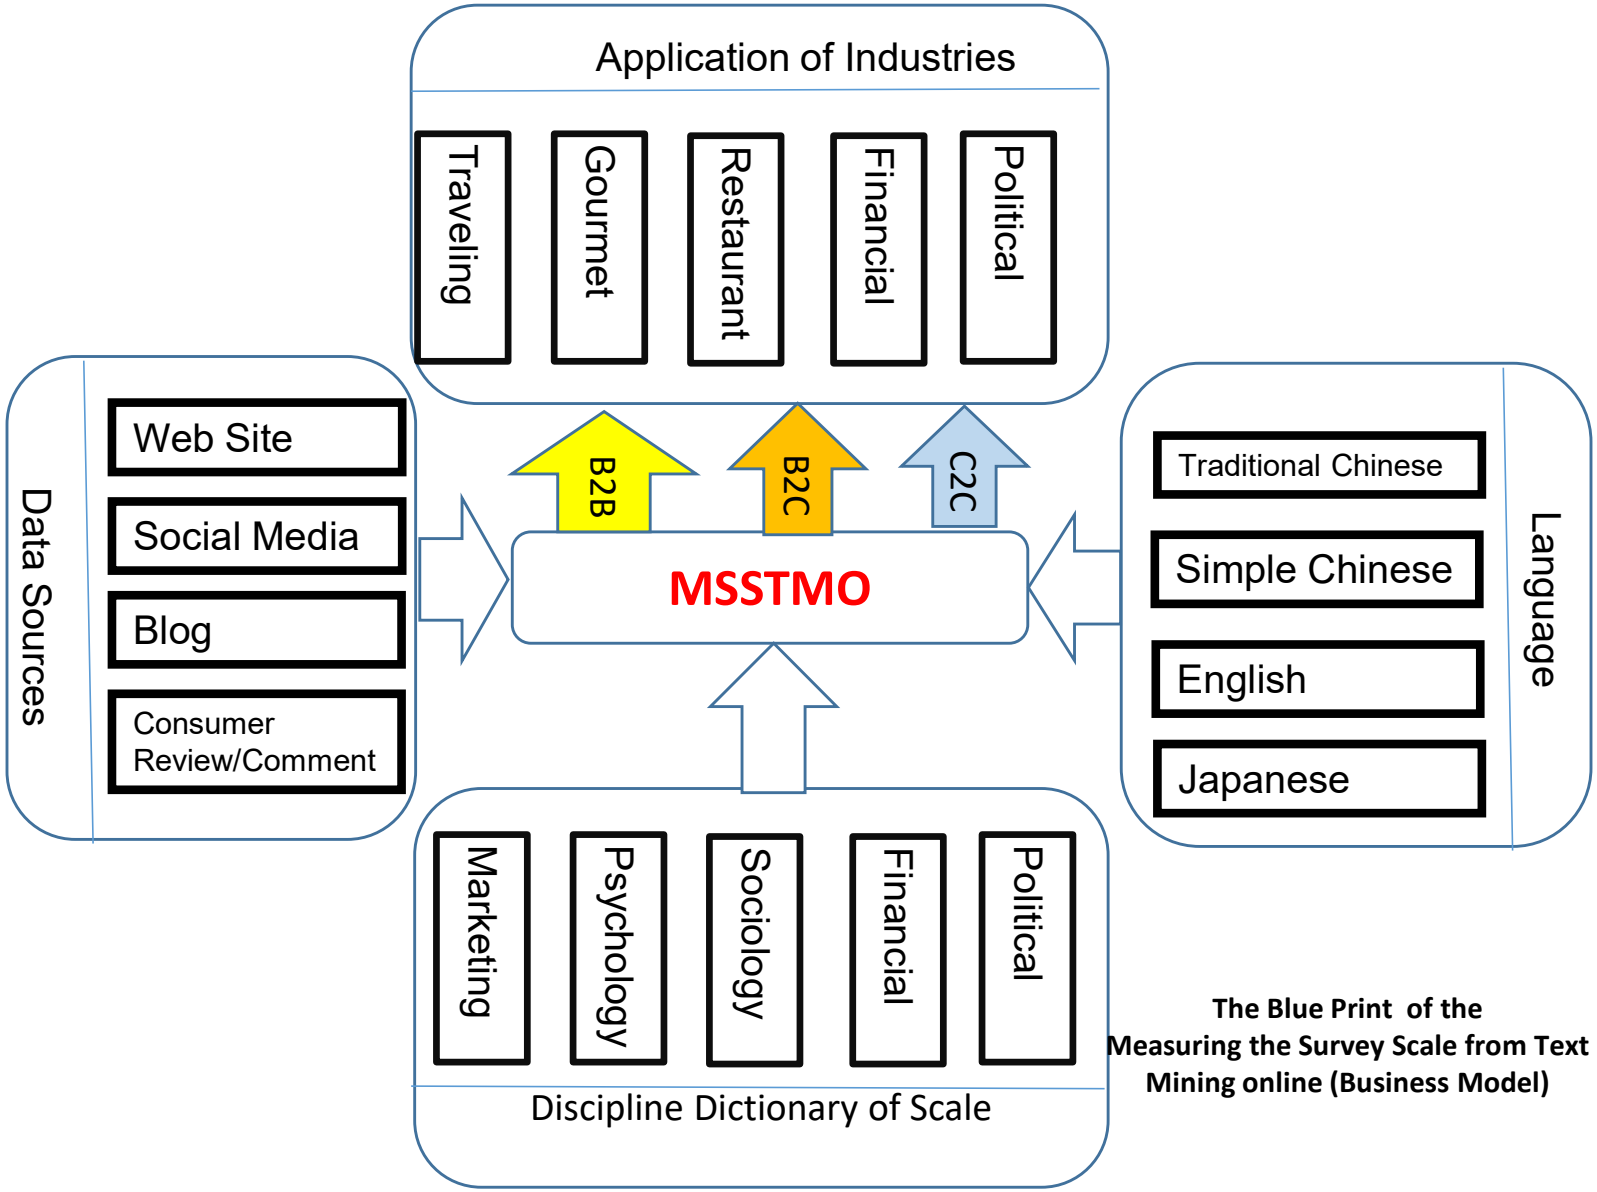

The Blue Print of the Measuring the Survey Scale from Text Mining online (Business Model)

The Application of Big Text Analytics				
Marketing Task	Marketing Measure	Text Analytics	Applied Industries	Literatures
Branding	Brand Personality Brand Experience Brand Attitude	Opinion Mining	Tourism Hospitality	TSAO POKU
Communication	Advertising Effectiveness	Opinion Mining		
Marketing Research	Product Preference Satisfaction	Opinion Mining+ Network Analysis	Goverment Tourism Restaurant Political and Communication	
Public Relationship	Monitoring, warning, and WOM		E-Commernce Intelligence Institute Non-profit	

Social Insight Discovery Research(SIDR)

當馬斯克碰到比特幣

(April,2021)

行銷理論、商業與人生
學術與實務的對話

盧瑞山 曹修源

05/01/2021

- **Concept, Technology, and Application**

台灣金融研訓院
TAIWAN ACADEMY OF BANKING AND FINANCE

NCHU Marketing 國立中興大學行銷學系
國立中興大學行銷學系 Department of Marketing, National Chung Hsing University

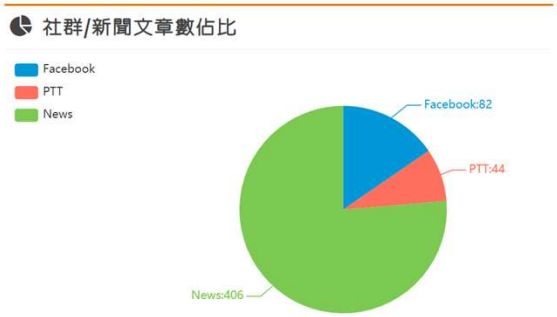

國際金融：馬斯克等揚言要在「狗狗幣日」推上新高，狗狗幣24小時飆升近18%

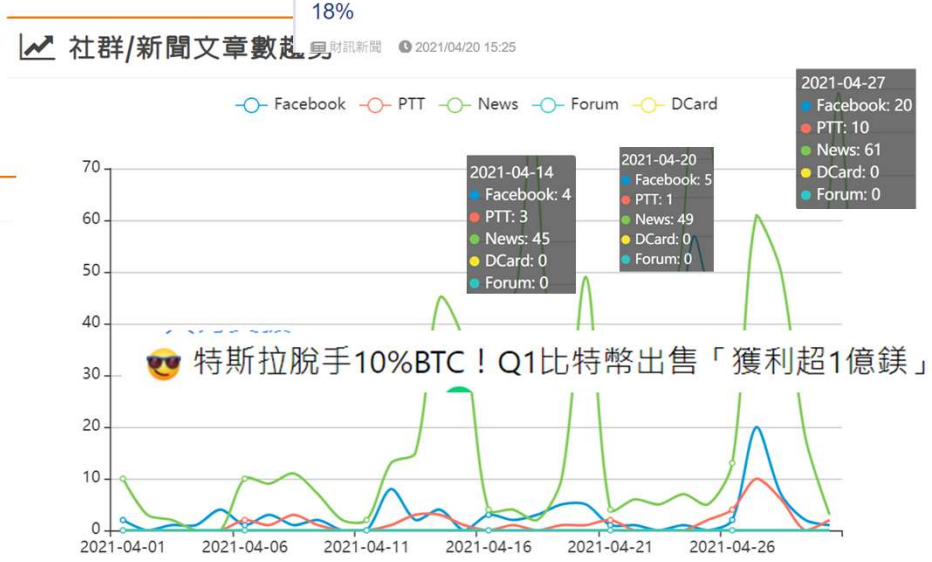

比特幣飆破 63,000 美元大關，與以太幣雙創新高

總聲量：532

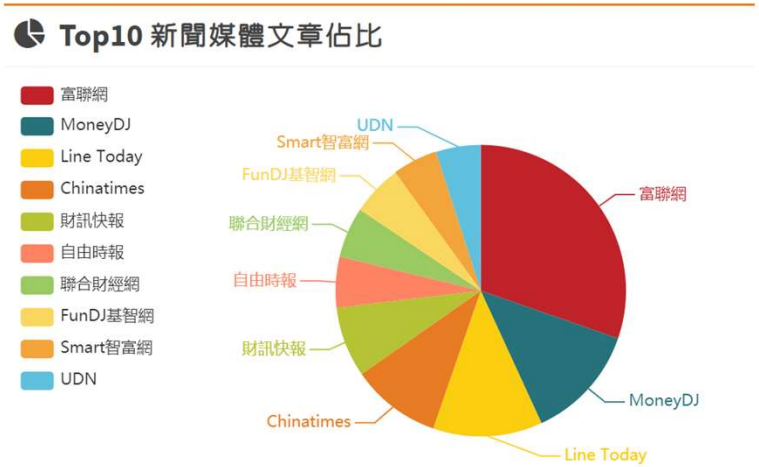

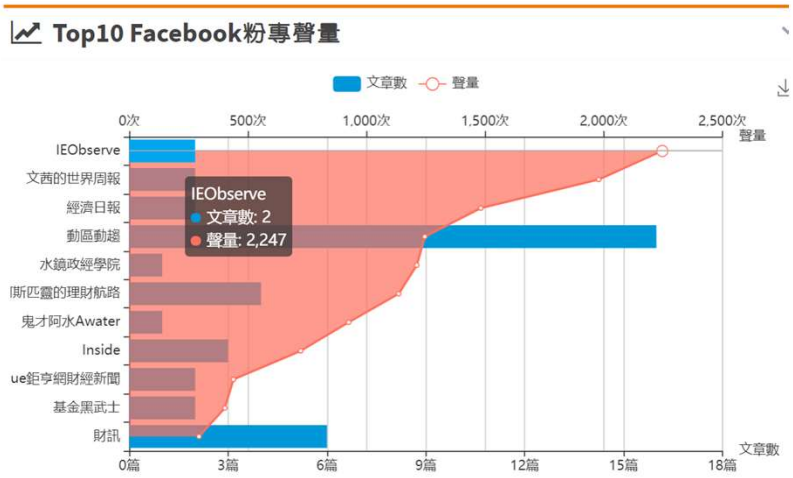

Facebook

擴散強FB　比特幣 v.s 特斯拉

發文時間	網址	粉專名稱	總互動數	讚數	留言數	分享數
2021-04-27 11:30:15	https://www.facebook.com/179043295447791/posts/4241629512522462/	179043295447791 經濟日報	1463	1071	49	56
2021-04-27 08:20:25	https://www.facebook.com/203839673117112/posts/3019181612928 19/	203839673117112 IEObserve 國際經濟觀察	1270	1195	12	55
2021-04-18 15:09:18	https://www.facebook.com/2359076411080525/posts/2941987116122782/	2359076411080525 水鏡政經學院	1212	875	23	56
2021-04-17 09:32:47	https://www.facebook.com/322447507832934/posts/4021563741254607/	322447507832934 文茜的世界周報 Sisys World News	1006	958	4	19
2021-04-20 07:38:37	https://www.facebook.com/203839673117112/posts/297710171713618/	203839673117112 IEObserve 國際經濟觀察	977	928	10	24

經濟日報
4d ·

特斯拉財報攤開，居然有逾1億美元賣出比特幣的獲利‼️

#特斯拉 #比特幣 #財報

MONEY.UDN.COM | BY 經濟日報

特斯拉Q1「炒」比特幣 大賺逾1億美元 | 國際焦點 | 國際 | 經濟日報

根據特斯拉（Tesla）周一公布的財報，今年第1季根據通用會計準則的淨利達創紀錄的4.38億美...

水鏡政經學院
April 18 at 3:09 PM ·

#加密幣初4啦

1.3/4比特幣登上商週封面
2.今天傳出美國將針對加密貨幣洗錢進行調查，比特幣從62000下跌到53000
3.幣安下單出現問題

一般認為數位幣上漲，部分是洗錢需求

特別是中國外匯管制下，買數位幣拉高數位幣，再到海外換成美元，成為熱門洗錢管道

有人猜測，特斯拉公司買比特幣就是幫忙中國特定族群洗錢出去
也因此被中共官方找麻煩

若美國真查洗錢，隨之而跌的數位幣

台灣除了投資數位幣的受影響，最近飆漲的顯卡（挖礦概念），明天拉回的機會很大

3/4商周封面領先指標再次顯神通

#加百列

PTT

熱門討論鄉民聲音　比特幣 v.s 特斯拉

發文時間	發文標題	討論版	總留言數	推文數	噓頭數	噓文數
2021-04-26 23:57:07	[心得] 投資策略分享	stock	269	104	146	19
2021-04-30 17:00:57	[新聞] 蔡明彰觀點：印度疫情全面失控 紡織股	stock	114	69	40	5
2021-04-21 17:08:50	[新聞] 4 年前鎮壓比特幣，中國如今大改口支持：	Gossiping	113	68	41	4
2021-04-25 01:36:31	Fw: [支付] 第一槍!比特幣可以買房了	home-sale	102	48	54	0

批踢踢實業坊 › 看板 Stock　　聯絡資訊　關於我們

作者 pqoiwe (nn)　　看板 Stock
標題 [心得] 投資策略分享
時間 Mon Apr 26 23:57:07 2021

1.發文前請先詳閱[心得]分類發文規範，未依規範發文將受處份。
2.若提及股號股名，且屬未來性的預測或分析有推薦意圖，
　請寫到［標的］分類，否則將以板規4-1砍文處份。

----------按ctrl+y可刪除以上內容。----------

看到很多人在討論綠角的被動投資
我自認為我有個主動投資的方法比綠角好得多

其實我覺得投資最大的祕密就是一便宜的槓桿
根據分散時間投資法，年輕的時候要用比較大的槓桿
而最便宜的槓桿就是一期貨
期貨的槓桿可以自己控制，不用付利息，比融資好得多
所以我的策略也是以期貨為中心

以我自身為例，我目前總資產(不含房子)大約2000萬元
我持有台積電個股期貨12口，實際價值等於24張台積電，約1450萬元，但是我期貨保證金
只放300萬元而已，意思是我不用付任何利息就借到了1450-300=1150萬
(實際上是負利率啦，因為遠期還有逆價差可以吃，等於借你錢還給你利息)
可能有人會覺得重押單一個股台積電很不妥
我倒是很安心XD

熱門焦點新聞　比特幣 v.s 特斯拉

1億美金！「楓之谷」南韓母公司大買1717枚比特幣

2021/04/29 00:21

推出多種熱門遊戲的南韓知名遊戲公司Nexon，宣布花費近1億美金購買比特幣。（路透）

LINE TODAY 理財

傳臉書最新財報將揭露「持有比特幣」

anue鉅亨網

© Anue.com 鉅亨 提供

比特幣概念股買啥好？高盛：19檔概念股 今年漲46%

2021/04/28 11:33　　回應(0) 人氣(0) 收藏(0)

MoneyDJ新聞 2021-04-28 11:33:52 記者 陳苓 報導

比特幣漲勢驚人，今年以來飆高86%，許多投資人想從此一趨勢獲利，又怕比特幣過於波動，轉向擁抱相關概念股。到底哪些標的可以抱？高盛篩選後，選出19檔純度最高的概念股。

Barron`s 27日報導，儘管有好幾家公司接受比特幣、採納比特幣背後的區塊鏈技術、甚至直接敲進比特幣，但是對投資人來說，很難判斷哪些個股和比特幣價格走勢的連動性最強。高盛分析師Ben Snider用三個標準衡量，找出19檔純度最高的個股。

特斯拉披露：目前持有價值24.8億美元的比特幣

2021/04/29 11:26

美國電動車大廠特斯拉（Tesla）28日表示，截至3月31日為止，該公司持有比特幣的公允市場價值為24.8億美元。（路透）

馬斯克碰上比特幣-- 解讀文字雲

只在此山中，雲深不知處

行到水窮處，坐看雲起時

主題分類 → 情感正負 → 關注焦點 → 洞見 ? → 建議 ?

社群正負面意見焦點比特幣 v.s 特斯拉

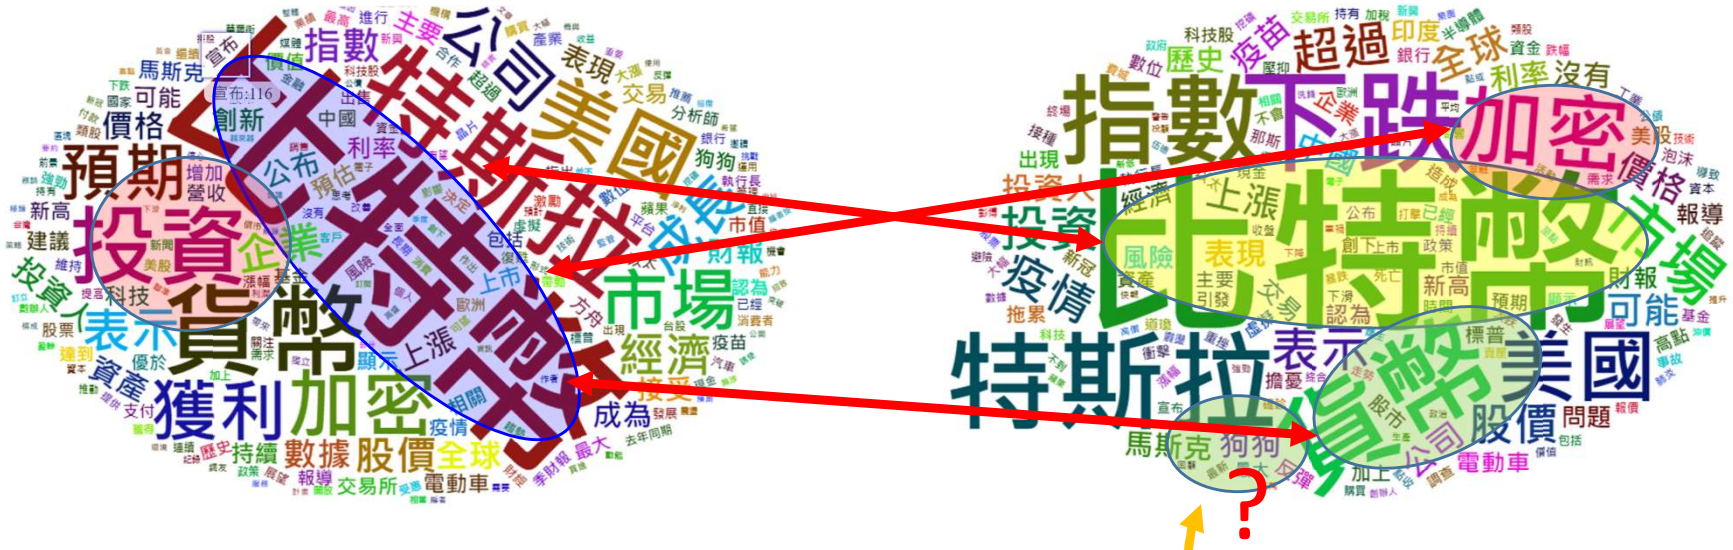

正面的焦點

正負兩面兼具

正面的焦點

負面的焦點

未被發現的焦點

負面的焦點

讓我們看雲去--比特幣

讓我們看雲去--比特幣 v.s 特斯拉

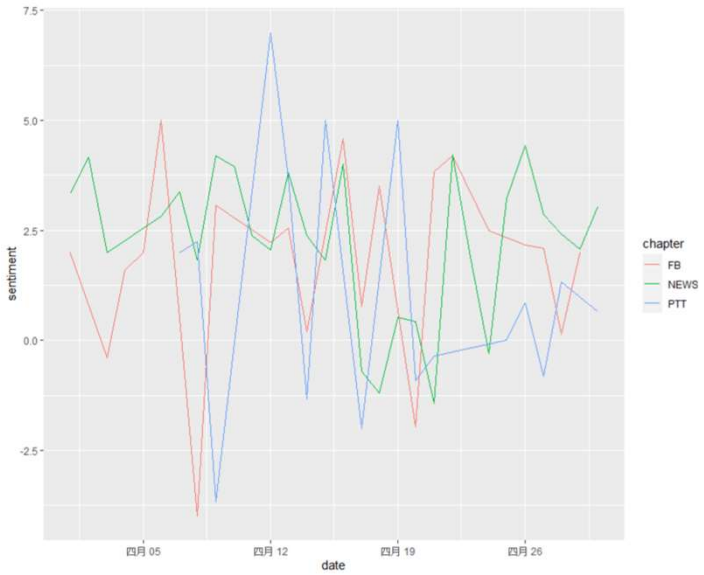

輿論語意情緒變化

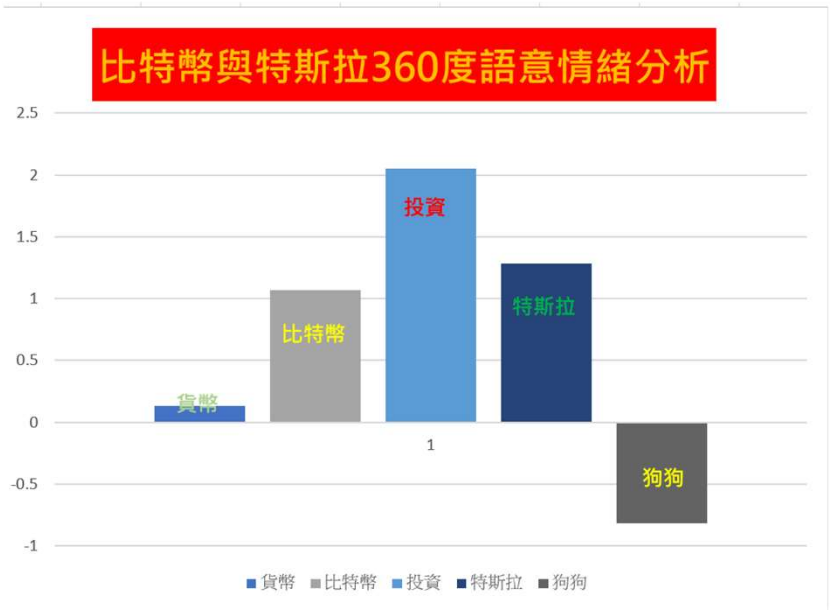

多元語意情緒分數

讓我們看雲去--比特幣 v.s 特斯拉

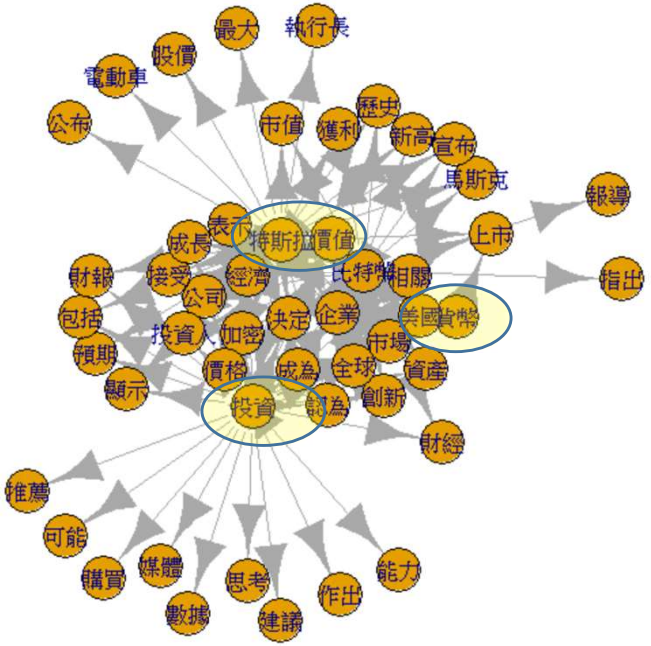

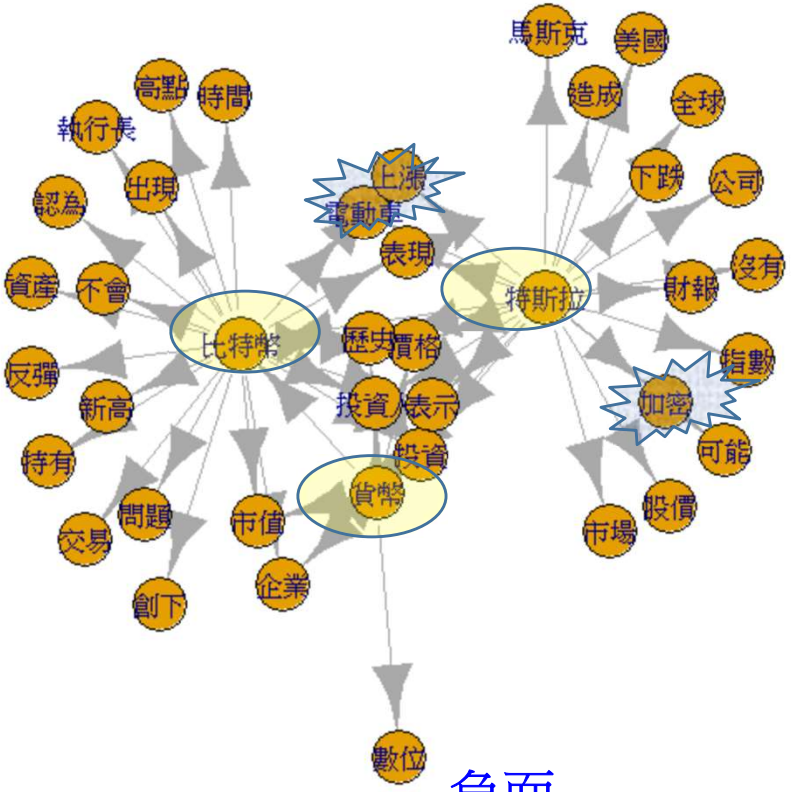

正面

未被發現的焦點

正負兩面兼具

正面的焦點

負面的焦點

未被發現的焦點

負面

未被發現的焦點

讓我們看雲去—狗狗?

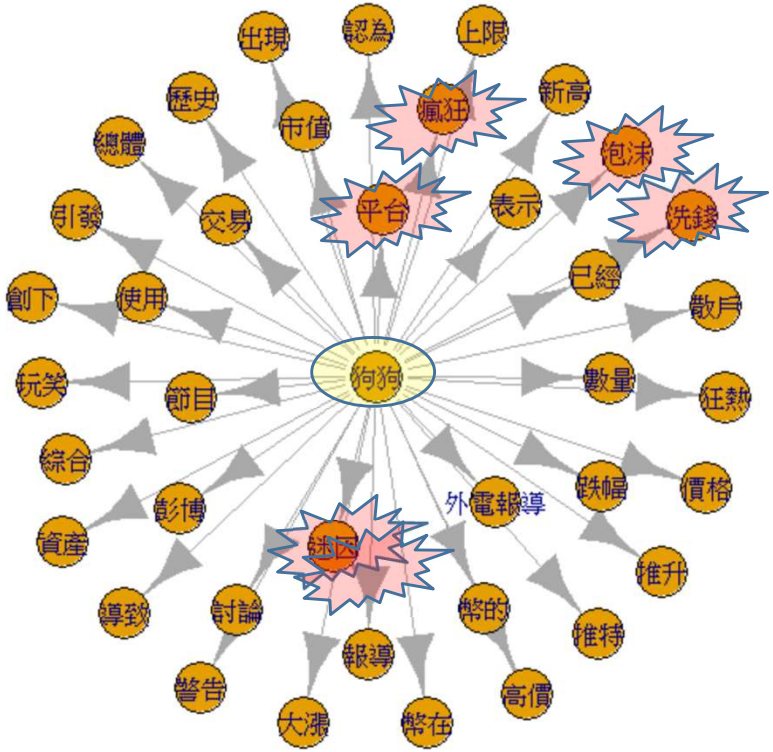

意外的焦點

中文斷字
文字雲產生器

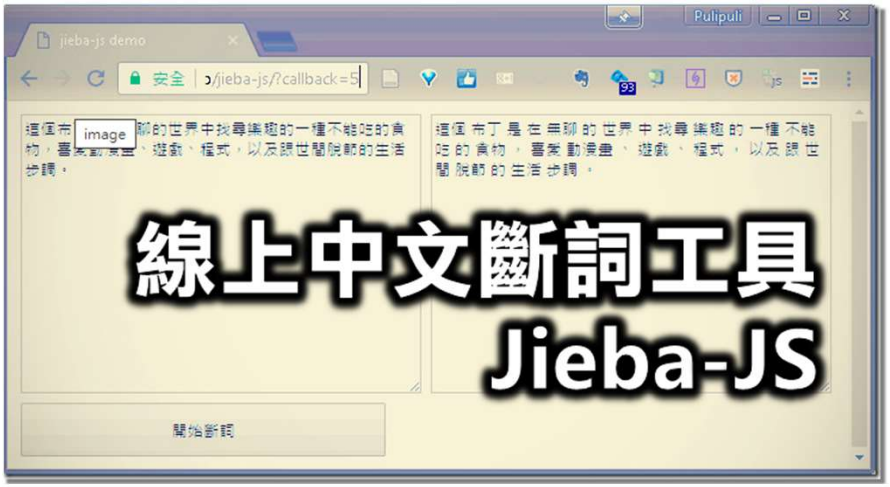

線上展示 / Online Demo

Filename: Raw Text

Input Raw Text

message
這個布丁 是在無聊的世界中找尋code的1998種不能吃的codes，
喜愛動漫畫、遊戲、Coding，以及ABCDV跟世間脫節的生活步調。

START SEGMENTATION

Output Segmentation Result

message
布丁 無聊的世界 找尋 code 1998 種 不能 吃 code
喜愛 動漫畫 遊戲 code abcdv 世間 脫節 生活 步調

Copy

Remove first line (header)

Draw word cloud

Text

253天無本土病例破功！陳時中13:30親上火線說明

4,446 讚

【寵物聖誕市集】寵物雲商城全館結帳89折！

Input Raw Text

國內今（22日）新增3例新冠肺炎確定病例，中央流行疫情指揮中心將於下午1時30分召開臨時記者會，由指揮官陳時中說明病例情況，據了解其中有本土病例，確診病患目前已在醫院接受治療中，也讓台灣連續253天無本土病例破功。

以往指揮中心例行記者會為每周三，一般日的臨時記者會如果是境外移入，僅由發言人莊人祥說明，而今天臨時記者會改由陳時中主持，不排除有本土個案，台灣上一次有本土病例已經是4月12日，是案386的男性，被美國境外移入的同住友人傳染。

指揮中心統計，國內目前累積769例確診，分別為675例境外移入，55例本土病例，36例敦睦艦隊、2例航空醫療感染及1例不明；另1例(案530)移除為空號，確診個案中7人死亡，627人解除隔離，其餘住院隔離中。

START SEGMENTATION

Output Segmentation Result

國內 22 新增 例 新 冠 肺炎 確定 病例 中央 流行 疫情 指揮中心 下午 30 召開 臨時 記者會 指揮官 陳 說明 病例 情況 了解 本土 病例 確診 病患 目前 醫院 接受 治療 台 灣 連續 253 天 本土 病例 破 功

以往 指揮中心 例行 記者會 每周三 臨時 記者會 境外 移入 僅 發言人 莊 祥 說明 今天 臨時 記者會 改由 陳 主持 排除 本土 個案 台 灣 一次 本土 病例 已經 12 案 386 男性 美國 境外 移入 住友 傳染

指揮中心 統計 國內 目前 累積 769 例 確診 675 例 境外 移入 55 例 本土 病例 36 例 敦睦 艦隊 例 航空醫 感染 例 不明 例 案 530 移除 空 號 確診 個案 死亡 627 解除 隔離 住院 隔離

Copy　Save as text　Save as sheet

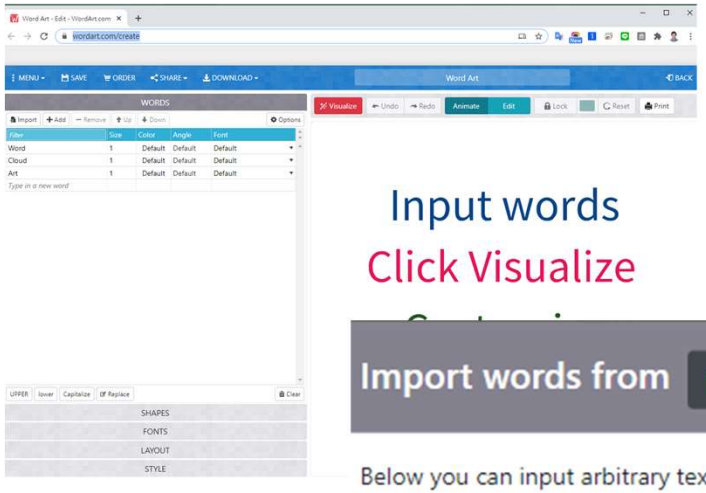

Input words

Click Visualize

Import words from Text Web

Below you can input arbitrary text or use CSV format or paste text from Excel

指揮中心 呼籲 民 眾 國外 入境 發燒 咳嗽 不適 症狀 應 主動 通報 機場 港口 檢疫 人員 配合 防疫 措施 返國 應 落實 居家 檢疫 期間 出現 疑似 症狀 聯繫 衛生局 各縣市 關懷 中心 指示 就醫 切勿 搭乘 眾 運輸 就醫 務必 告知 醫師 旅遊 史 職業 接觸 史 是否 群聚 tocc 供 及時 通報

指揮中心 再次 提醒 民 眾 出入 醫療 照護 公共 運輸 生活 消費 教習 觀展 觀賽 休閒 娛樂 宗教 祭祀 洽 公 機關 構 大類 高 感染 傳播 險 場 域 不易 保持 社交 距離 近距離 接觸 特定 對象 務必 佩戴 口 落實 勤洗手 咳嗽 禮節 個人 衛生習慣 降低 感染 風險

Remove common words

Remove numbers

CSV format

Import words

SENTIMENT ANALYSIS

文字情緒分析

Also known as **opinion mining**: to understand the attitude of a speaker or a writer with respect to some topic

– The attitude may be their judgment or evaluation, their Affection state or the intended emotional communication

- – Most popular classification of sentiment:

•positive or negative

- unbelievably disappointing

- Full of zany characters and richly applied satire, and some great plot twists

- this is the greatest screwball comedy ever filmed

- It was pathetic. The worst part about it was the boxing scenes.

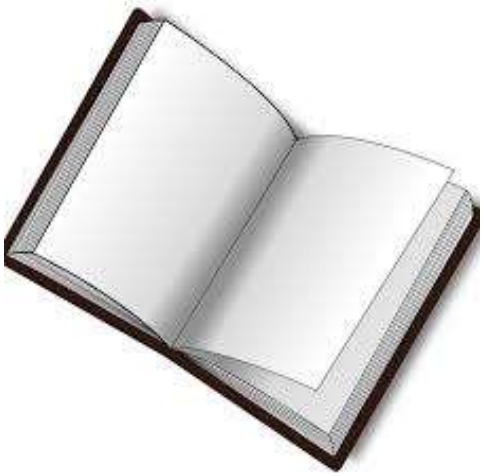

AFINN Sentiment Analysis

AFINN情緒辭典是一個評分範圍從-5(非常負面)到5(非常正面)的英文單字列表，是附有極性的評分方式。

分數	辭彙
-4	遜、歧視、渣、發脾氣、輸、爛透、不要臉、笨蛋、智障、etc.
-3	可怕、受不了、恐慌、討厭、欺騙、傻眼、厭惡、賠償、etc.
-2	小氣、干涉、不耐煩、反感、欠缺、叫囂、失望、丟人現眼、etc.
-1	不對勁、丟棄、兇、有待加強、吵、取消、延遲、浪費、etc.
1	心安、充足、平淡、安心、安全感、自由、吸引、明晰、etc.
2	及格、友善、心儀、支持、主動、出色、合適、划算、etc.
3	大笑、不賴、心愛、名正言順、好吃、有趣、完美、etc.
4	可圈可點、哇、棒、精彩、豪華、優雅、驚艷、贏、etc.

TLSSD(Tsao, Lin & Su Sentiment Dictionary)

否定詞的加入將會影響到詞彙或句子的意思。像是「好吃」這詞本身就有正面情緒的意思，但是如果在前面加入否定詞「不」來做修飾，變成一個新的字詞「不喜歡」，也使得原本正面情緒的字詞改變為負面情緒。本研究自行編撰否定詞詞庫並將此以-1表示。

否定詞詞庫	不、不及、不太、不必、不用、不再、不如、勿、未、杜絕 、沒、拒絕、非、無法、禁止、etc.

利用知網的程度值字別建立程度詞詞庫，依照強度大小分成「級、較、很、稍、無」，五個級別。

級別程度	權重值	程度詞詞庫
極 extreme	5	十分、有夠、卓越、極度、絕對、etc.
較 more	4	太、更、越、較、還要、比較、etc.
很 very	3	出奇、多麼、如此、相當、滿、頗etc.
稍 ish	2	多少、有些、尚可、些微、稍加、etc.
無 least	1	無、沒有、再也、etc.

- Sentiment = Holder + Polarity + Target
  - **Holder:** who expresses the sentiment
  - **Target**: what/whom the sentiment is expressed to
  - **Polarity**: the nature of the sentiment (e.g., positive or negative)

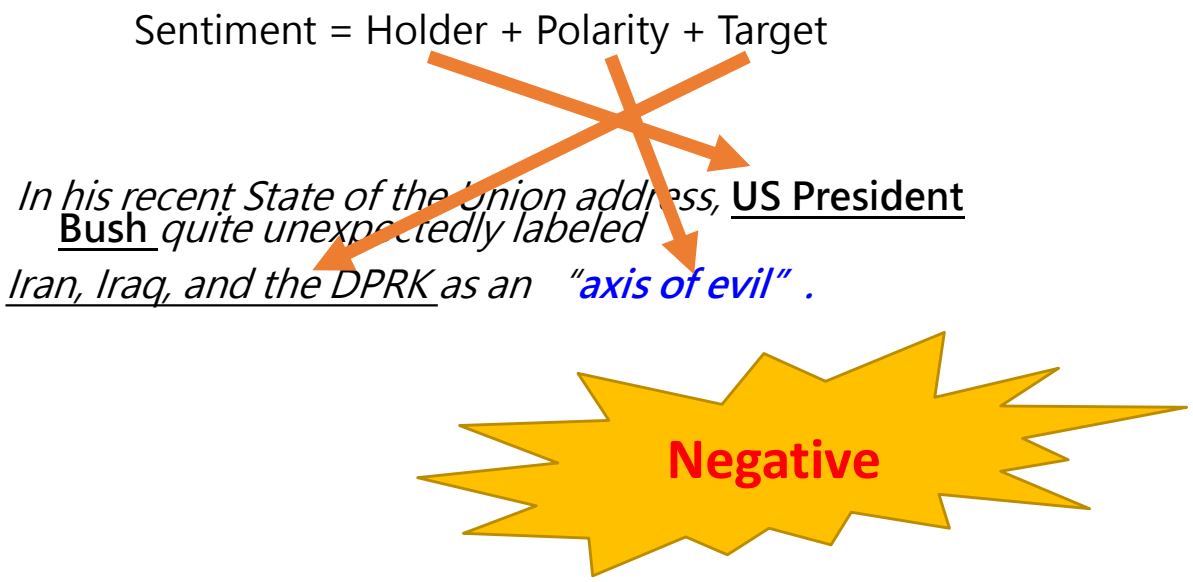

The Example of Analysis of Sentiment Analysis

- Sentiment = Holder + Polarity + Target

- *In his recent State of the Union address,* **US President Bush** *quite unexpectedly labeled*
- *Iran, Iraq, and the DPRK as an "**axis of evil".***
-

Why sentiment analysis?

- ***Movie*** : is this review positive or negative?
- ***Products*** : what do people think about the new iPhone?
- ***Public sentiment*** : how is consumer confidence?
- Is despair increasing?
- ***Politics*** : what do people think about this candidate or issue?
- ***Prediction*** : predict election outcomes, market trends, or stock price from sentiment

讓我們看雲去--比特幣 v.s 特斯拉

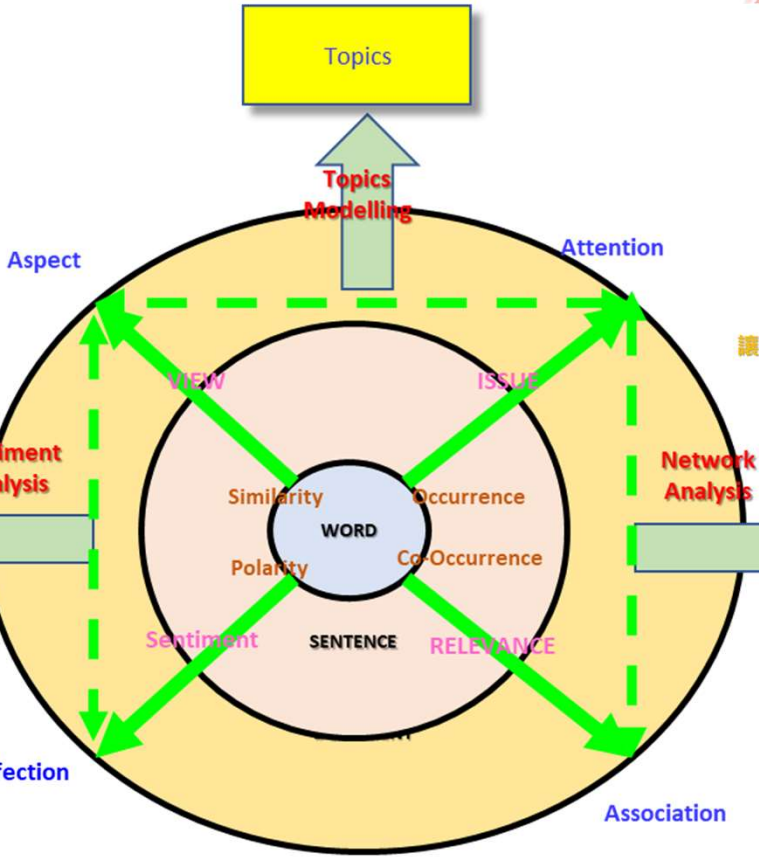

社群正負面意見焦點比特幣 v.s 特斯拉

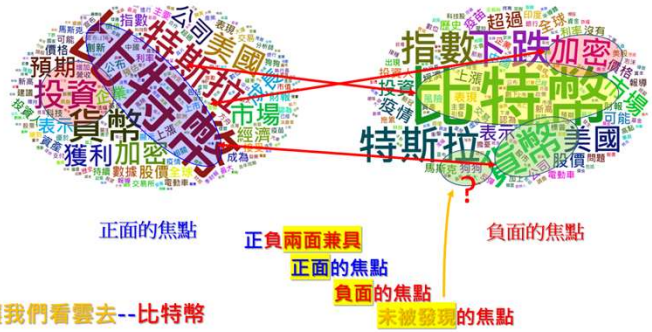

讓我們看雲去--比特幣

讓我們看雲去--比特幣 v.s 特斯拉

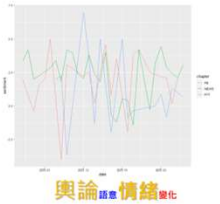

讓我們看雲去--比特幣 v.s 特斯拉

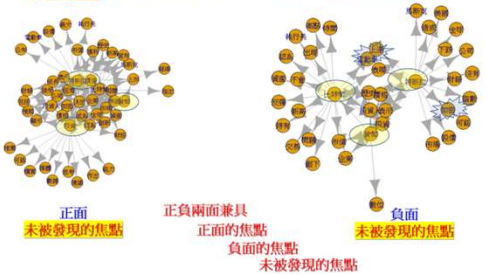

文字 → 意見

文字分析

聲量(Attention)
正負情緒(Affection)
銷量表的構面(Aspect)

意見 → 見解

IPA 分析

見解 → 智慧

領域專家

智慧 → 行動

行動

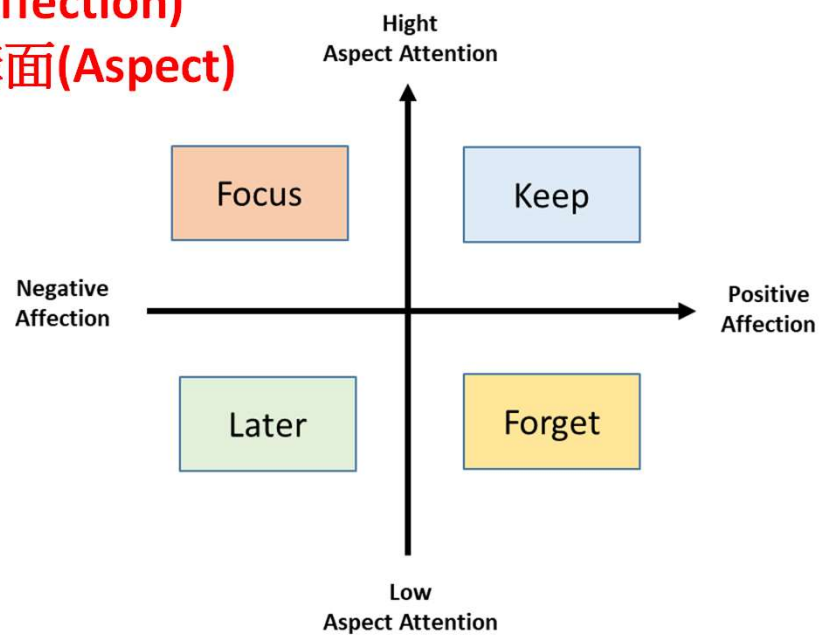

網路爬文(資料蒐集)

.特徵關鍵字句(資料分類)

IPA二維矩陣分析 (資料分析)

.服務品質的決策與建議

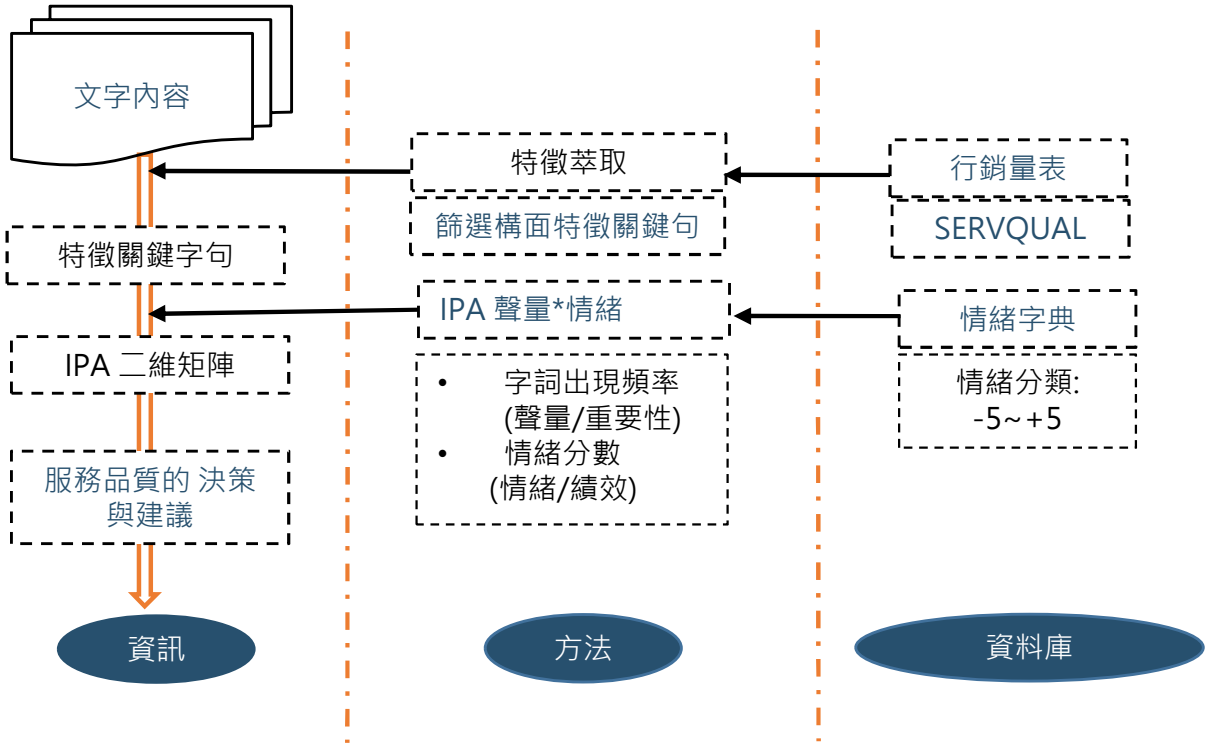

斷字

171	1	確認 | 數據 | 綠燈 | 平均速度 | 低於
172	1	表示 | 狀況 | 許久 | 並非 | 遠方 | 基地 | 近期 | 故障 | 影響
173	1	通話 | 斷斷續續 | 穩定
174	1	本人 | 反映 | 住家 | 今天 | 上網 | 緩慢 | 通話 | 正常 | 體驗 | 綠燈 | 熱點 | 分享 | 網速 | 緩慢 | 聯電 | 開單
175	1	本人 | 反映 | 住家 | 上網 | 緩慢 | 通話 | 正常 | 體驗 | 綠燈 | 持續 | 滿格 | 其他 | FET | 相同 | 熱點 | 分享 | 網速 |
176	2	簡述 | 問題 | 陽台 | 才能 | 使用

斷句

171	1	已確認數據為綠燈且平均速度低於7M
172	1	表示此狀況已許久,並非遠方基地台()近期故障影響
173	1	通話斷斷續續不穩定\"
174	1	本人反映住家今天上網緩慢,通話正常,體驗綠燈,3~4格,無熱點分享,網速緩慢<7M,聯電,開單
175	1	本人反映住家上網緩慢,通話正常,體驗綠燈,持續2~3天,滿格,其他FET相同,有熱點分享,網速緩慢<7M位,開單
176	2	簡述客問題：室不佳,要到陽台才能使用

特徵關鍵字 字典

電信業 服務品質構面	有形性 (Tangibles)	可靠性 (Reliability)	回應性 (Responsiveness)	保證性 (Assurance)	同理性 (Empathy)
	地點	承諾	確實	任務	聆聽
	連線	完成	及時	知識	理解
	場所	達成	樂意	能力	心情
	門市	穩定	意願	尊重	建議
	服務	正確	快速	行為	經驗
	速度	準時	負責	技術	分享
	價格	信賴	解決	誠意	處境
	效率	一致	協助	接觸	互動
	功能	準確	授予	支援	道歉
	設施	履行	確認	專業	朋友
	資料	滿意	準確	溝通	公司
	空間	品質	機制	解決	家庭
	環境	管理	資訊	處理	方便
	速率	控管	積極		關心
	上網	訓練	授權		重視
	費率		態度		權益
	網路		熱忱		主動
	合約				需求
	通路				補償
	產品				風險
					傾聽
					關懷
					體驗

1.網路爬文(資料蒐集)

經由輿情系統或爬蟲程式下載

2.特徵關鍵字句(資料分類)

以台中捷運議題話務內容為例

台中捷運服務品質構面	Tangible	Reliability	Responsivenes	Assurance	Empathy
	斷裂	問題	報告	安全	公車轉乘
	人行道	服務	川崎	態度	需求
	高鐵	提供	處理	服務	公車
	車廂	正確	服務	信任	乘客
	設備	協助	旅客	能力	重視
	設計	品質	迅速	處理	娛樂
	時間	完善	搭乘	表示	旅遊
	環境	困難	回應	測試	景點
	路線	解決	抱怨	負責	交通
	路網	延誤	規定	知道	接駁
	綠線	承諾	幫助	道歉	商店街
	藍線	資訊	資訊	保證	處理
	橘線	態度	旅遊	確保	抱怨
	運量	重視	即時	交代	表示
	營運	安心	回答	解決	負責
	列車	信任	改善	決定	重要
	車站	信賴	規劃	謹慎	道歉
	軌道	詢問	通車	發現問題	設計
	月台	權益	負責		習慣
	高架	過程	知道		養成
	停車位	方便	發現		方便
	收費	及時	發生		需要
	票證	誤點	搭乘		
		處理			

2.特徵關鍵字句(資料分類)

構面分類及情緒分數計算

ID	構面	特徵詞	特徵關鍵句	TLSSD情緒字詞	情緒分數
2	Tangibility	車廂	車廂非常清潔與舒適	舒適	+4
2	Assurance	服務態度	人員服務態度欠佳	欠佳	-2

line	sentenceno	sentiment	word	dimname	text
173	1	3	通話	RESPONSIVENESS	通話斷斷續續不穩定\"
174	1	-1	通話	RESPONSIVENESS	本人反映住家今天上網緩慢,通話正常,體驗綠燈,3~4格,無熱點分享,網速緩慢
175	1	-3	通話	RESPONSIVENESS	本人反映住家上網緩慢,通話正常,體驗綠燈,持續2~3天,滿格,其他FET相同,有 電 、,GIS無法定位,以常駐站
177	2	-2	反應	ASSURANCE	反應地點：住家(彰化縣),因
177	2	-2	反應	RESPONSIVENESS	反應地點：住家(彰化縣),因
177	2	-2	地點	TANGIBLES	反應地點：住家(彰化縣),因

mname	sentiment
ASSURANCE	3.007622677
EMPATHY	3.362244898
RELIABILITY	5.688485804
RESPONSIVENESS	2.759298889
TANGIBLES	0.803876853

- 特徵關鍵字句情緒分數(情緒)
- 特徵關鍵字句出現次數(聲量)
- IPA <--- 聲量*情緒

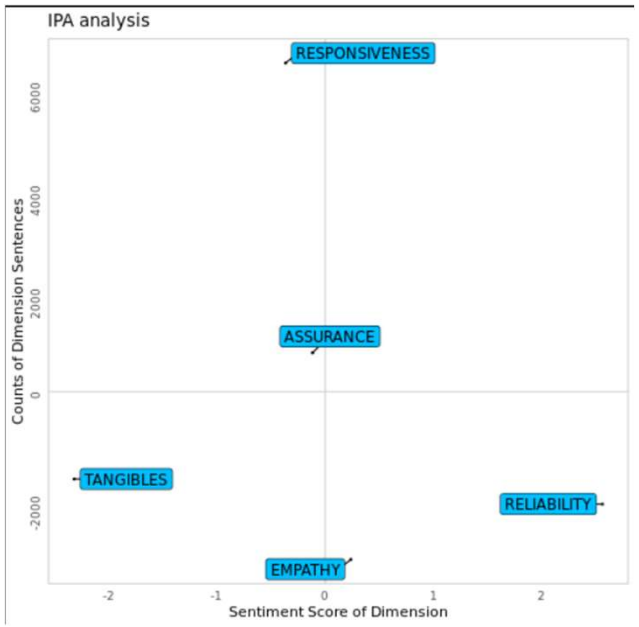

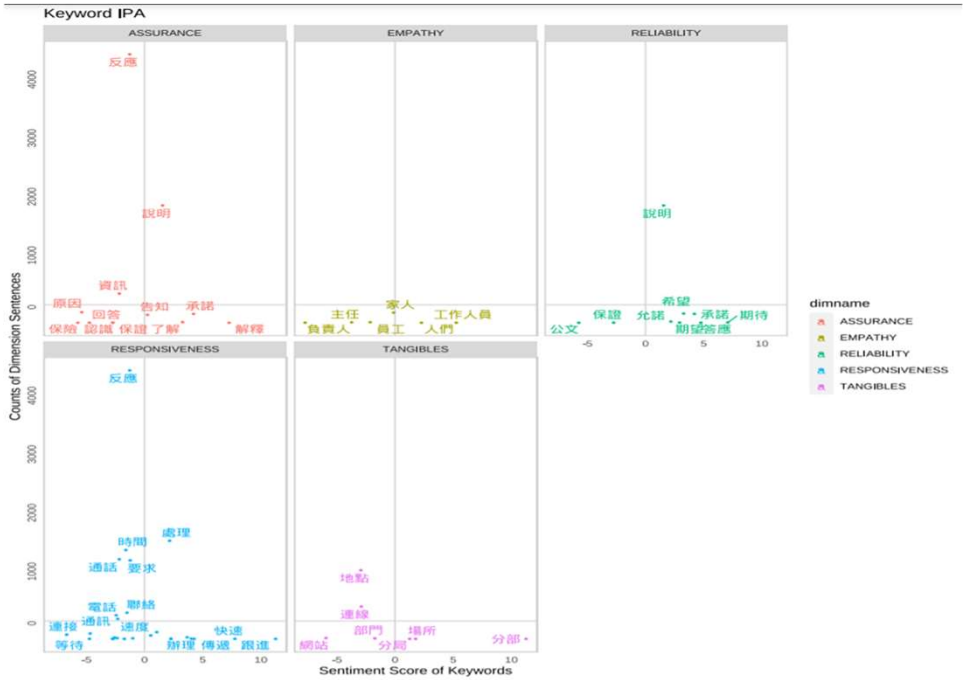

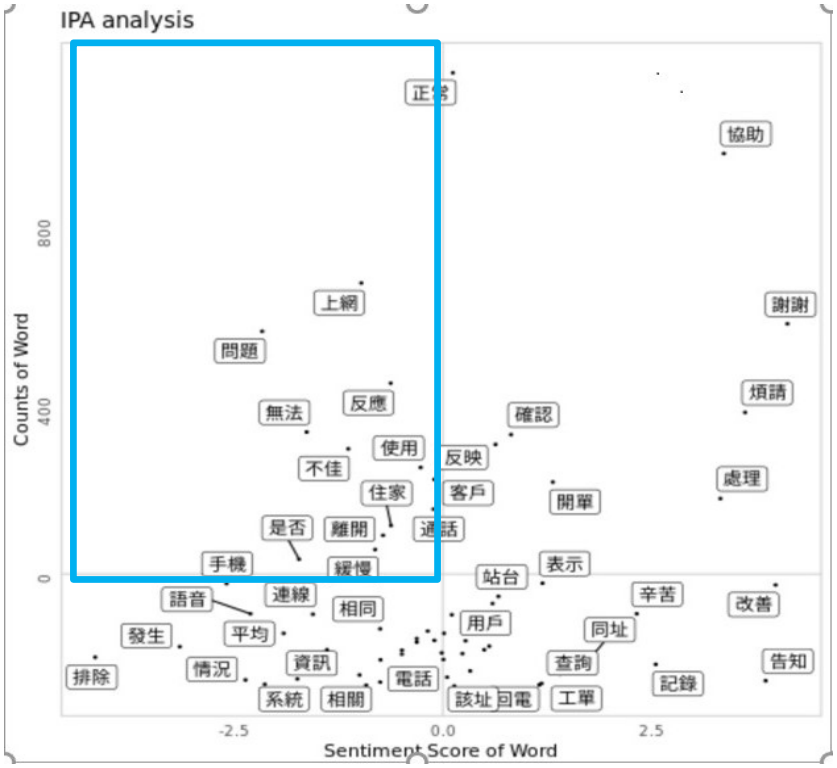
IPA analysis
正常
協助
上網
謝謝
問題
煩請
無法
反應
確認
使用
反映
不佳
住家
客戶
處理
開單
是否
離開
通話
手機
緩慢
站台
表示
語音
連線
辛苦
改善
相同
用戶
同址
發生
平均
查詢
告知
情況
資訊
電話
記錄
排除
系統
相關
該址
回電
工單
Counts of Word
800
400
0
-2.5
0.0
2.5
Sentiment Score of Word

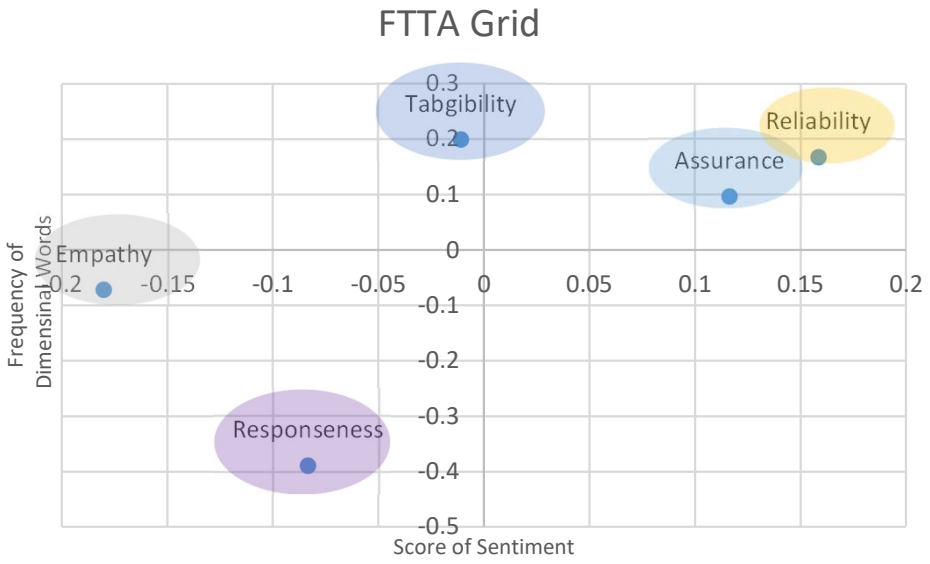
FTTA Grid
Tabgibility
Reliability
Assurance
Empathy
Responseness
0.3
0.2
0.1
0
-0.1
-0.2
-0.3
-0.4
-0.5
-0.2
-0.15
-0.1
-0.05
0
0.05
0.1
0.15
0.2
Frequency of Dimensinal Words
Score of Sentiment

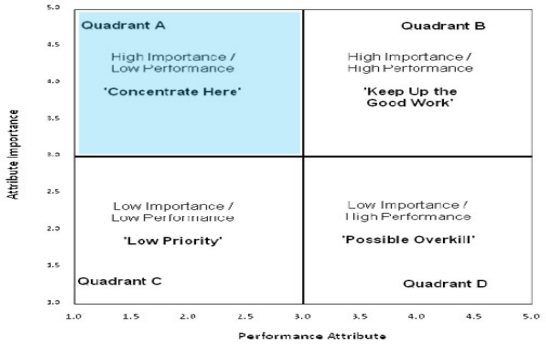
Quadrant A
High Importance / Low Performance
'Concentrate Here'
Quadrant B
High Importance / High Performance
'Keep Up the Good Work'
Low Importance / Low Performance
'Low Priority'
Quadrant C
Low Importance / High Performance
'Possible Overkill'
Quadrant D
Attribute Importance
Performance Attribute

文字分析產品服務市場

分析主題	實例	分析項目	行銷管理內函	應用產業
品牌個性 品牌經驗 品牌概念	Starbucks v.s 85Cafe 85Cafe vs. 壹咖啡 怡客 vs. 丹堤 海尼根 vs. 老虎	品牌 vs. 競爭品牌 代言人 vs. 競品代言人	網路品牌管理 (品牌定位與差異化) 廣告效果衡量	企業 娛樂業 餐旅業
產品主題情緒分析	85C Café海鹽咖啡 王品菜單 Apple iPhone7 柯P 大巨蛋事件	針高情緒分數與低情緒分數觀察 高關注的項目 產品特性之與高關聯之項目分析	新產品開發 產品滿意度調查 廣告關鍵字之投放建議	餐旅業 政府(觀光局) 3C產業 政治傳播
問卷文字化分析	餐飲業(王品滿意度) 飯店業(雲品滿意度) 1999專線滿意度	廣告效果 滿意度 服務品質	問卷調查	餐旅業 政治傳播
網路口碑管理之流程	電商或Hotel暨競爭者消費者的聲音 Trump vs. Hillary 太陽花學運 個人情緒分析	社群媒體 監測、預警、建議、推薦	網路公關 民意探勘 情資蒐集 高風險個案監測	電商餐旅業 政治傳播 研究調查機構 非營利組織
情緒分數預測民調 情緒分數預測產品市場成長及股市漲跌	柯P vs. 連勝文 Trump vs. Hillary	民調與情緒分數關連性 預測民調及選舉結果	銷售預測 市場預測	政治傳播 企業/零售/電商 財金

情緒分析網站(練習範例)

- **AFINN Sentiment**
- **lexalytics 簡介PPT**

網路爬蟲步驟範例

- Microsoft Power Query 為例
  - 柯P
  - Donald Trump
  - 政府開放資料
- Webharvy (練習範例)
- Youtube
- PTT

爬蟲軟體Webharvy
Step by Step Demo

東森新聞網
拜登相關新聞


news.ebc.net.tw
EBC東森電視 | 東森Apps | 東森美洲 | 簡体
EBC 東森新聞
POWER BOOK II: GHOST
Midseason return December 6
only on Stan.
不出國也超好玩！耶誕跨年全攻略
HBL高中籃球聯賽嗨翻全台
即時 | 熱門 | 娛樂 | 總覽 | 影音 | 開鍵 | 直播 | BBC News 中文 | 話題 | 爆料
即時
獨／半夜洗衣機自動運轉！小孩一看嚇喊：是不是有鬼 08:49
英國王室：梅根撰文緬及「禁忌」話題 披露流產的傷心與... 08:28
Live 直播
東森新聞 51頻道
英國藥廠疫苗年底足產2億劑

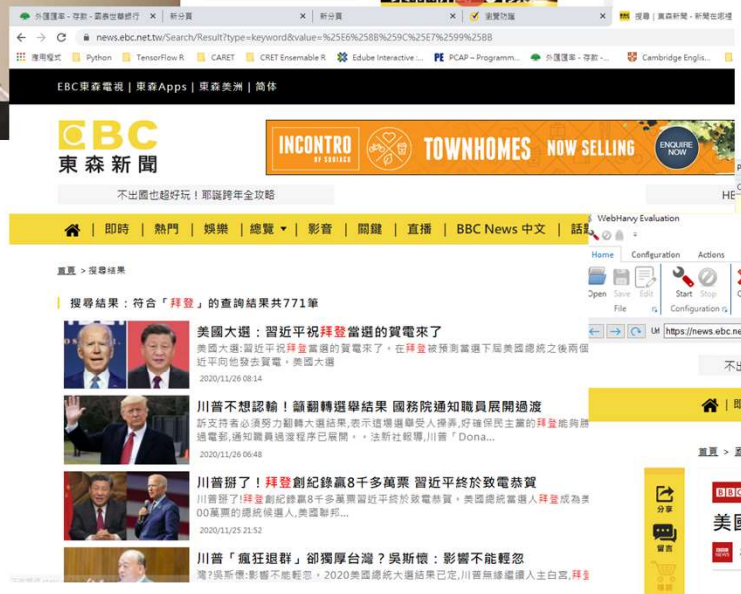
news.ebc.net.tw/Search/Result?type=keyword&value=%25E6%2588%259C%25E7%2599%2588
EBC東森電視 | 東森Apps | 東森美洲 | 簡体
EBC 東森新聞
INCONTRO TOWNHOMES NOW SELLING ENQUIRE NOW
不出國也超好玩！耶誕跨年全攻略
即時 | 熱門 | 娛樂 | 總覽 | 影音 | 開鍵 | 直播 | BBC News 中文 | 話題
首頁 > 搜尋結果
搜尋結果：符合「拜登」的查詢結果共771筆
美國大選：習近平祝拜登當選的賀電來了
美國大選:習近平祝拜登當選的賀電來了，在拜登被預測當選下屆美國總統之後兩個近平向他發去賀電，美國大選
2020/11/26 08:14
川普不想認輸！顛翻轉選舉結果 國務院通知職員展開過渡
訴支持者必須努力翻轉大選結果,表示這場選舉受人操弄,好確保民主黨的拜登能夠過電郵,通知職員過渡程序已展開，，法新社報導,川普「Dona...
2020/11/26 06:48
川普掰了！拜登創紀錄贏8千多萬票 習近平終於致電恭賀
川普掰了!拜登創紀錄贏8千多萬票習近平終於致電恭賀，美國總統當選人拜登成為美00萬票的總統候選人,美國聯邦...
2020/11/25 21:52
川普「瘋狂退群」卻獨厚台灣？吳斯懷：影響不能輕忽
灣?吳斯懷:影響不能輕忽，2020美國總統大選結果已定,川普無緣繼續人主白宮,拜登


WebHarvy Evaluation
Home Configuration Actions Tools Help
Open Save Edit File
Start Stop Configuration
Clear Settings
Start-Mine
https://news.ebc.net.tw/Search/Result?type=keyword&value=%25E6%258B%259C%25E7%2599%25BB
EBC東森電視 | 東森Apps | 東森美洲 | 簡体
EBC 東森新聞
Dr. White 白博士 家中異味多 讓你好難受?
不出國也超好玩！耶誕跨年全攻略
HBL高中籃球聯賽嗨翻全台
即時 | 熱門 | 娛樂 | 總覽 | 影音 | 開鍵 | 直播 | BBC News 中文 | 話題 | 爆料
首頁 > 搜尋結果
搜尋結果：符合「拜登」的查詢結果共771筆
美國大選：習近平祝拜登當選的賀電來了
美國大選:習近平祝拜登當選的賀電來了，在拜登被...
2020/11/26 08:14
川普不想認輸！顛翻轉選舉結果 國務院通知職員展開...
訴支持者必須努力翻轉大選結果,表示這場選舉受人操弄,好確保民
Live 直播
東森新聞 51頻道
點我看直播
Proxy [OFF] Timeout [PageLoad: 30s AJAX:5s] Miner Options [High,10,2] Mining Threads [4] Zoom [100%] Help for news.ebc.net.tw
Captured Data Preview
WebHarvy Evaluation
Home Configuration Actions Tools Help
Open Save Edit File
Start Stop Configuration
Clear Settings
Start-Mine
https://news.ebc.net.tw/news/article/237882
不出國也超好玩！耶誕跨年全攻略
HBL高中籃球聯賽嗨翻全台
即時 | 熱門 | 娛樂 | 總覽 | 影音 | 開鍵 | 直播 | BBC News 中文 | 話題 | 爆料
首頁 > 國際 > 美國大選：習近平祝拜登當選的賀電來了
分享
留言
BBC NEWS | 中文
美國大選：習近平祝拜登當選的賀電來了
2020/11/26 08:14
字級： 字 字
0:00 / 4:37
Live 直播
東森新聞 51頻道
點我看直播
中華電信 5G

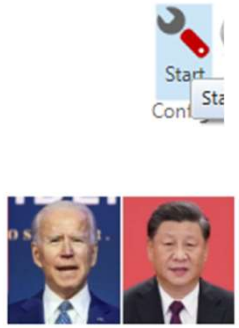

美國大選：習近平祝拜登

美國大選:習近平祝拜登當選的賀電來了。在拜登被...

2020/11/26 08:14

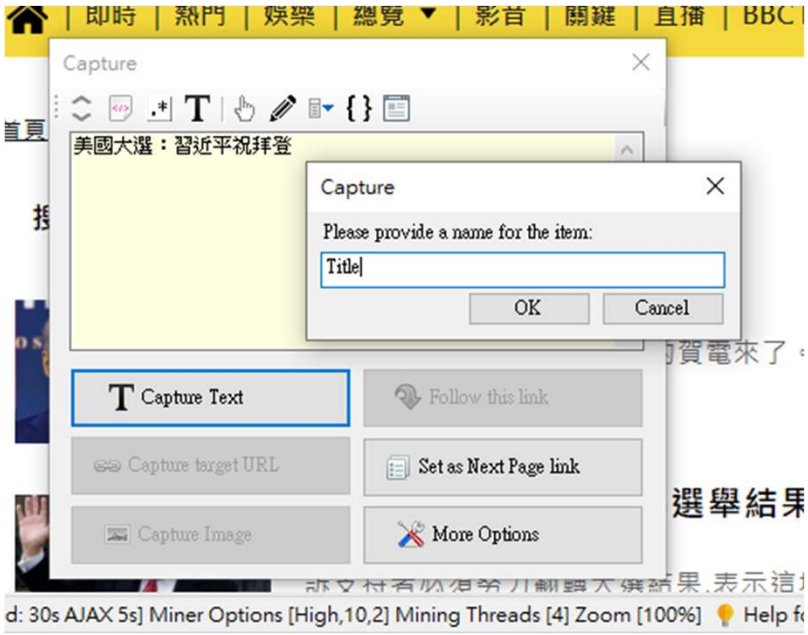

搜尋結果：符合「拜登」的查詢結果共771筆

美國大選：習近平祝拜登

美國大選:習近平祝拜登當選的賀電來了。在拜登被...

2020/11/26 08:14

Capture

美國大選：習近平祝拜登
美國大選:習近平祝拜登當選的賀電來了。在拜登被...
2020/11/26 08:14

Capture Text | Follow this link | Capture target URL | Set as Next Page link | Capture Image | More Options

Title	Content
美國大選：習近平祝拜登	美國大選：習近平祝拜登當選的賀電來了 2020/11/26 08:14 字級：字 字 ▲（圖／REUTERS/EPA） 在拜登被預測當選下屆美國總統之後兩個多星期，中國最高領導人習近平向他發去賀電。 美國大選
川普不想認輸！翻盤轉進舉結果 國務院通知職員展開...	--
川普贺了！拜登創紀錄...	--
川普「瘋狂選群」卻獨厚台灣？吳斯懷：影響不能輕忽	--

WebHarvy Evaluation

Home | Configuration | Actions | Tools | Help

Open | Save | Edit | Start | Stop | Clear | Settings | Start-Mine

File | Configuration

Url https://news.ebc.net.tw/news/article/237882

即時 | 熱門 | 娛樂 | 總覽 | 影音 | 關鍵 | 直播 | BBC News 中文 | 話題 | 爆料

美國大選：習近平祝拜登當選的賀電來了

2020/11/26 08:14 字級：字 字

0:00 / 4:37

Capture

美國大選：習近平祝拜登當選的賀電來了
2020/11/26 08:14
字級：字 字

▲（圖／REUTERS/EPA）

在拜登被預測當選下屆美國總統之後兩個多星期，中國最高領導人習近平向他發去賀電。

Capture Text | Capture target URL | Capture Image

Capture

Please provide a name for the item:

Content

OK | Cancel

PA）

後兩個多星期，中國最高領導人習近

勝出之後不久，包括德國總理默克爾、法國總統馬克龍、英國首相約翰遜在內的多國領導人都在第一時間致電拜登表示祝

Proxy [OFF] Timeout [PageLoad: 30s AJAX 5s] Miner Options [High,10,2] Mining Threads [4] Zoom [100%] Help for news.ebc.net.tw

Captured Data Preview

Title

美國大選：習近平祝拜登
川普不想認輸！翻盤轉進舉結果 國務院通知職員展開...
川普贺了！拜登創紀錄...
川普「瘋狂選群」卻獨厚台灣？吳斯懷：影響不能輕忽
拜登外交核心三人組：...


WebHarvy Evaluation
Home
Configuration
Actions
Tools
Help
Open
Save
Edit
File
Start
Stop
Configuration
Clear
Settings
Start-Mine
Url
https://news.ebc.net.tw/Search/Result?type=keyword&value=%25E6%258B%259C%25E7%2599%25BB
即時 | 熱門 | 娛樂 | 總覽 | 影音 | 關鍵 | 直播 | BBC News 中文
首頁 > 搜尋結果
搜尋結果：符合「拜登」的
美國大選
2020/11/26 0
川普不
開...
2020/11/26 0
川普掰了
川普掰了!
當選人
2020/11/25 2
2020/11/22 08:43
川普還能翻盤？預告將公開喬治亞
幕」...
陣營對搖擺州喬治亞州的結果不服,喬治亞
最終還是宣布由拜登
2020/11/22 08:43
1 2 3 4 5 >
Capture
Capture Text
Follow this link
Capture target URL
Set as Next Page link
Stop
Start-Mine
節目表 | 新聞自律委員會 | 資訊公開專區 | 取消訂閱推播
東森電視首頁 | 財經新聞台 | 綜合台 | 戲劇台 | 幼幼台 | 電影台 | 洋片台 | 超視 | 美洲衛視 | YOYO幼兒園 | 東
東森電視事業股份有限公司 10041 台北市忠孝西路一段
服務時間：週一至週五 09:00-20:00 | 客
EBC東森新聞

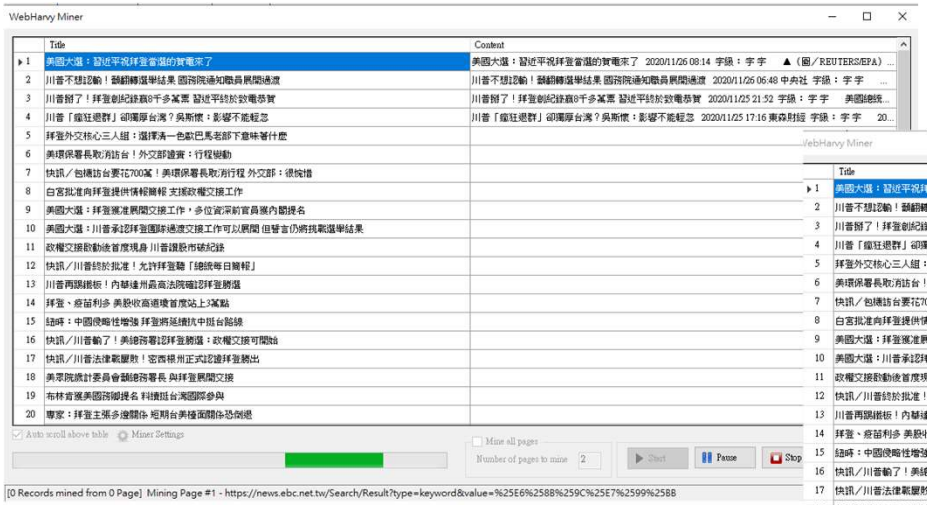
WebHarvy Miner
Title
Content
1 美國大選：習近平祝拜登當選的賀電來了 美國大選：習近平祝拜登當選的賀電來了 2020/11/26 08:14 字級：字 字 ▲（圖／REUTERS/EPA）...
2 川普不想認輸！翻翻轉選舉結果 國務院通知職員展開過渡 川普不想認輸！翻翻轉選舉結果 國務院通知職員展開過渡 2020/11/26 06:48 中央社 字級：字 字 ...
3 川普辦了！拜登創紀錄贏8千多萬票 習近平賀於致電恭賀 川普辦了！拜登創紀錄贏8千多萬票 習近平賀於致電恭賀 2020/11/25 21:52 字級：字 字 美國總統...
4 川普「瘋狂選群」卻獨厚台灣？吳斯懷：影響不能輕忽 川普「瘋狂選群」卻獨厚台灣？吳斯懷：影響不能輕忽 2020/11/25 17:16 東森財經 字級：字 字 20...
5 拜登外交核心三人組：選擇清一色歐巴馬老部下意味著什麼
6 美環保署長取消訪台！外交部證實：行程變動
7 快訊／包機訪台要花700萬！美環保署長取消行程 外交部：很惋惜
8 白宮批准向拜登提供情報簡報 支援政權交接工作
9 美國大選：拜登獲准展開交接工作，多位資深前官員獲內閣提名
10 美國大選：川普承認拜登團隊過渡交接工作可以展開 但誓言仍將挑戰選舉結果
11 政權交接啟動後首度現身 川普讚股市破紀錄
12 快訊／川普終於批准！允許拜登聽「總統每日簡報」
13 川普再踢鐵板！內華達州最高法院確認拜登勝選
14 拜登、疫苗利多 美股收高道瓊首度站上3萬點
15 紐時：中國侵略性增強 拜登將延續抗中挺台路線
16 快訊／川普輸了！美總務署認拜登勝選：政權交接可開始
17 快訊／川普法律戰屢敗！密西根州正式認證拜登勝出
18 美眾院統計委員會翻總務署長 與拜登展開交接
19 布林肯獲美國務卿提名 料擔挺台漸團隊參與
20 專家：拜登主張多邊關係 短期台美種面關係恐倒退
Auto scroll above table
Miner Settings
Mine all pages
Number of pages to mine
Start
Pause
Stop
[0 Records mined from 0 Page] Mining Page #1 - https://news.ebc.net.tw/Search/Result?type=keyword&value=%25E6%2588%259C%25E7%2599%25BB

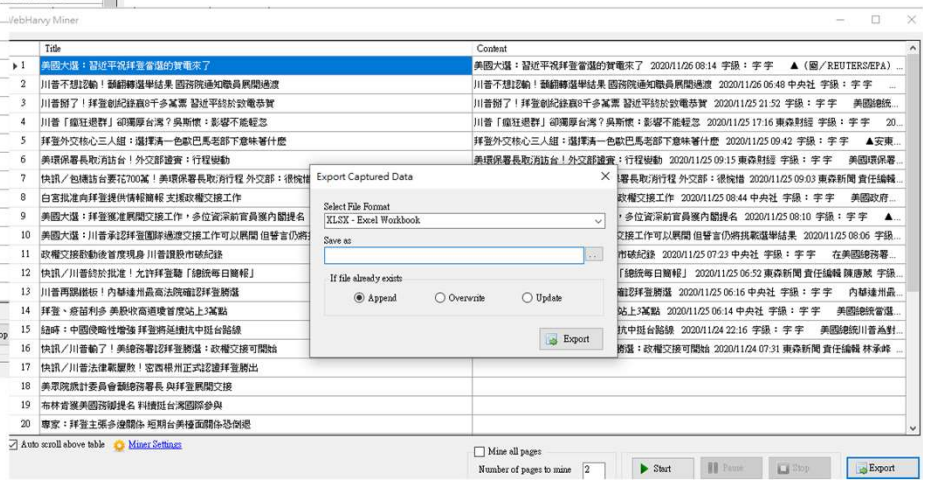
WebHarvy Miner
Export Captured Data
Select File Format
XLSX - Excel Workbook
Save as
If file already exists
Append
Overwrite
Update
Export
Start
Pause
Stop

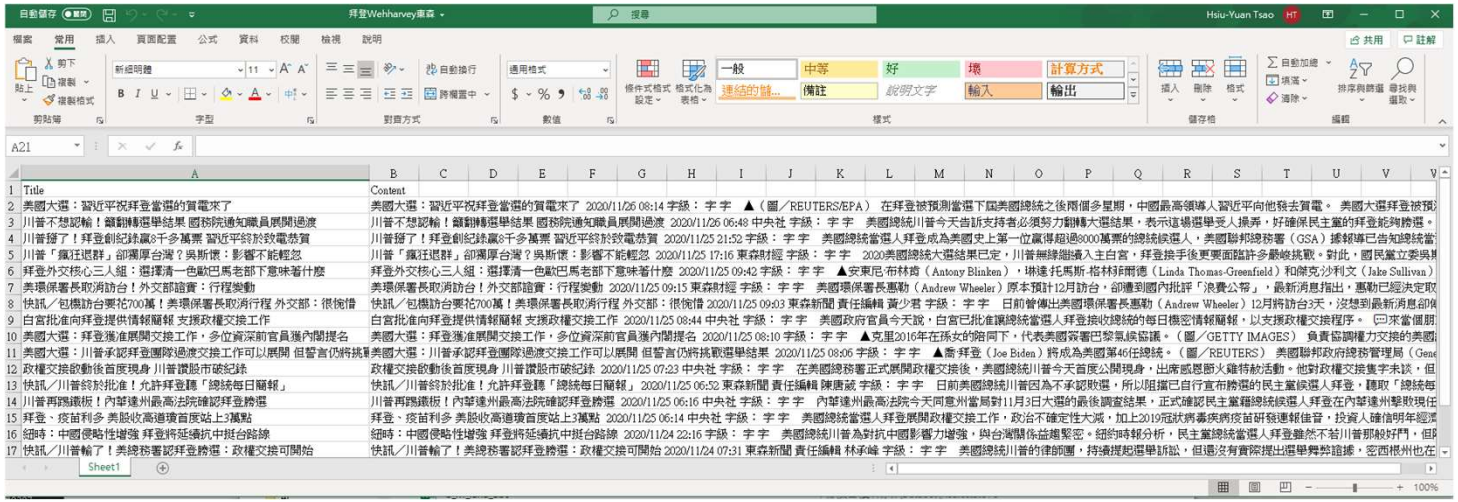
Hsiu-Yuan Tsao
A21
Sheet1

輿情系統

範例介紹

篩選測關注的議題

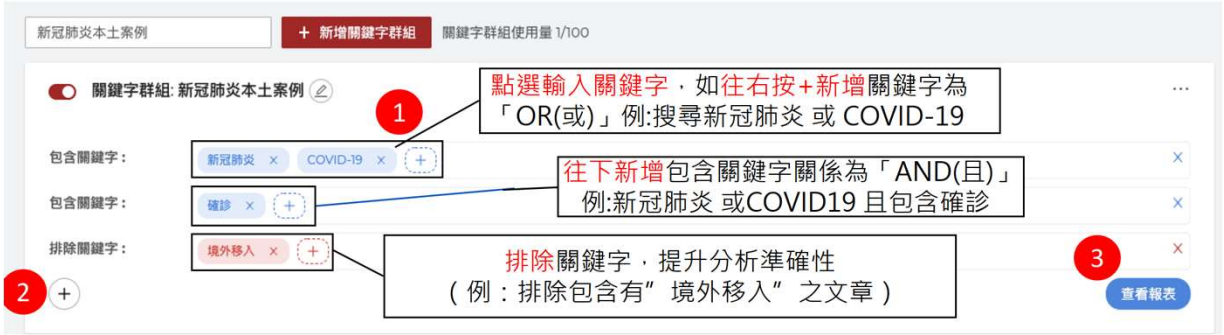

擷取公開網站的資料

聲量(攸關性)

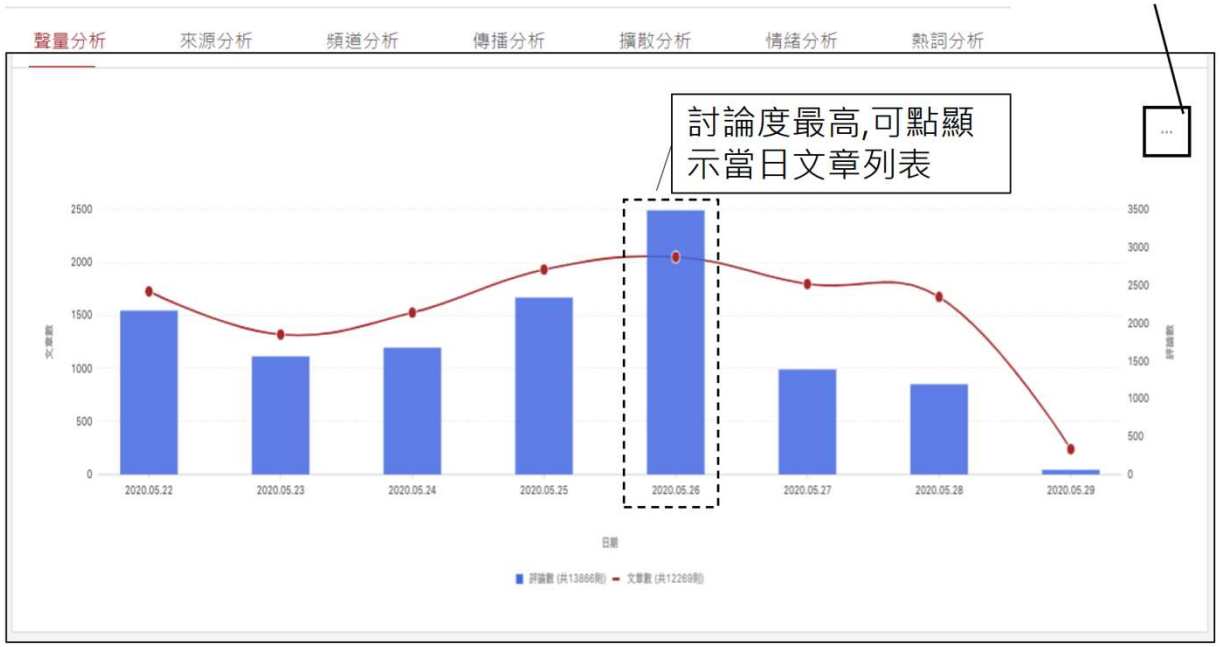

關鍵字文章/評論數(回文數) 趨勢圖
橫軸：日期
縱軸：關鍵字文章數(折線)
　　文章評論數(回文數)(直條)

情感(篇好與態度)

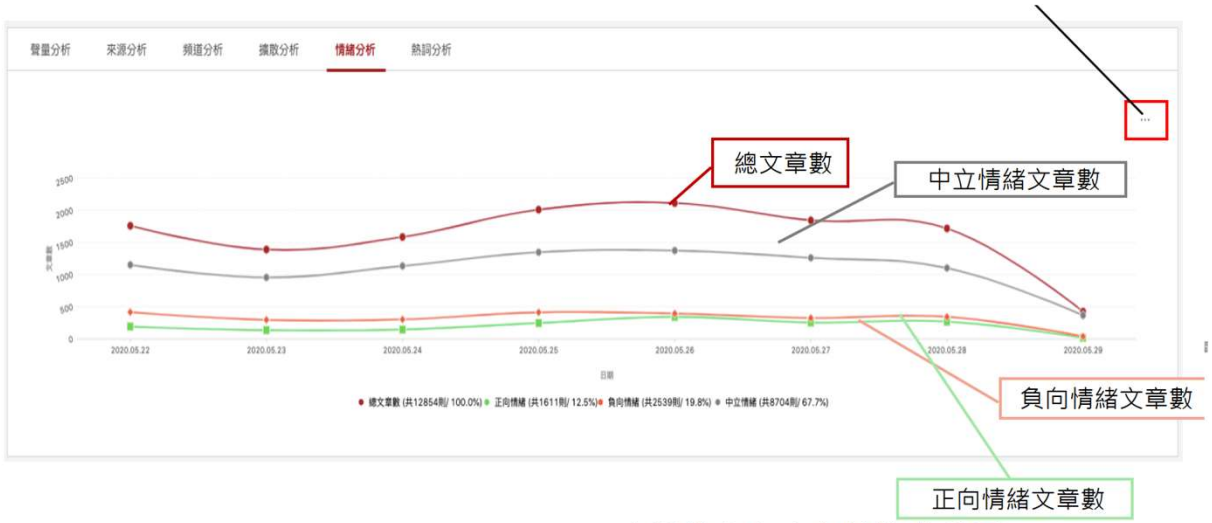

含關鍵字文章之情緒曲線圖
(橫軸：日期 / 縱軸：文章數)

聲量(攸關性)

熱門議題分群-熱門關鍵字

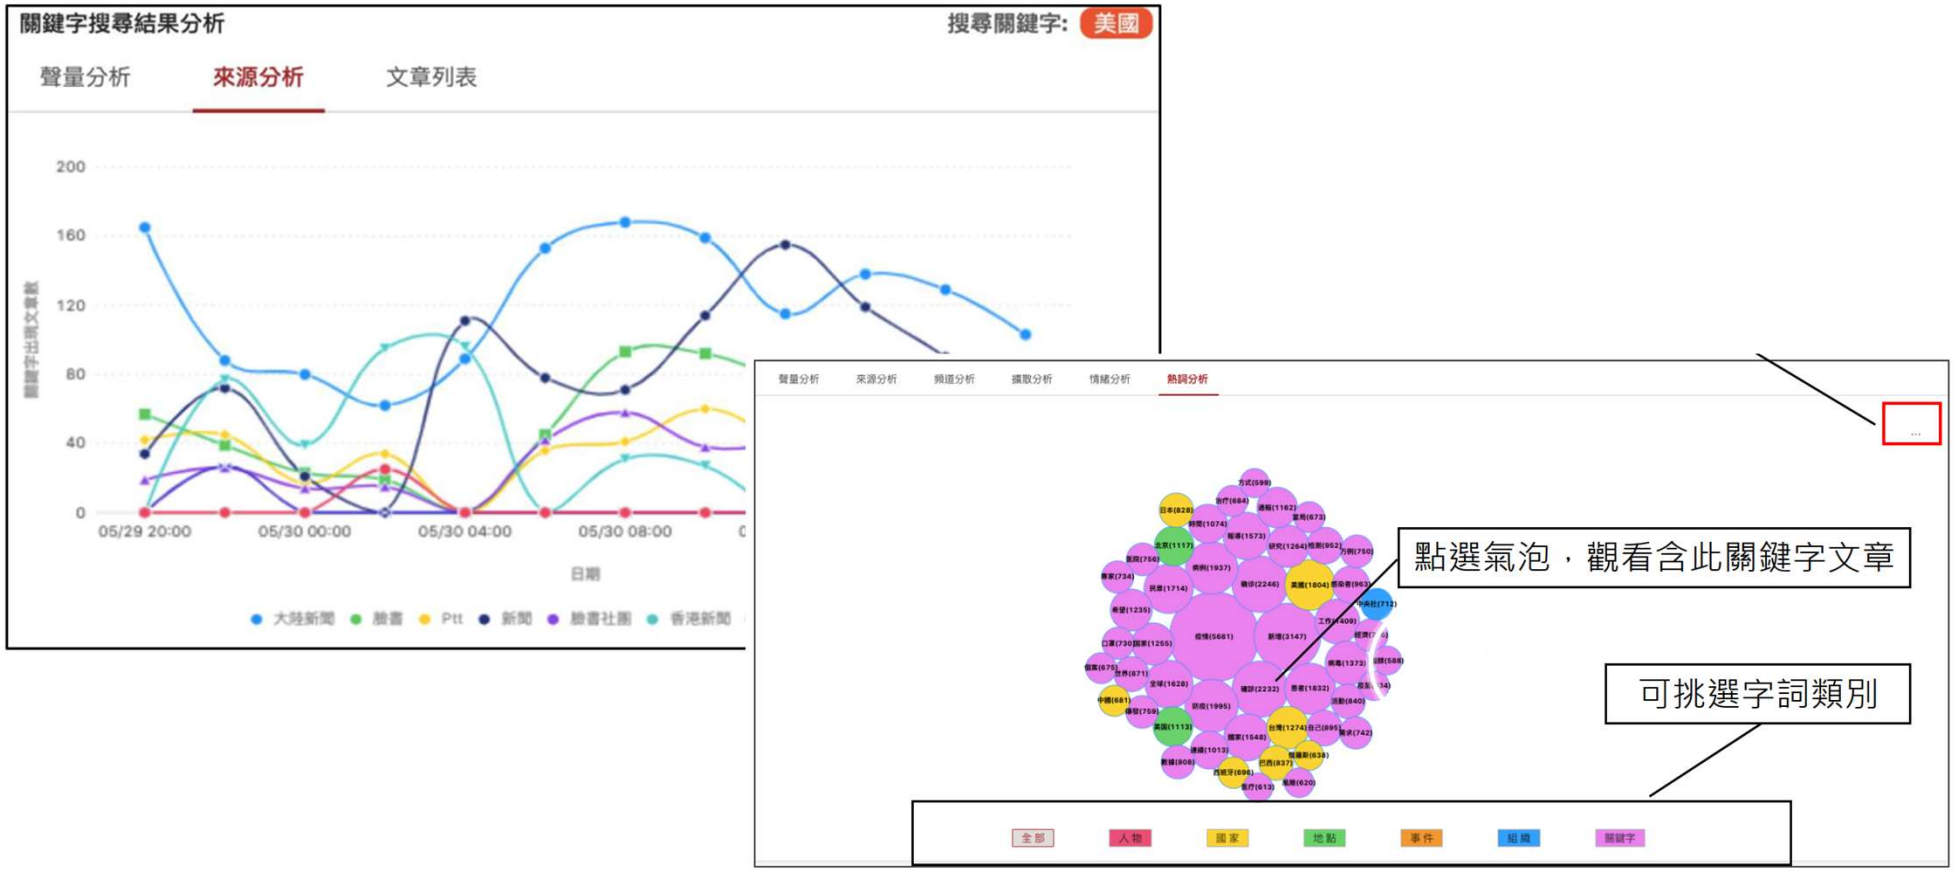

含關鍵字文章之字詞氣泡圖

提供目前台灣地區輿情系統的供應商供參考

1. InfoMiner https://www.largitdata.com/
2. LOWI https://www.chiefappc.com
3. Opview https://www.opview.com.tw/
4. Quickseek https://www.quickseek.com.tw/

機器學習範例

Azure Machine Learning Studio

https://studio.azureml.net

Azure Machine Learning Studio

- 資料集: iris.csv
-
  步驟:
  - 1.Data 匯入
  - 2.Select Column in dataset
  - 3.APPLY SQL transformation
  - 4.Split data（將檔案分割）
  - 5.(左邊開始寫演算法ex Multiclass Neural Network)
  - 6.Train Model
  - 7.Score Model
  - 8.Evalute Model
-
-

Azure Machine Learning Studio

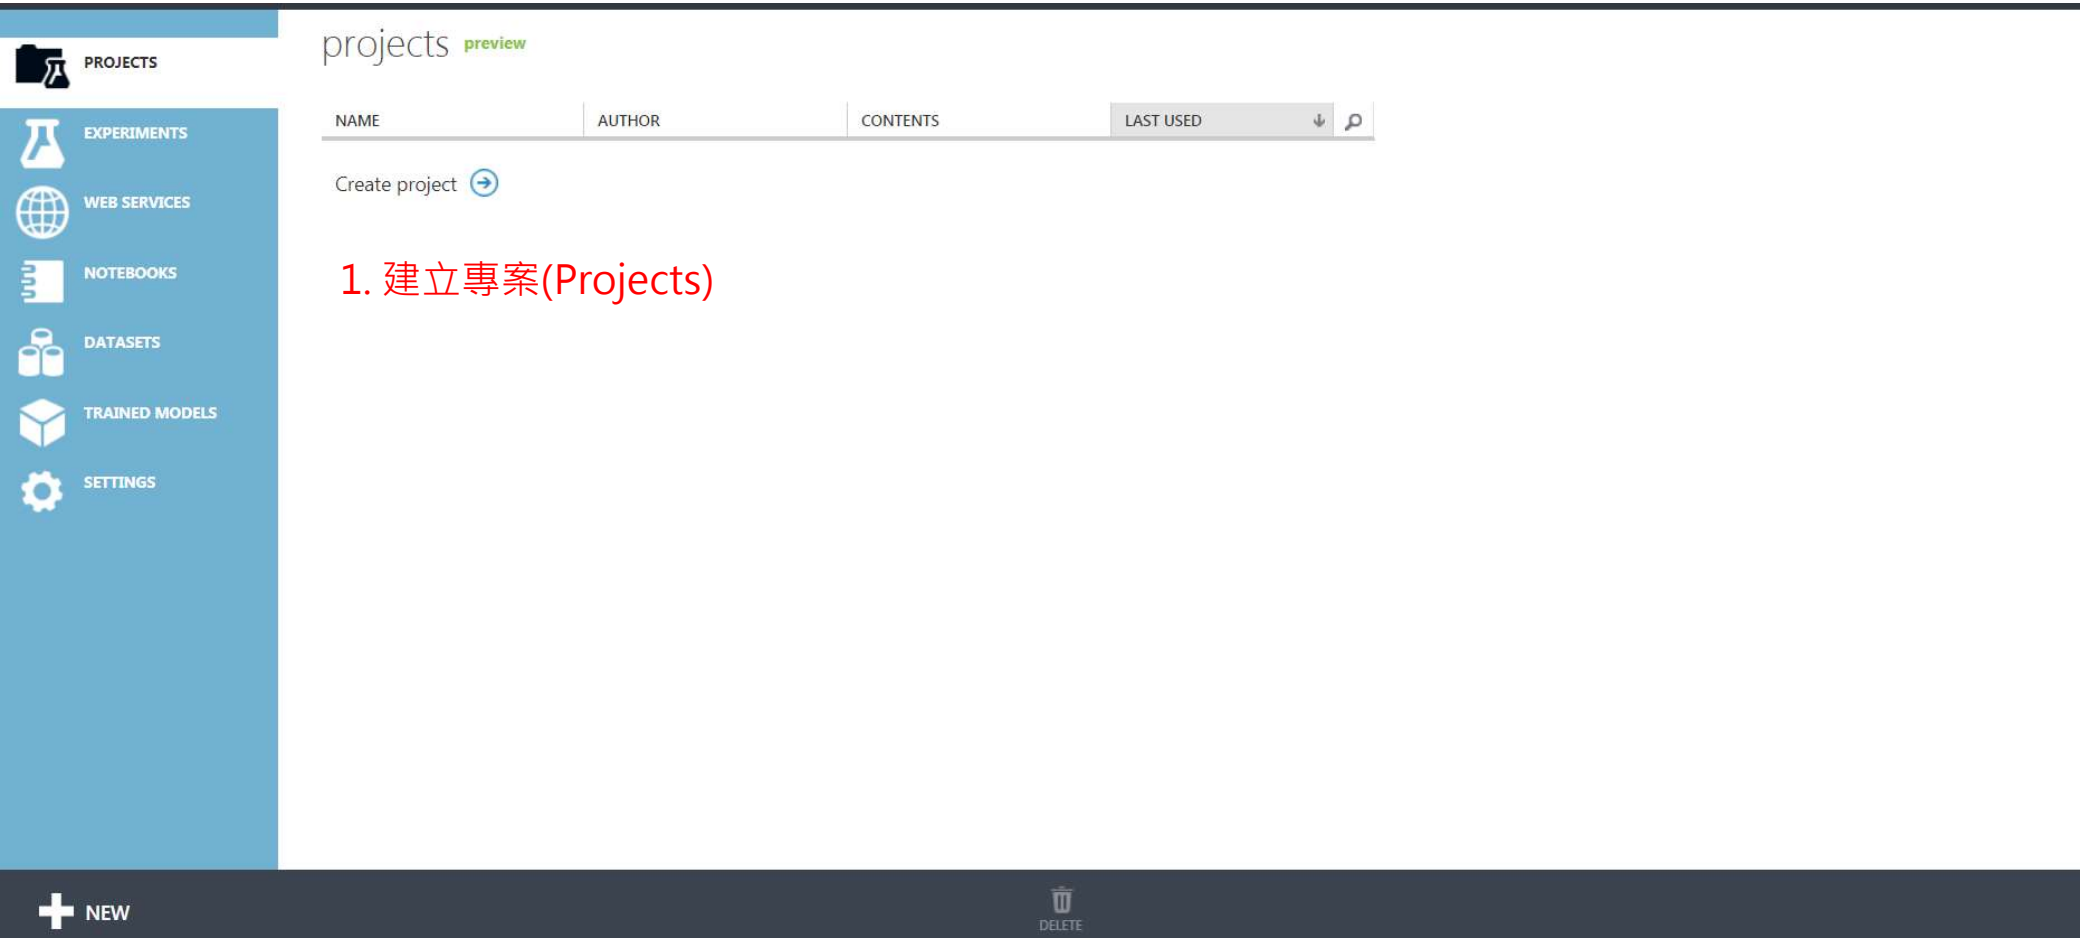

Azure Machine Learning Studio

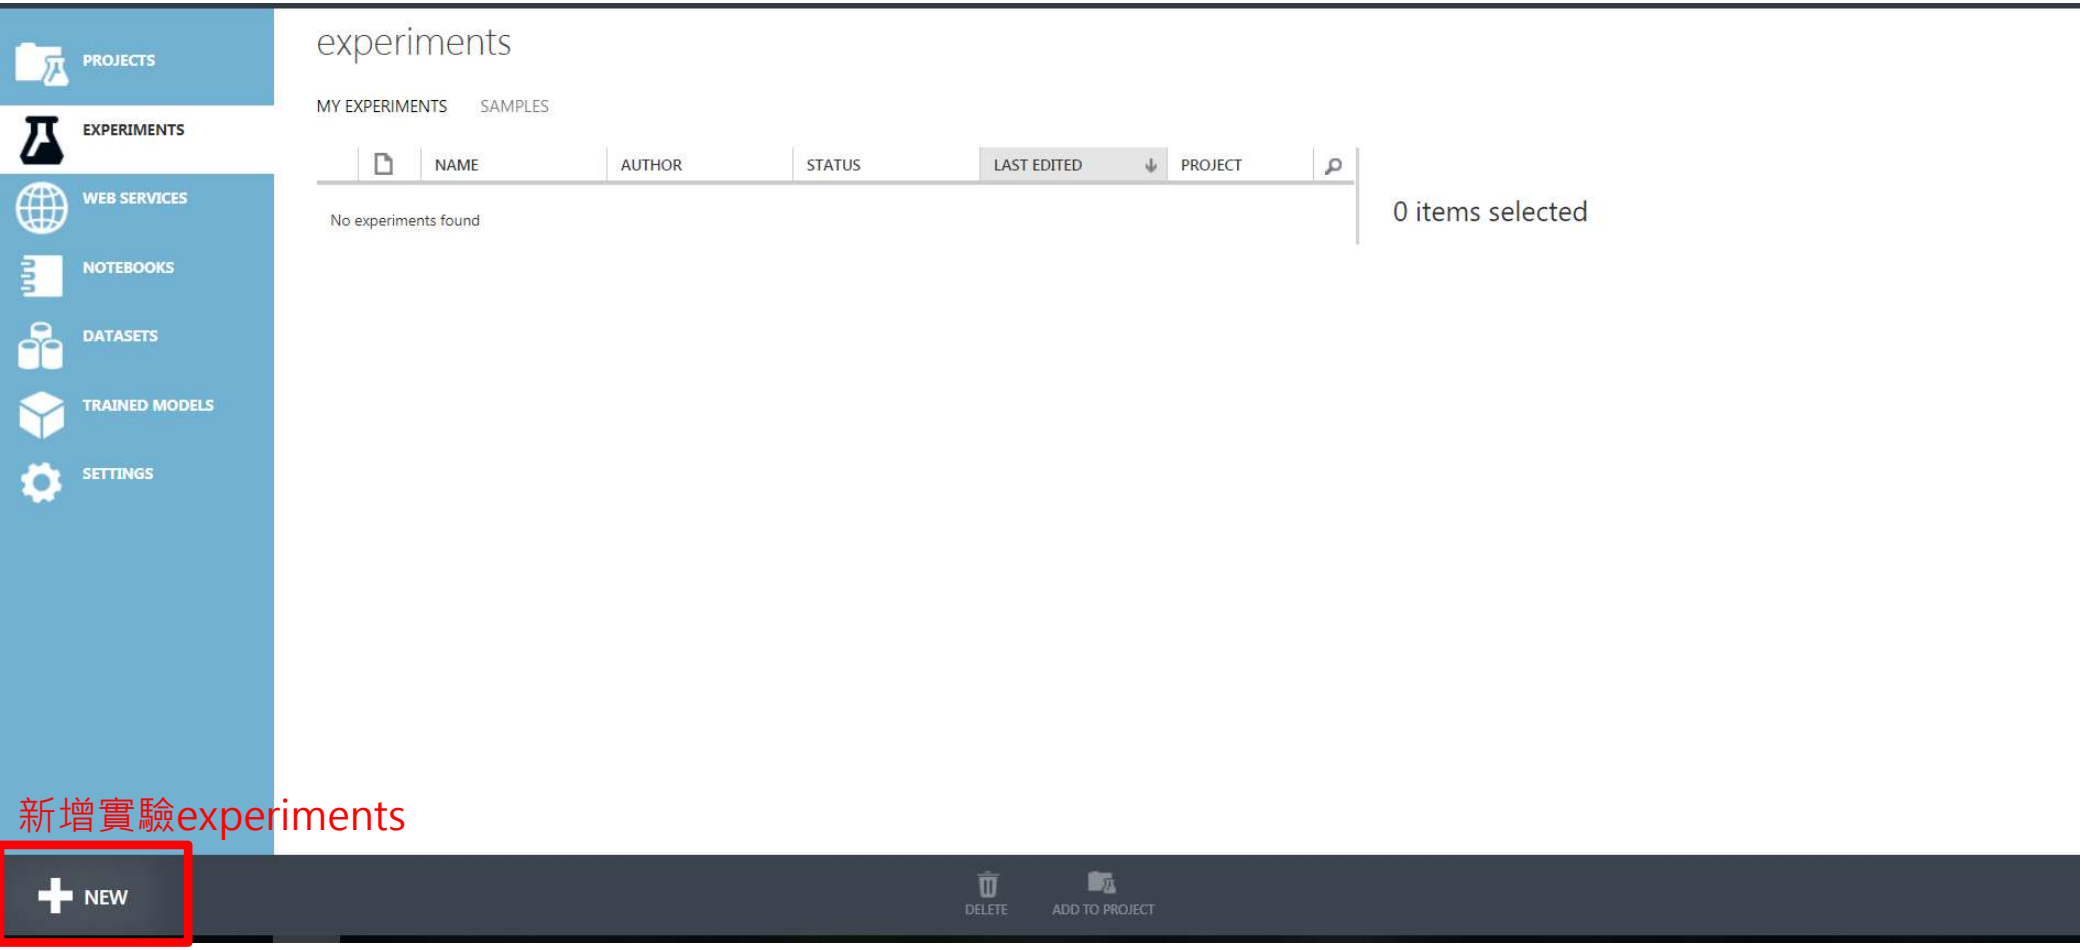

Azure Machine Learning Studio

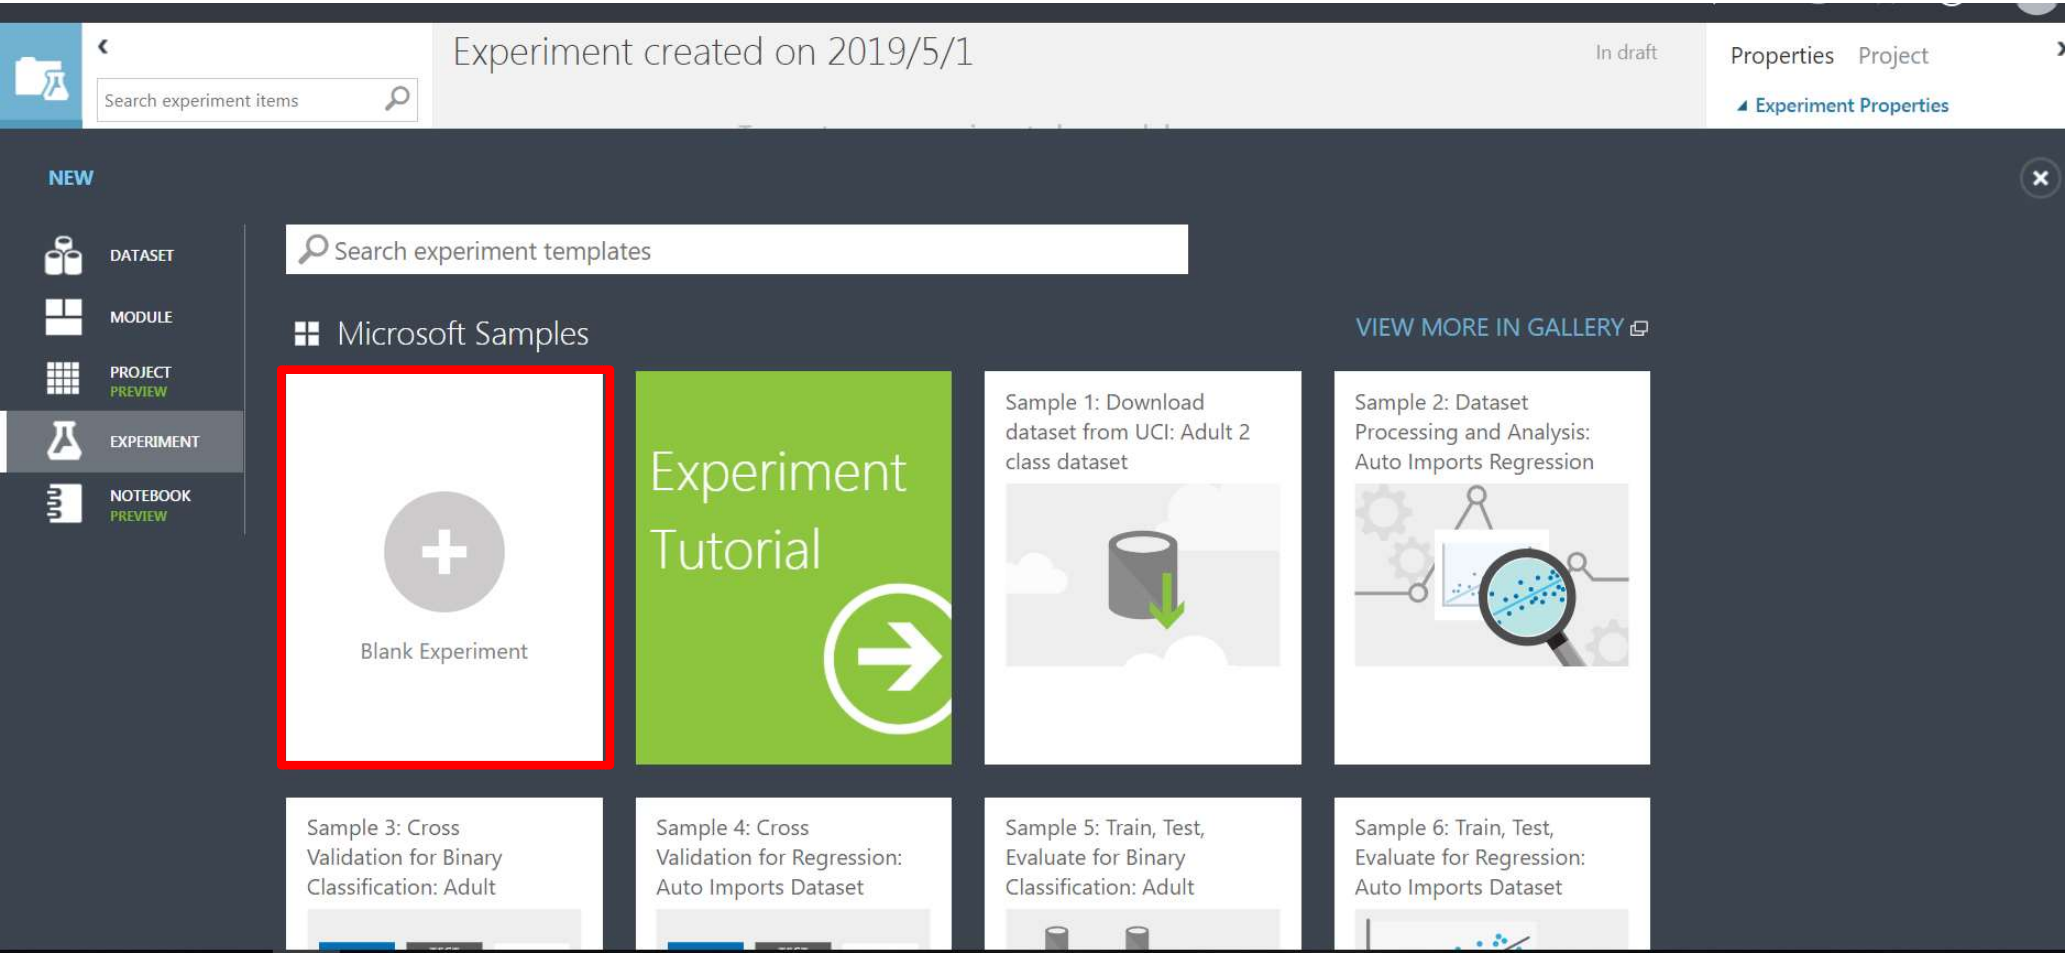

Azure Machine Learning Studio

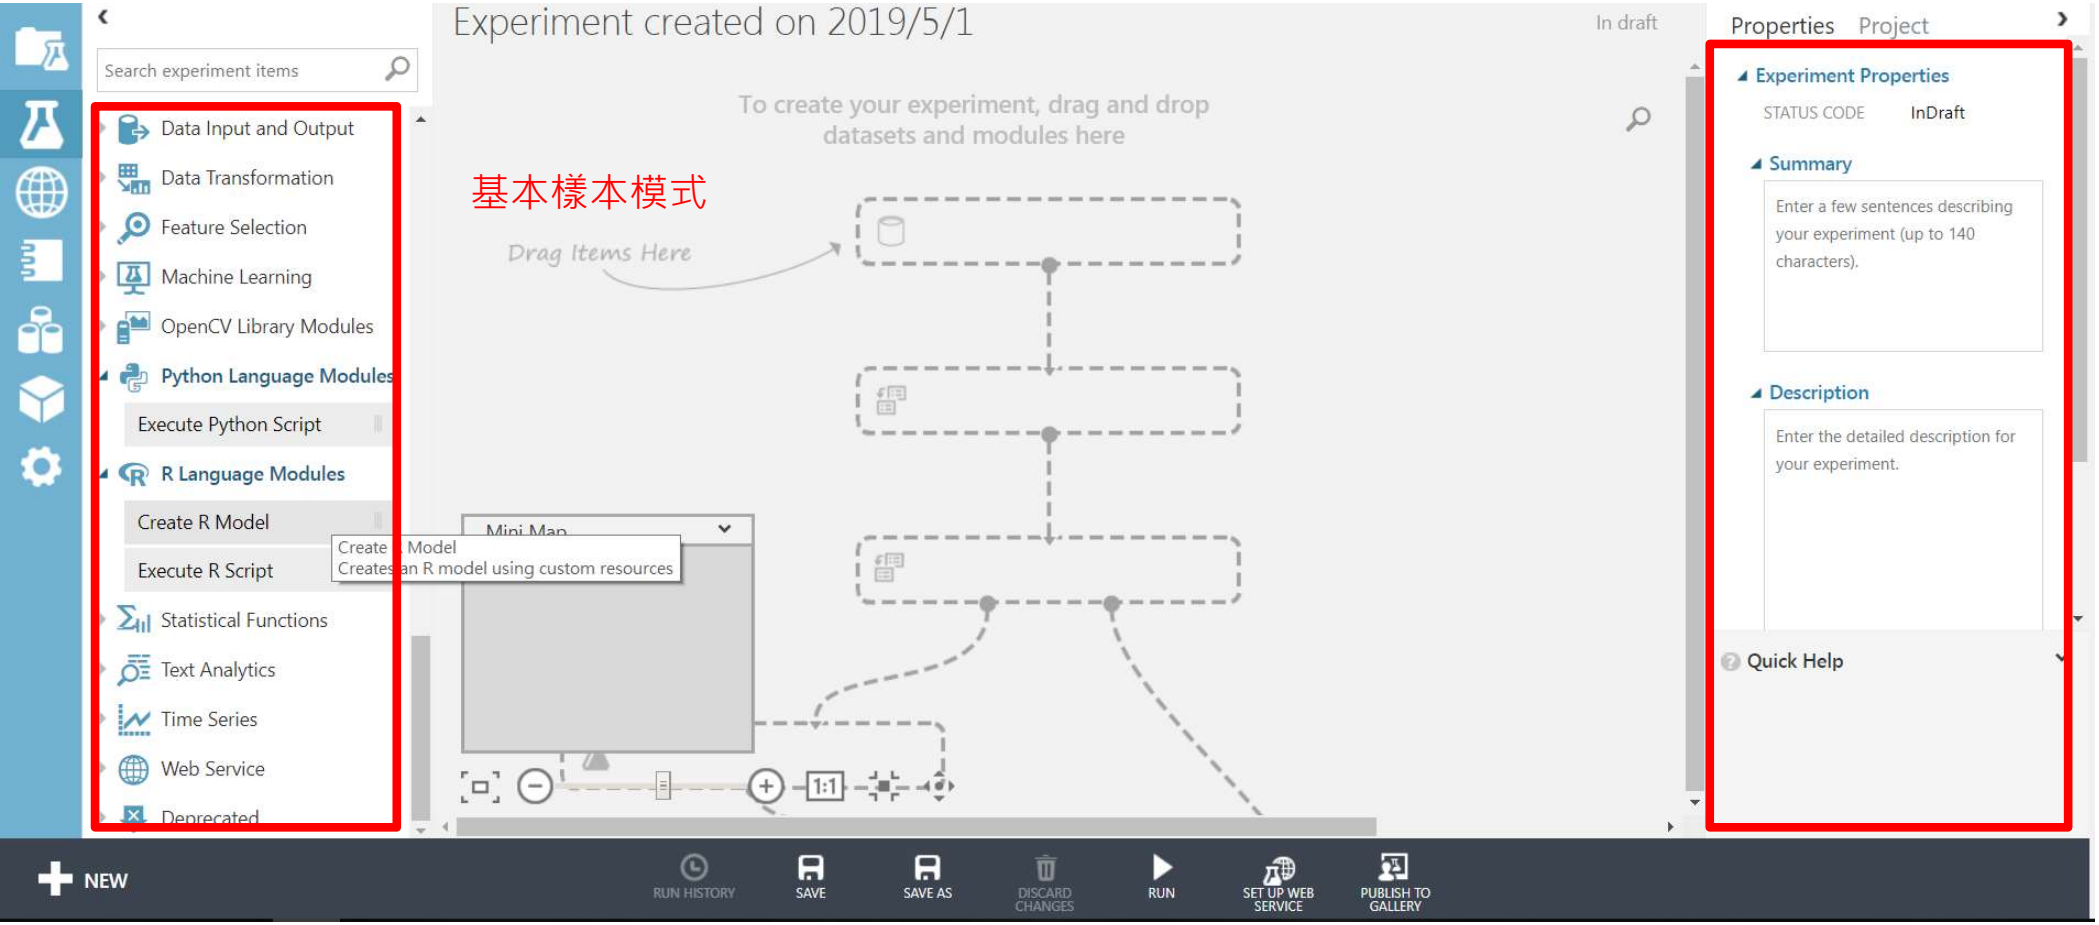

1.資料集(Dataset)上傳

Azure Machine Learning Studio

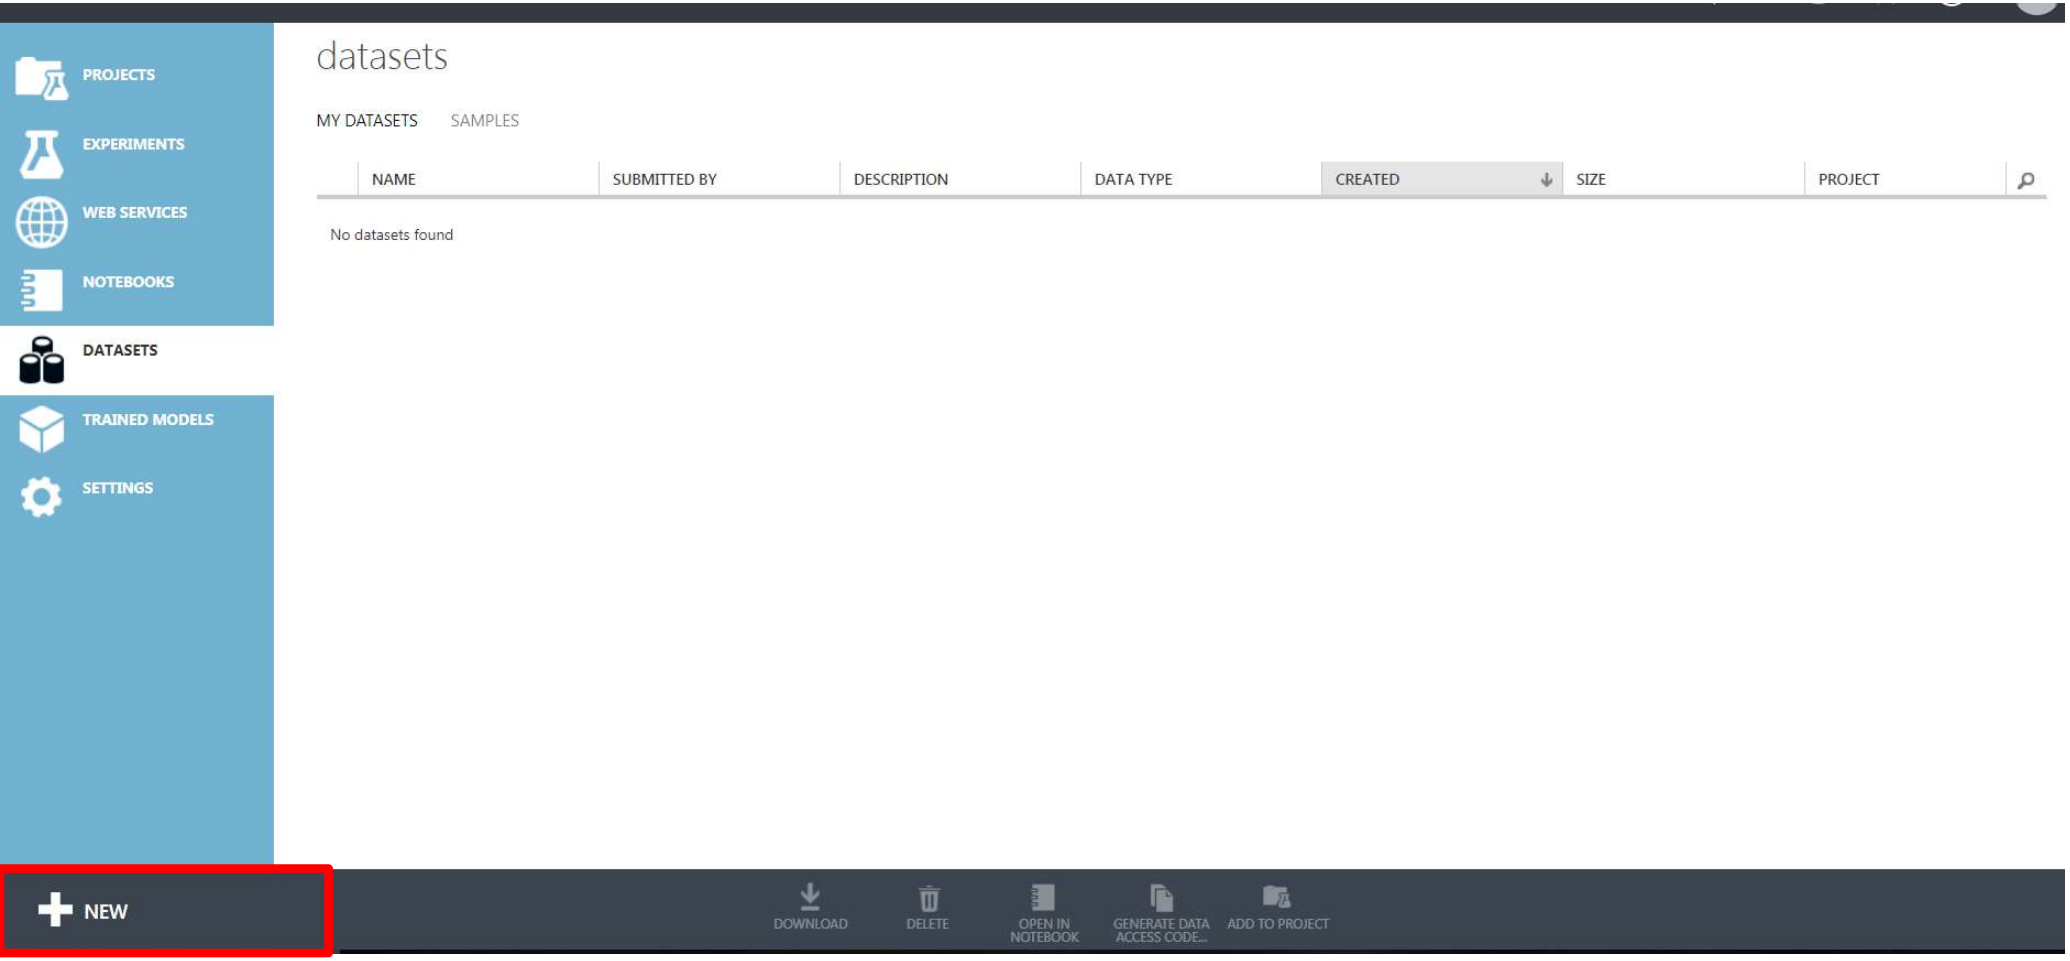

Azure Machine Learning Studio

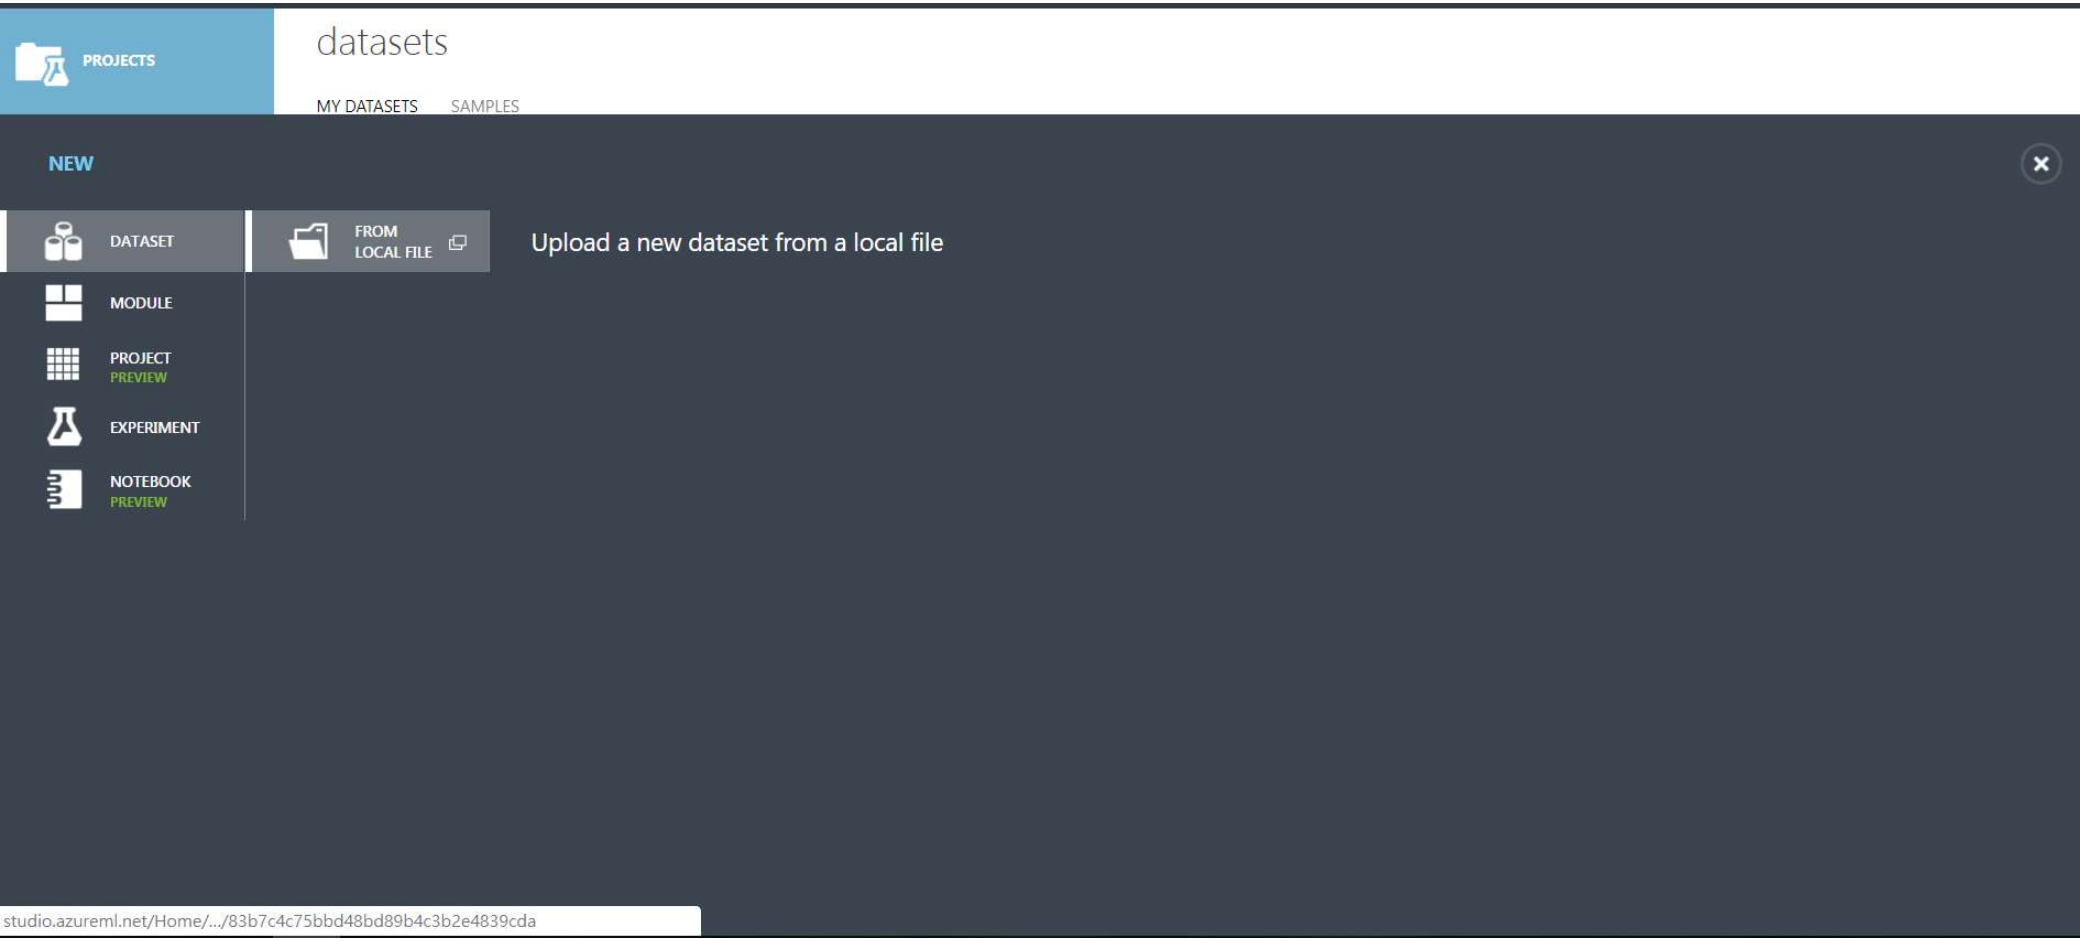

Azure Machine Learning Studio

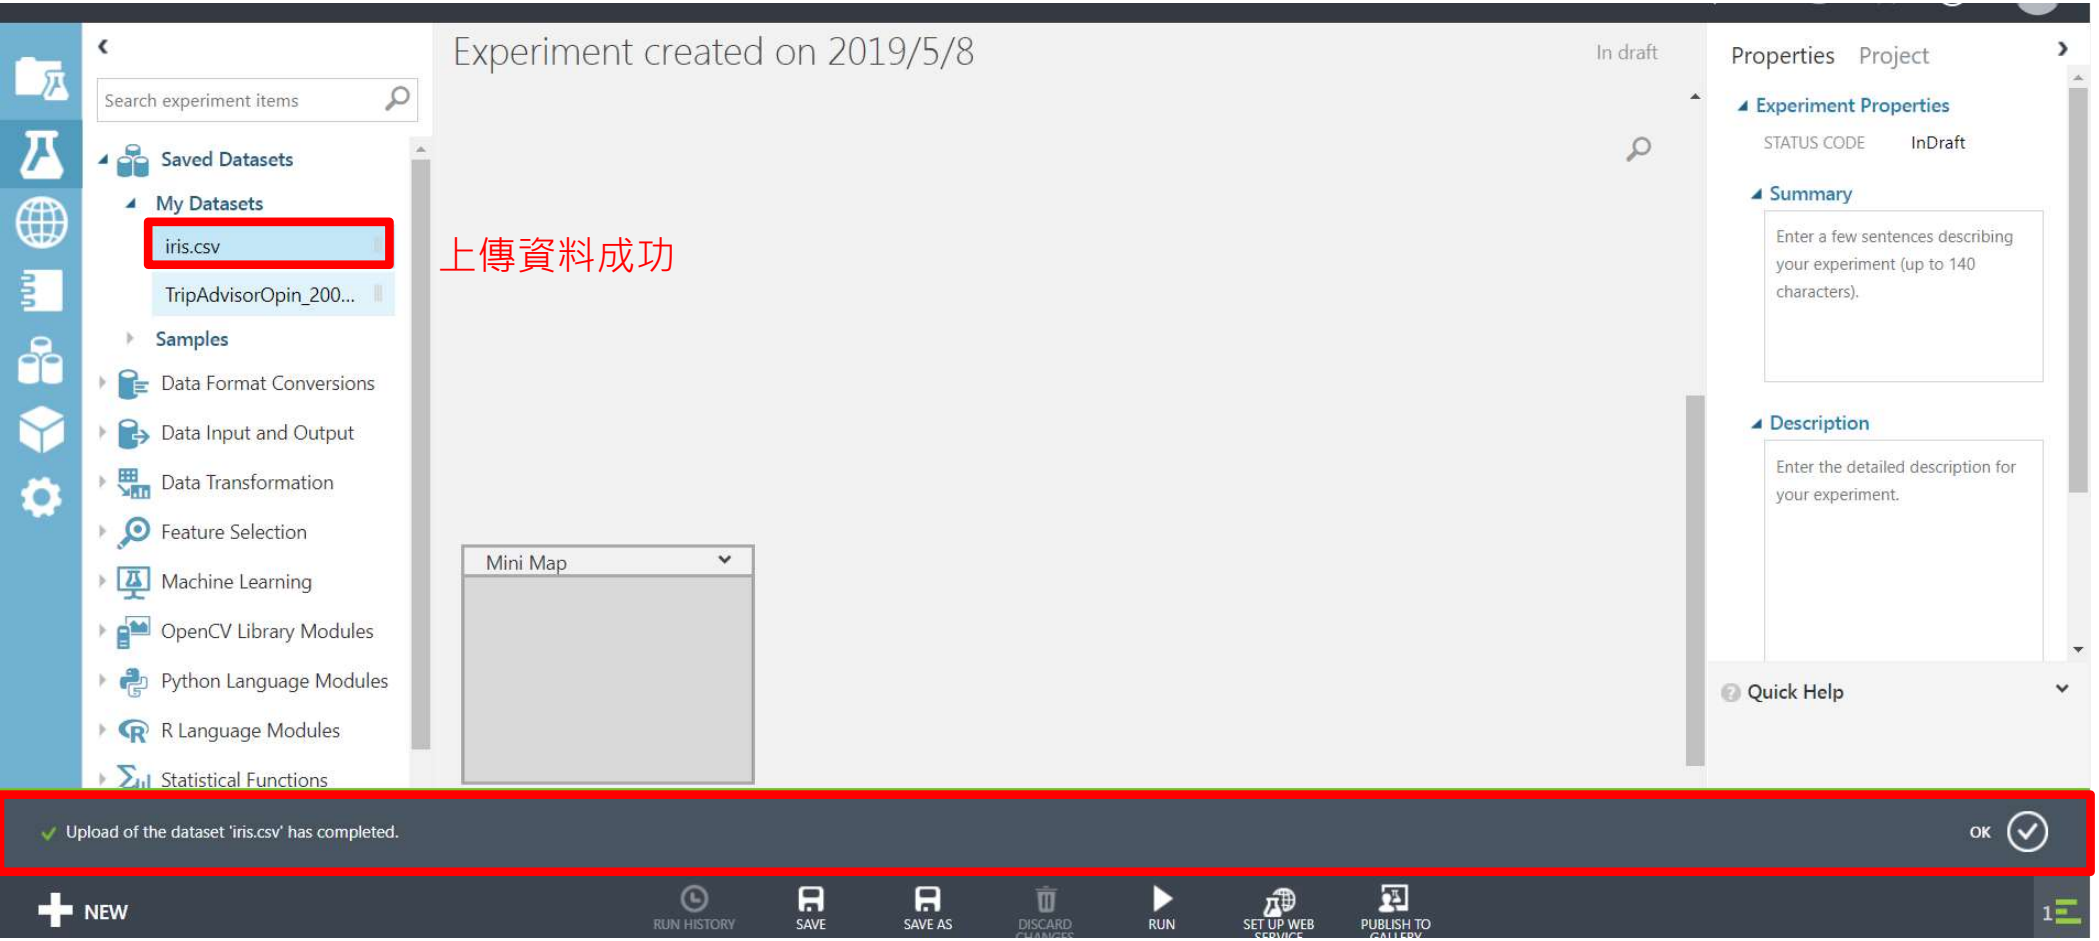

Azure Machine Learning Studio

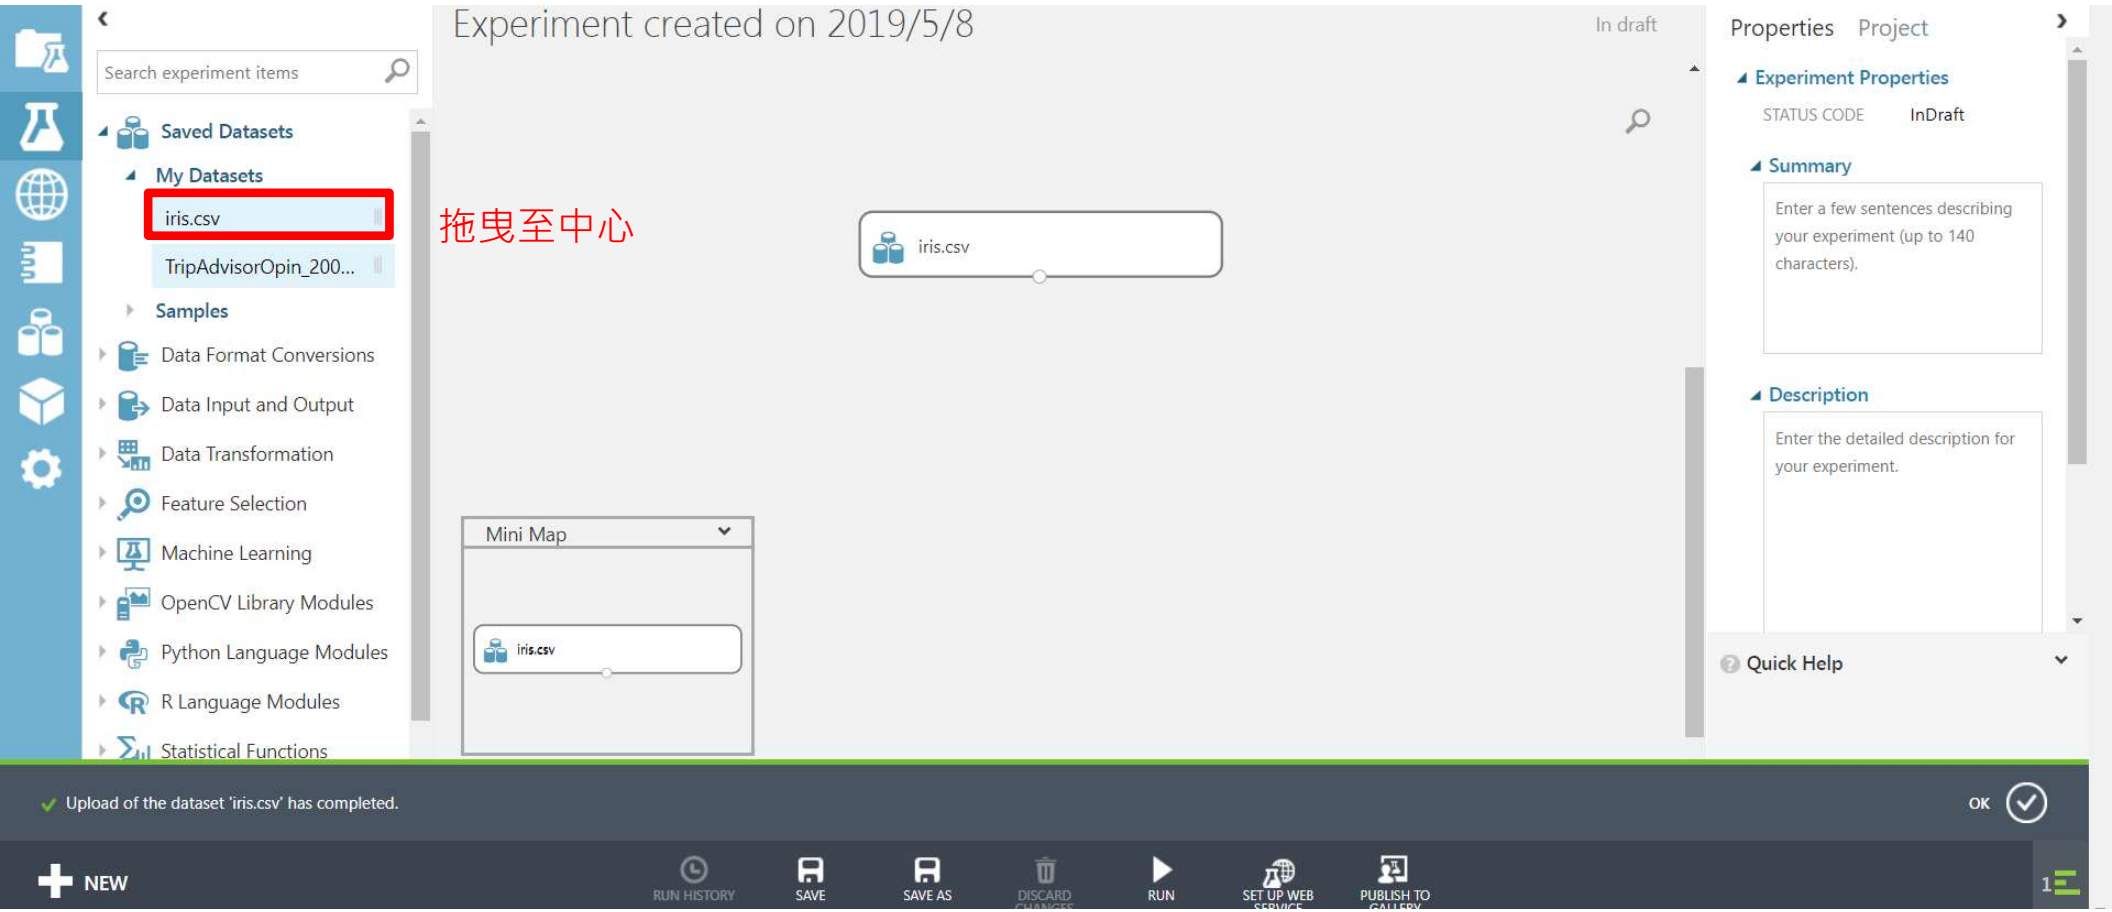

Azure Machine Learning Studio

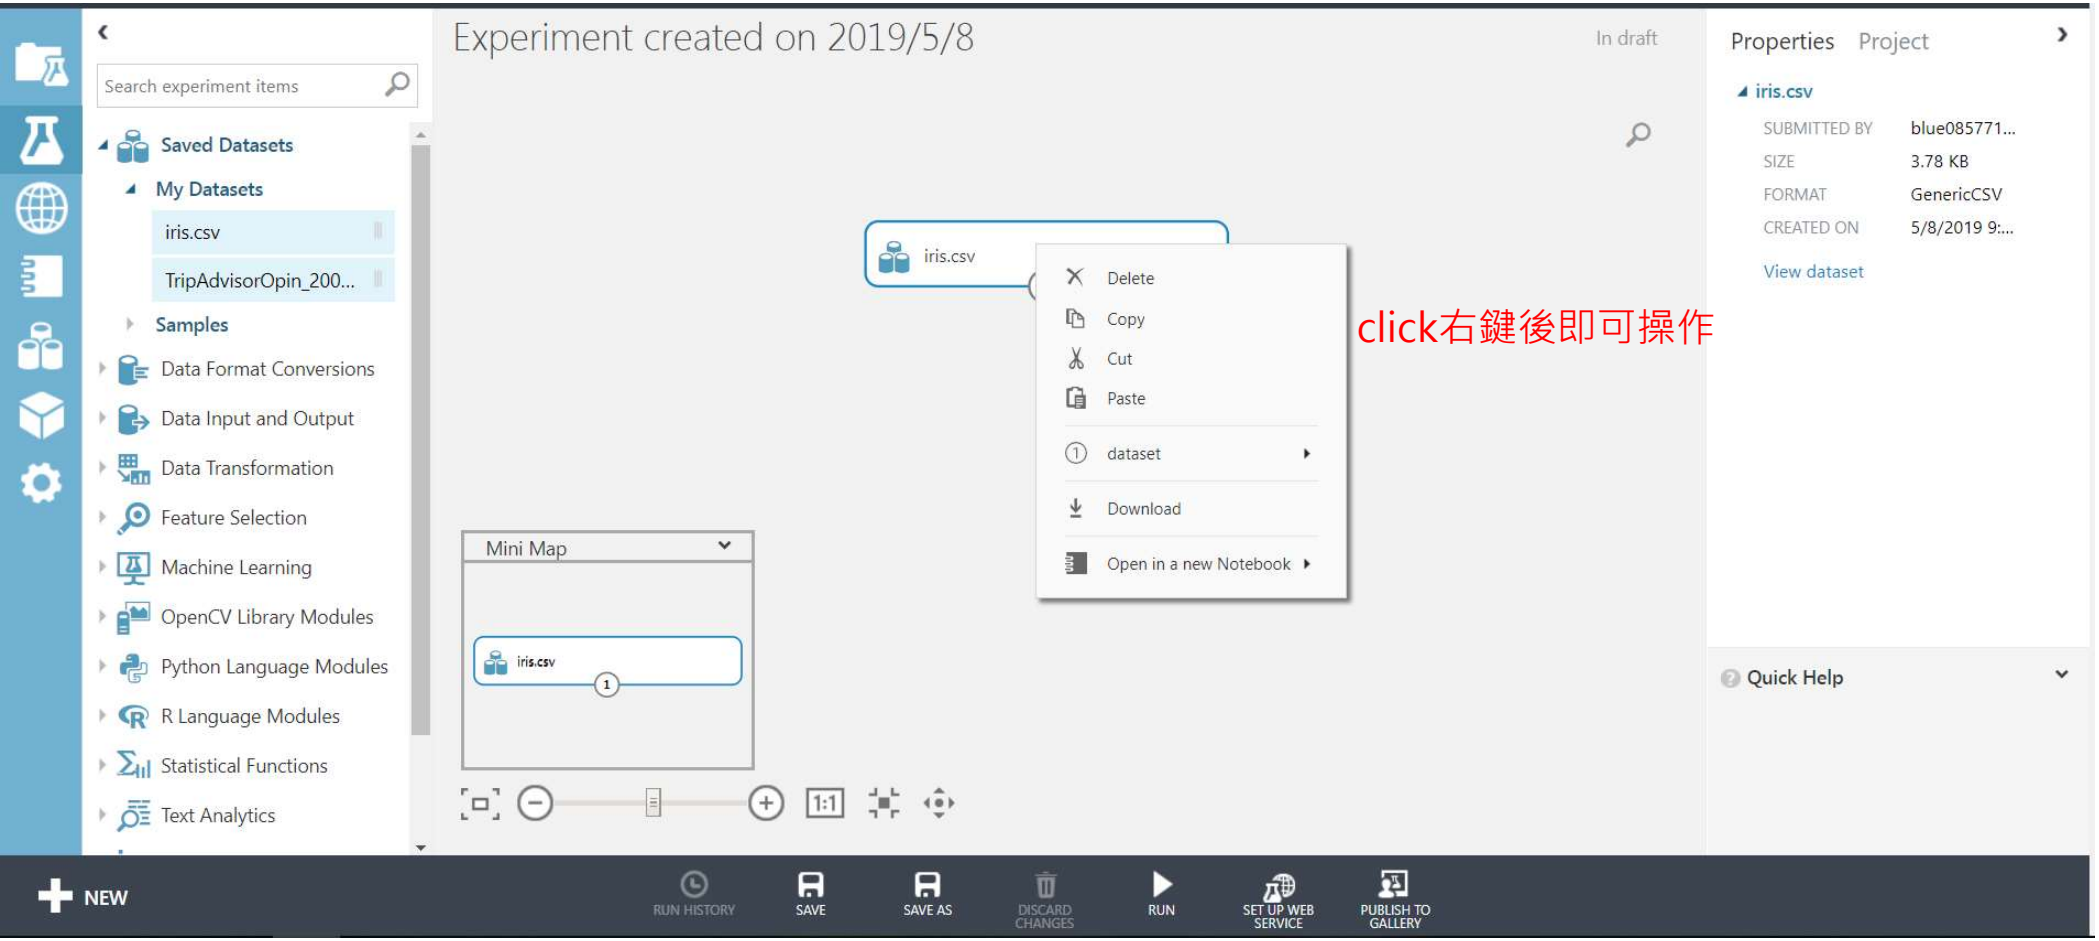

2.Select Columns in Dataset
(選擇欄位/構面)

Azure Machine Learning Studio

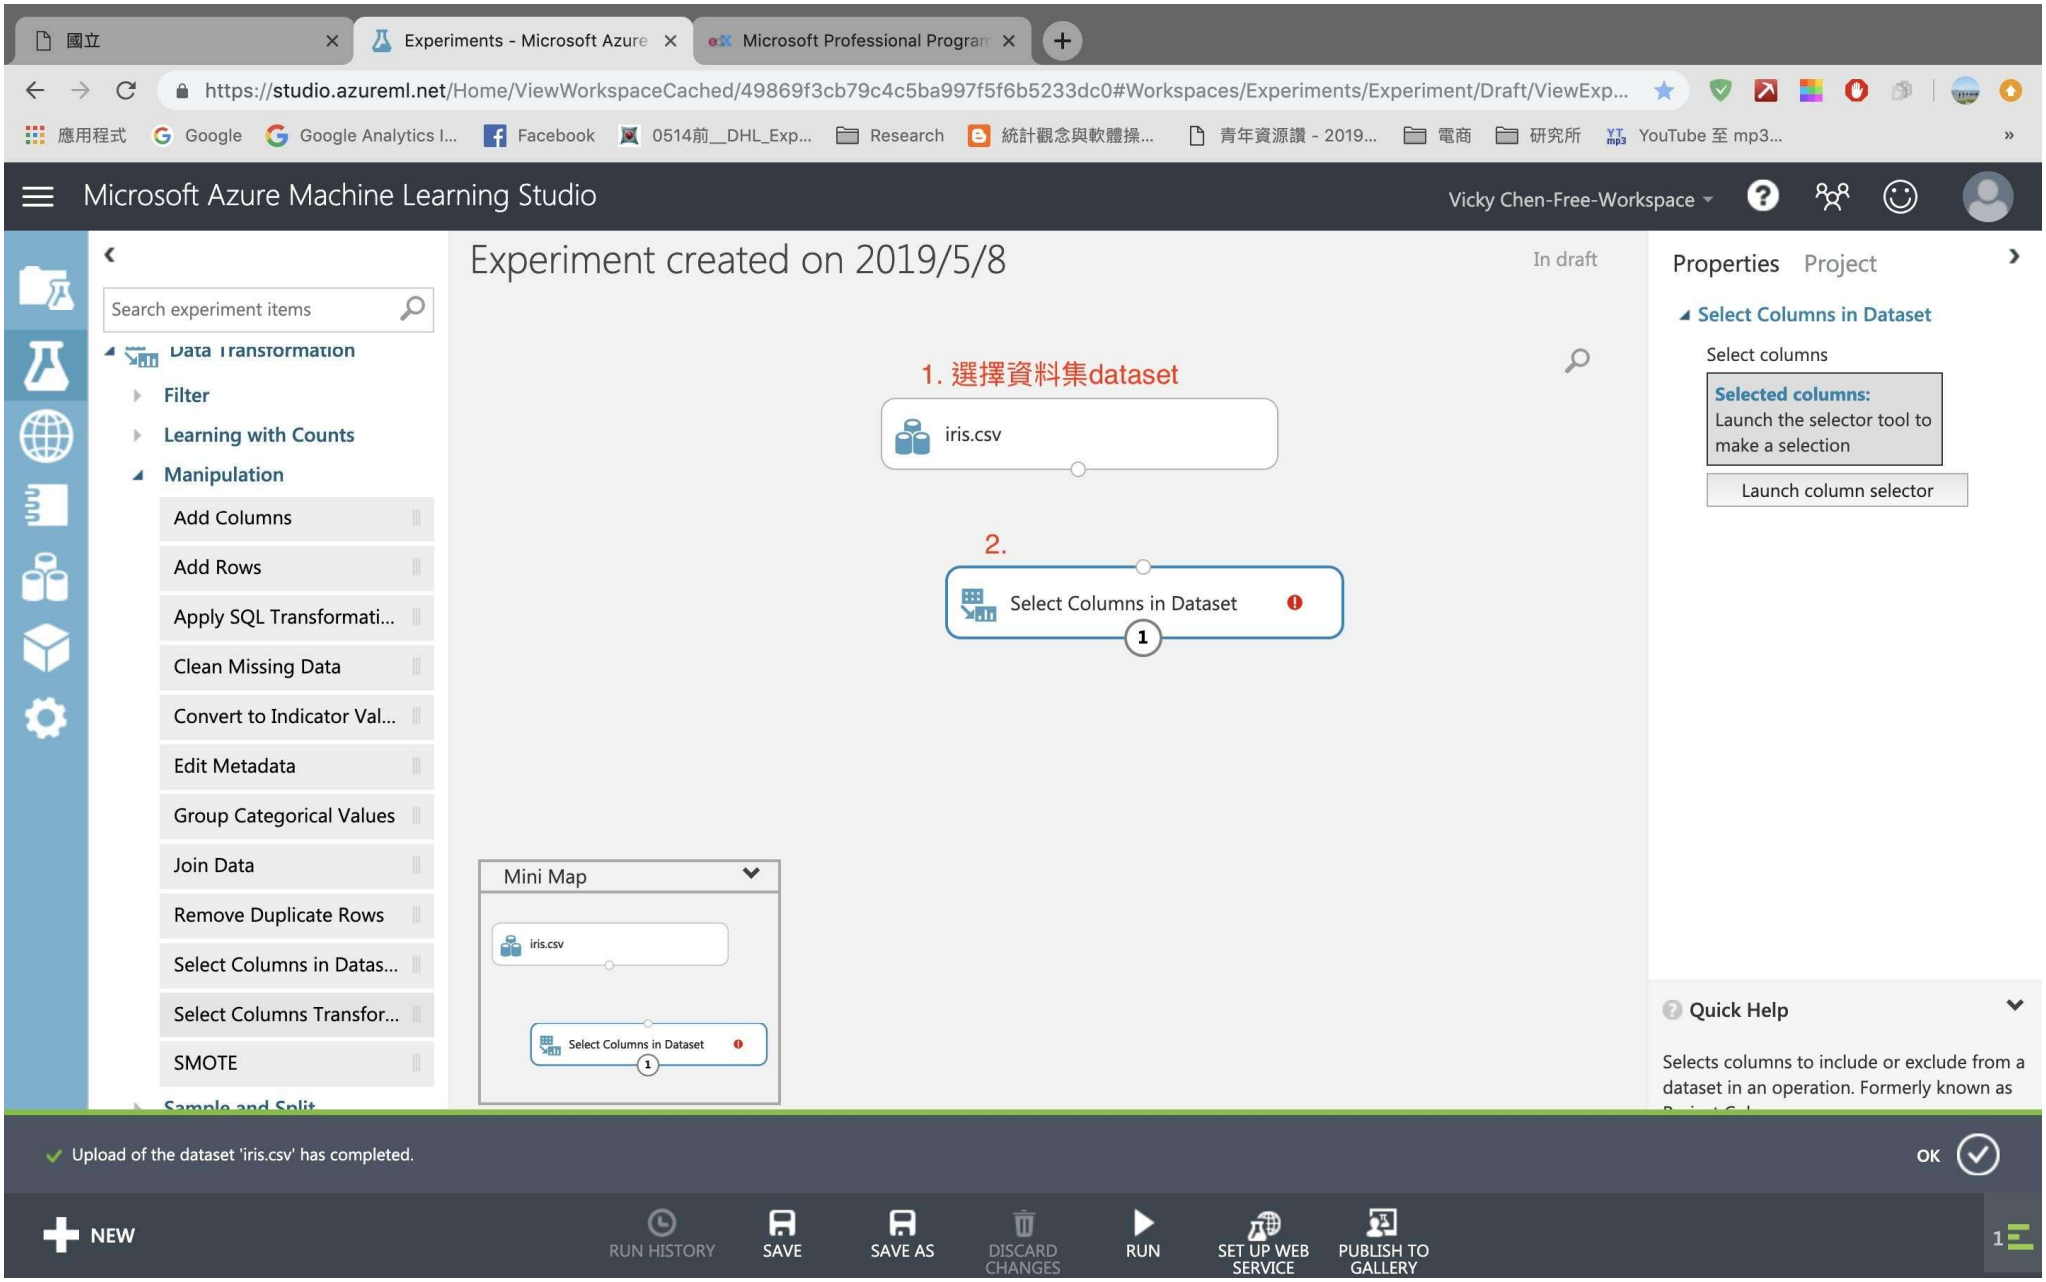

Azure Machine Learning Studio

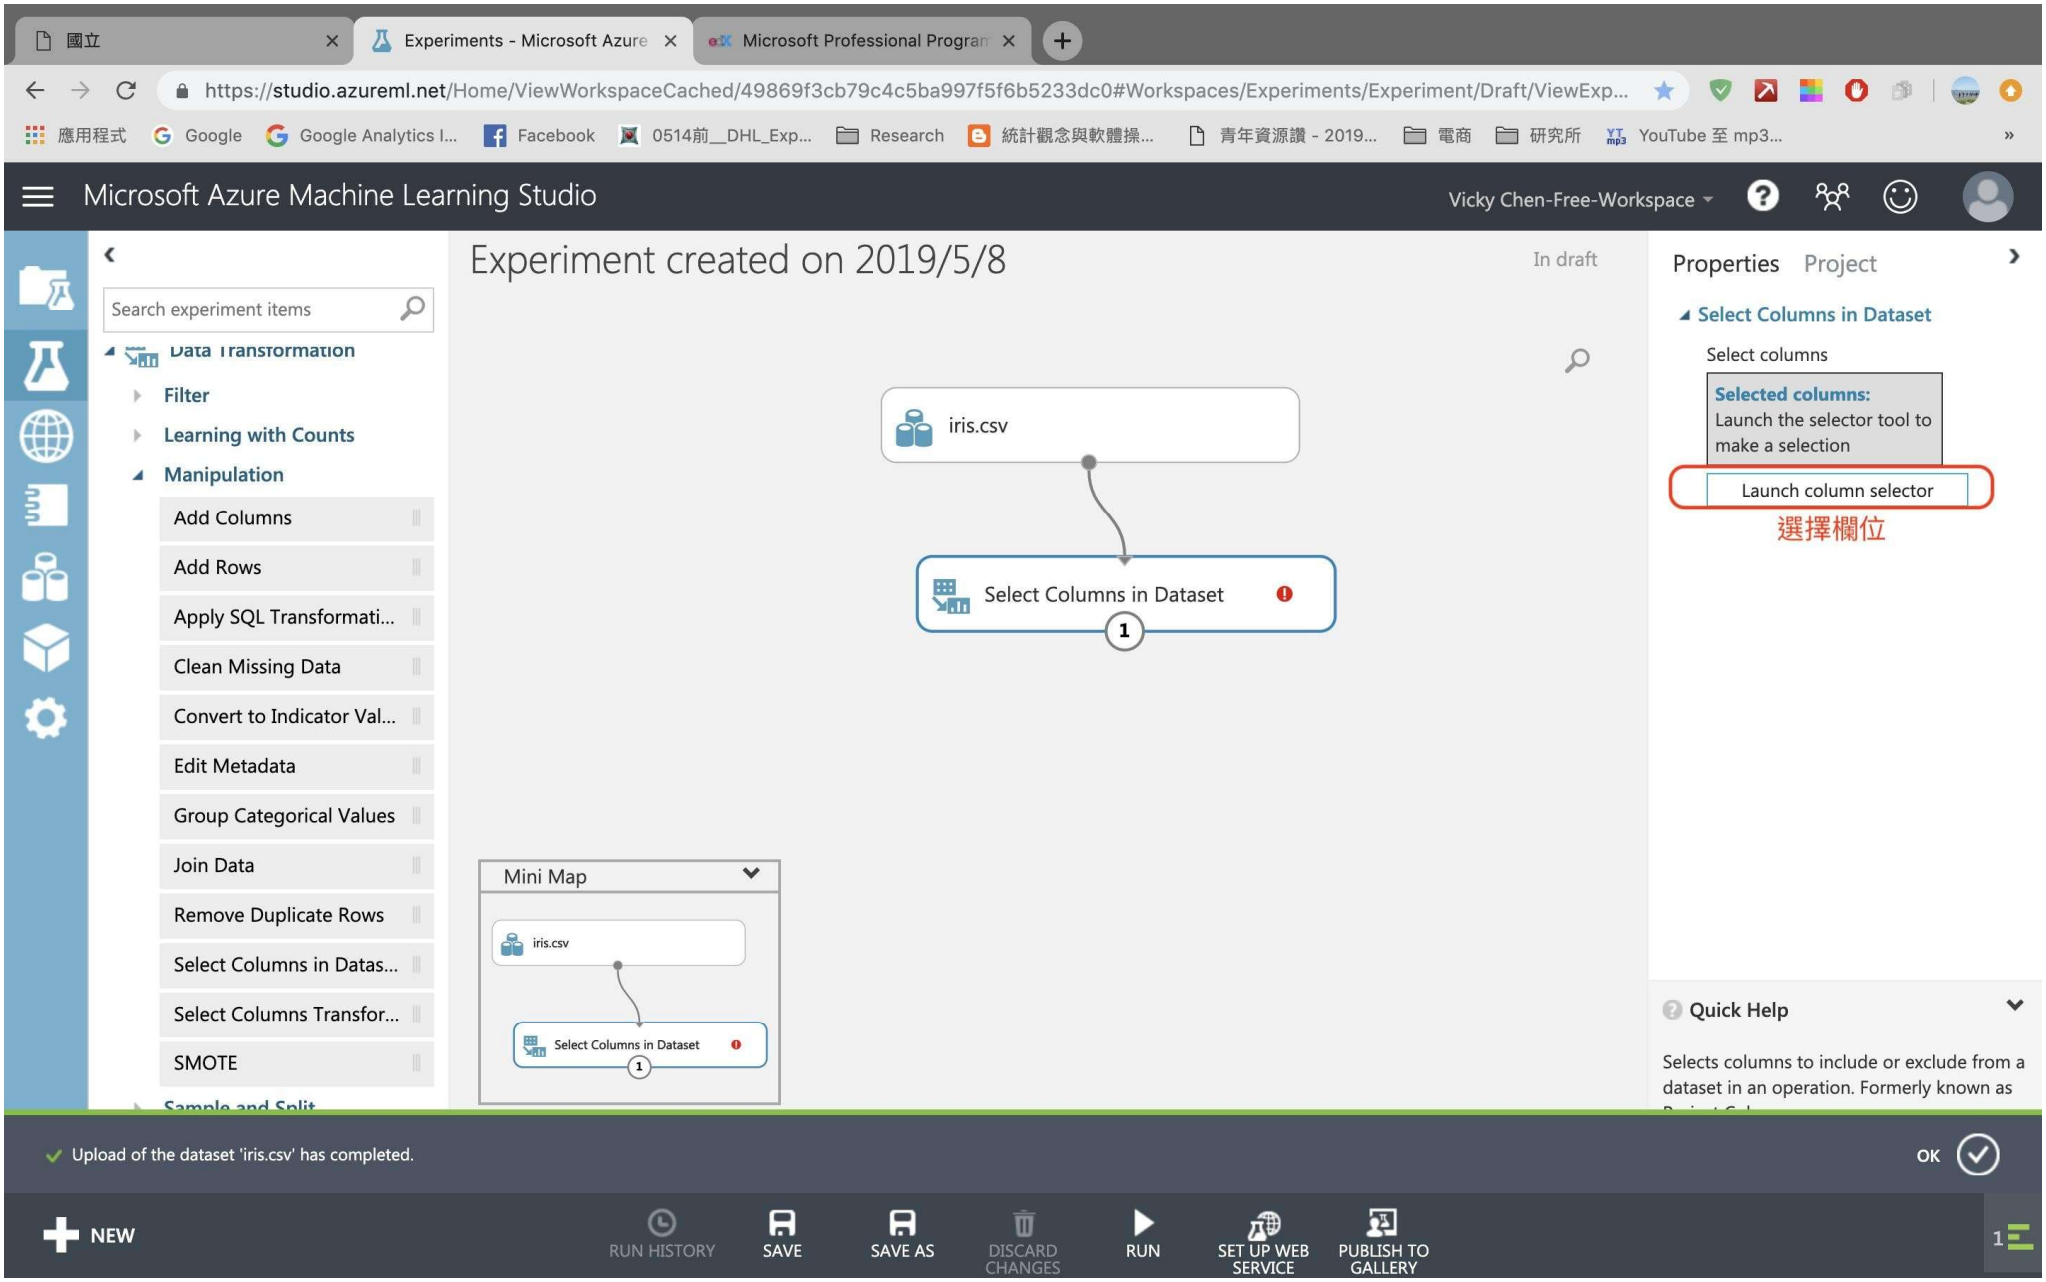

Azure Machine Learning Studio

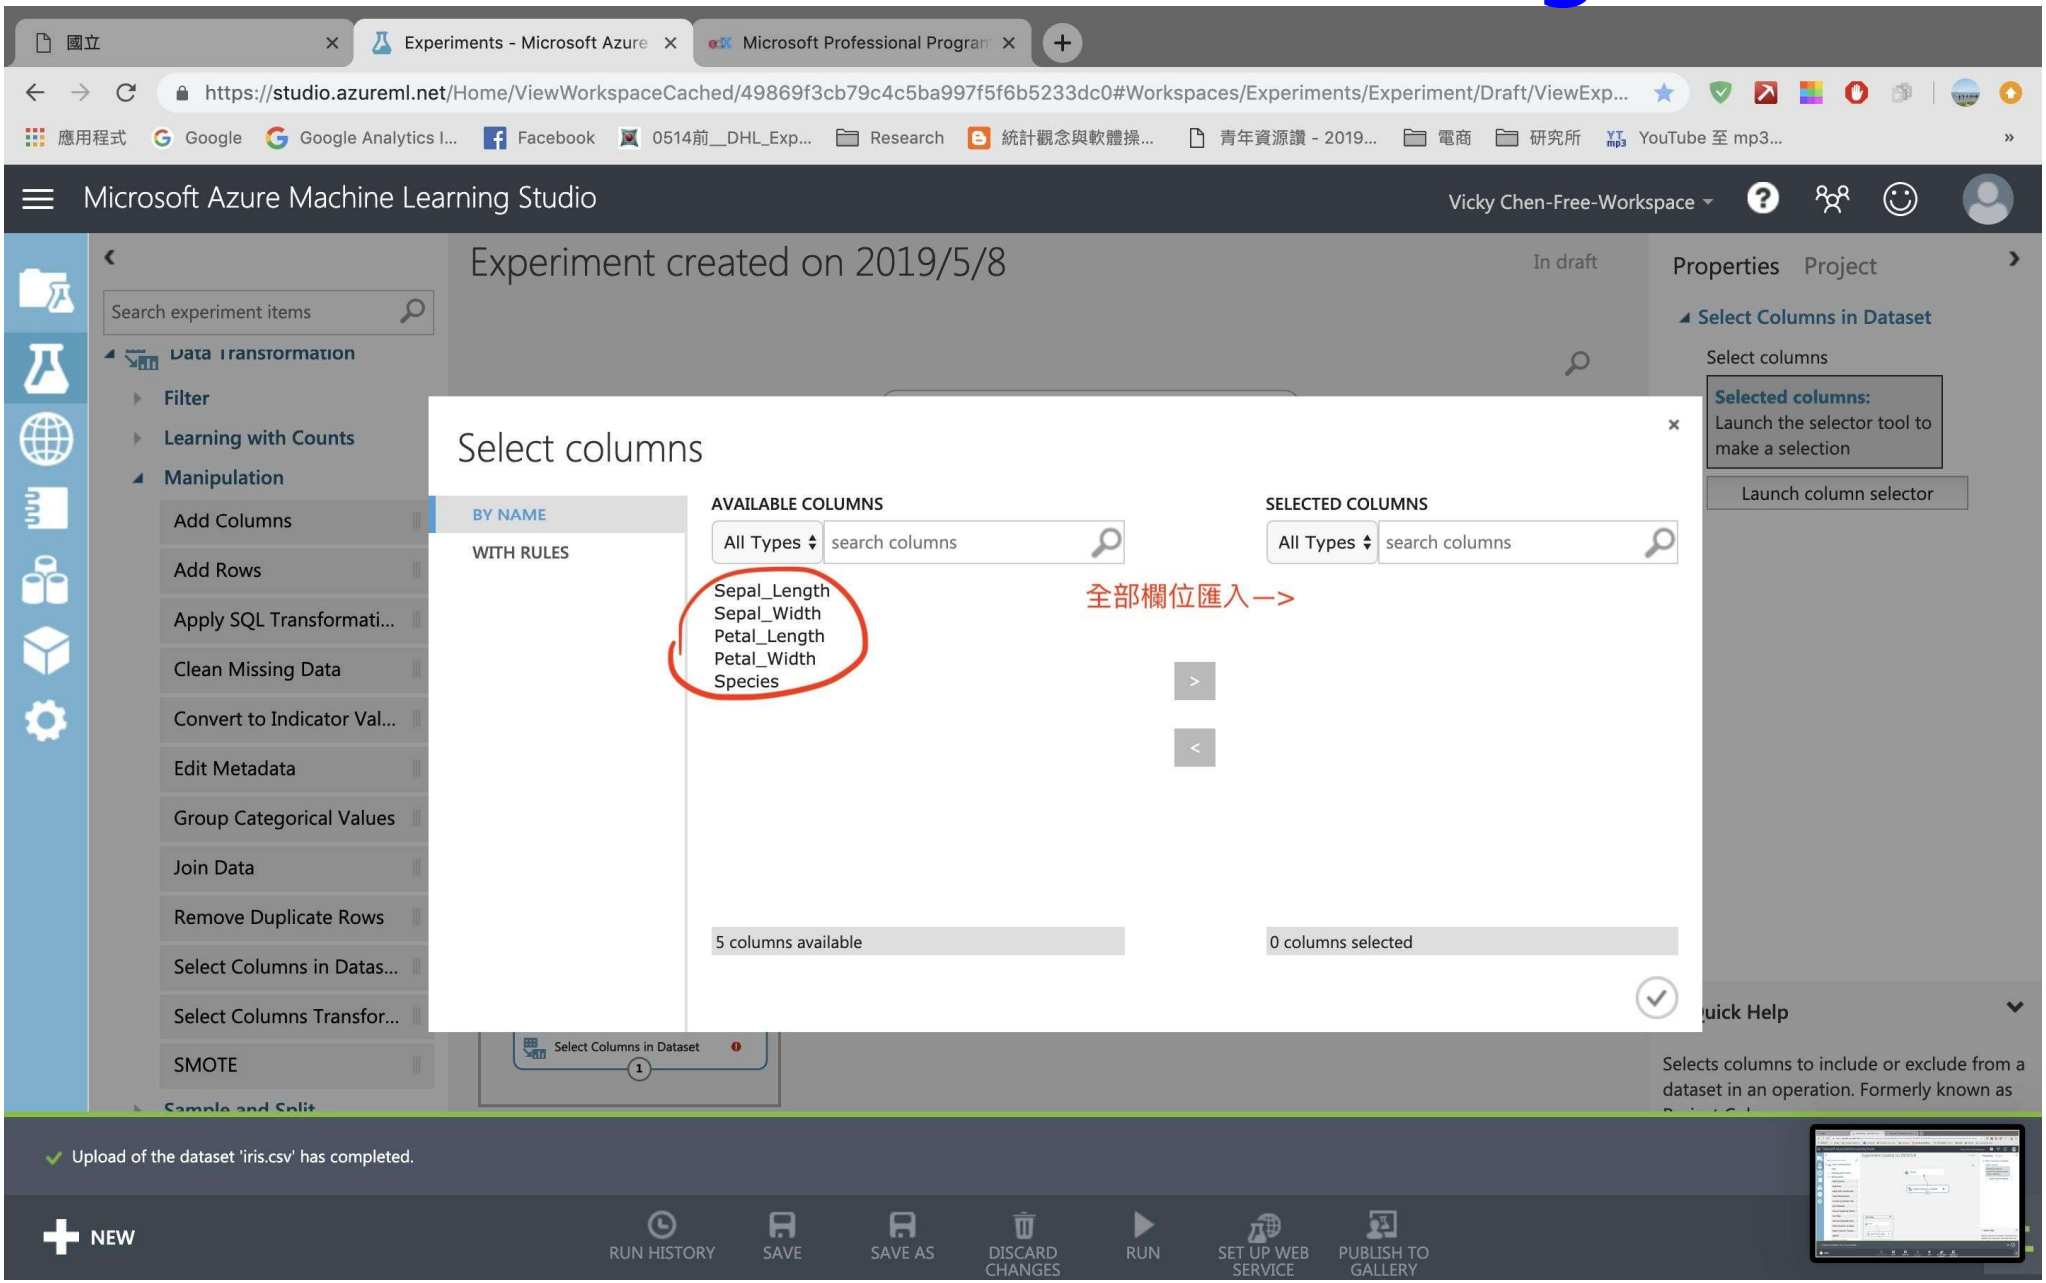

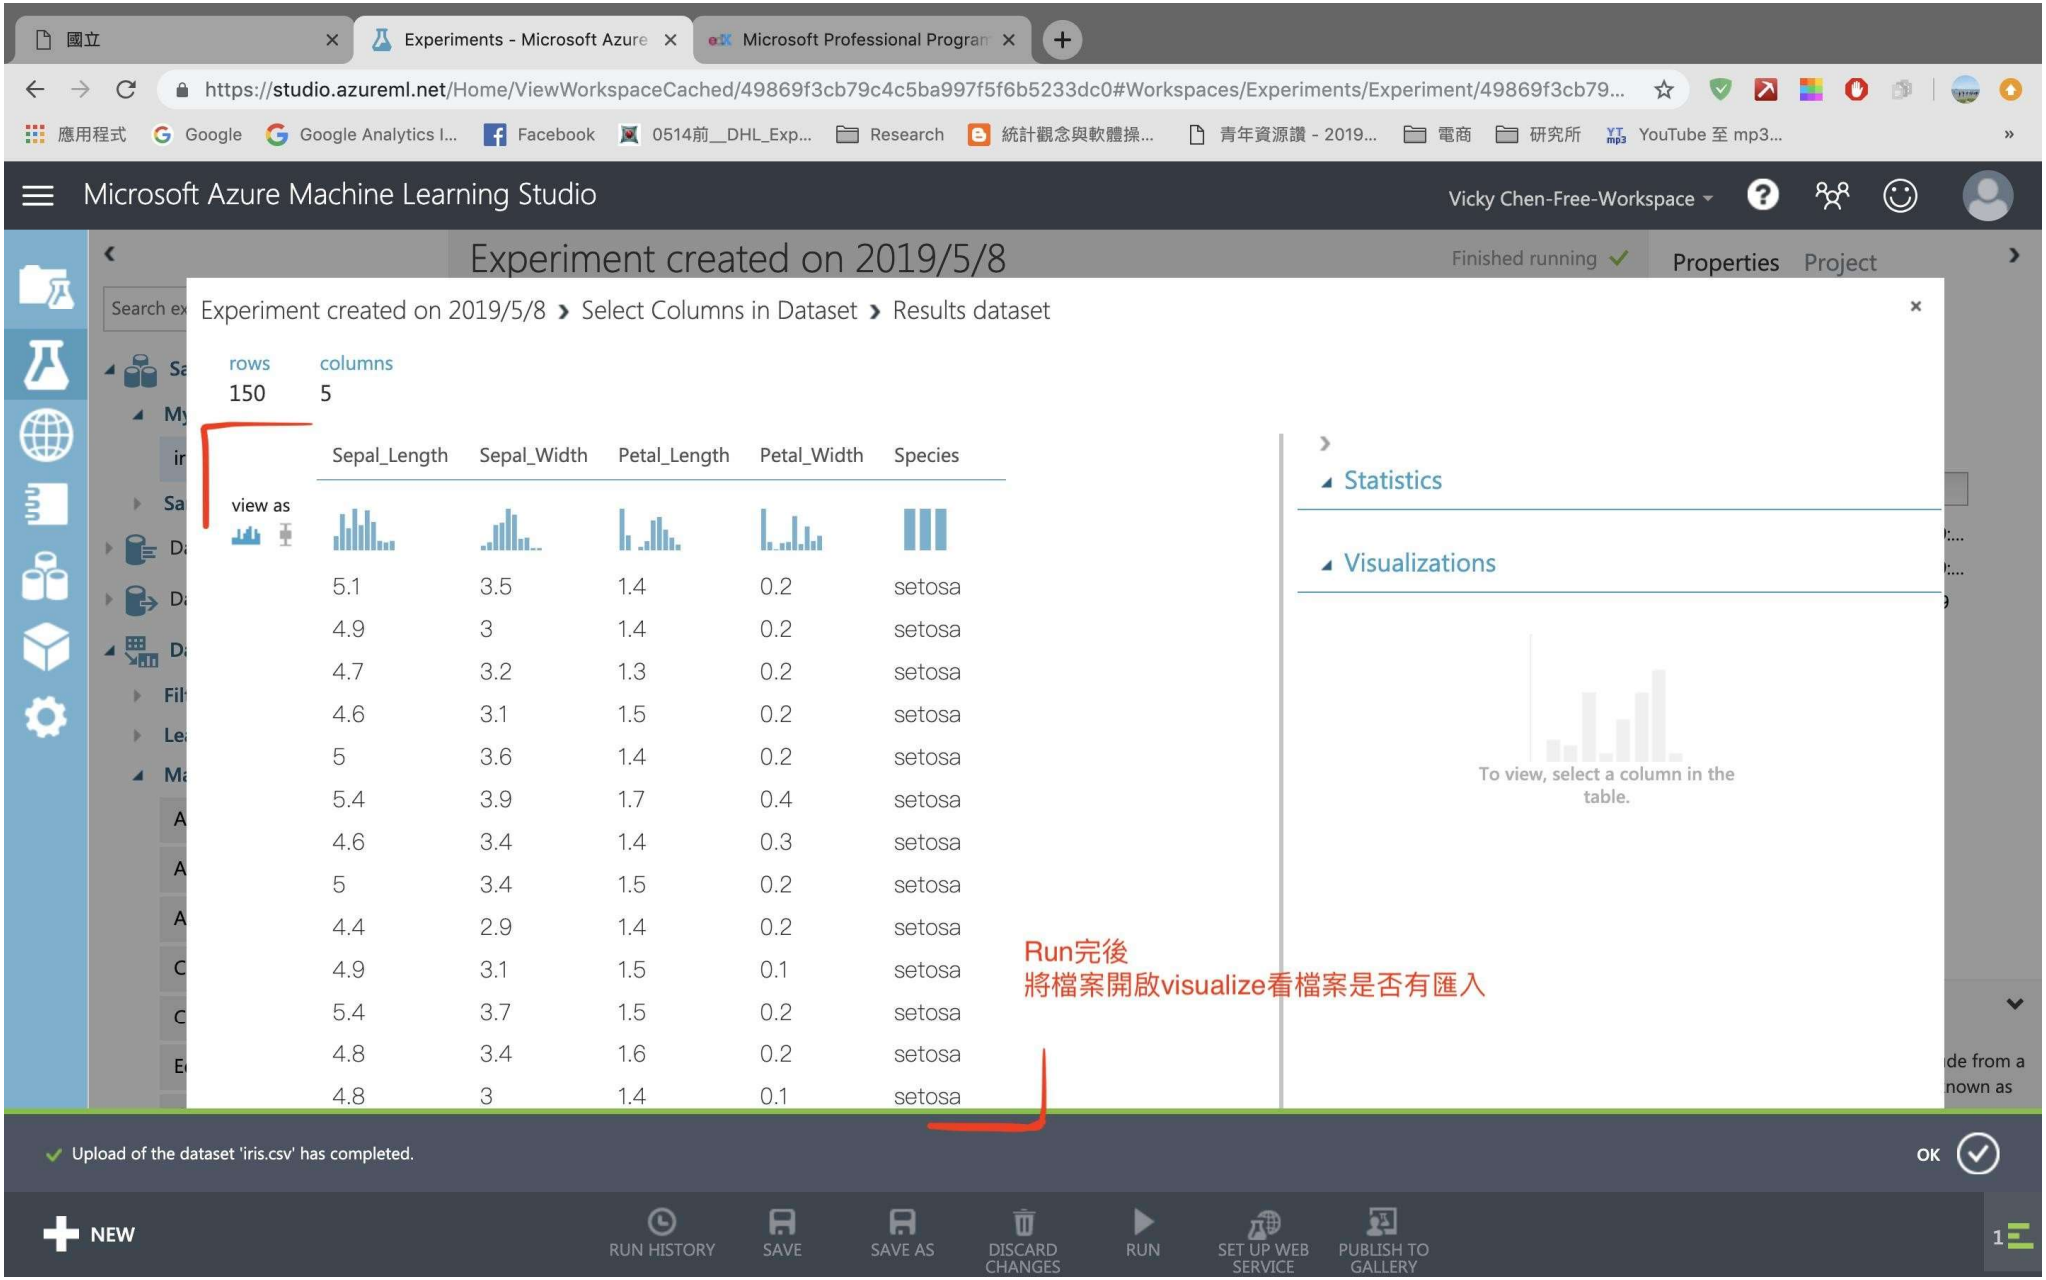
Microsoft Azure Machine Learning Studio
Vicky Chen-Free-Workspace
Experiment created on 2019/5/8
Finished running
Properties
Project
Experiment created on 2019/5/8 › Select Columns in Dataset › Results dataset
rows
150
columns
5
view as
Sepal_Length Sepal_Width Petal_Length Petal_Width Species
5.1 3.5 1.4 0.2 setosa
4.9 3 1.4 0.2 setosa
4.7 3.2 1.3 0.2 setosa
4.6 3.1 1.5 0.2 setosa
5 3.6 1.4 0.2 setosa
5.4 3.9 1.7 0.4 setosa
4.6 3.4 1.4 0.3 setosa
5 3.4 1.5 0.2 setosa
4.4 2.9 1.4 0.2 setosa
4.9 3.1 1.5 0.1 setosa
5.4 3.7 1.5 0.2 setosa
4.8 3.4 1.6 0.2 setosa
4.8 3 1.4 0.1 setosa
Statistics
Visualizations
To view, select a column in the table.
Run完後
將檔案開啟visualize看檔案是否有匯入
Upload of the dataset 'iris.csv' has completed.
OK
NEW
RUN HISTORY
SAVE
SAVE AS
DISCARD CHANGES
RUN
SET UP WEB SERVICE
PUBLISH TO GALLERY

#3.APPLY SQL transformation

4.Split data（將檔案分割）

Azure Machine Learning Studio

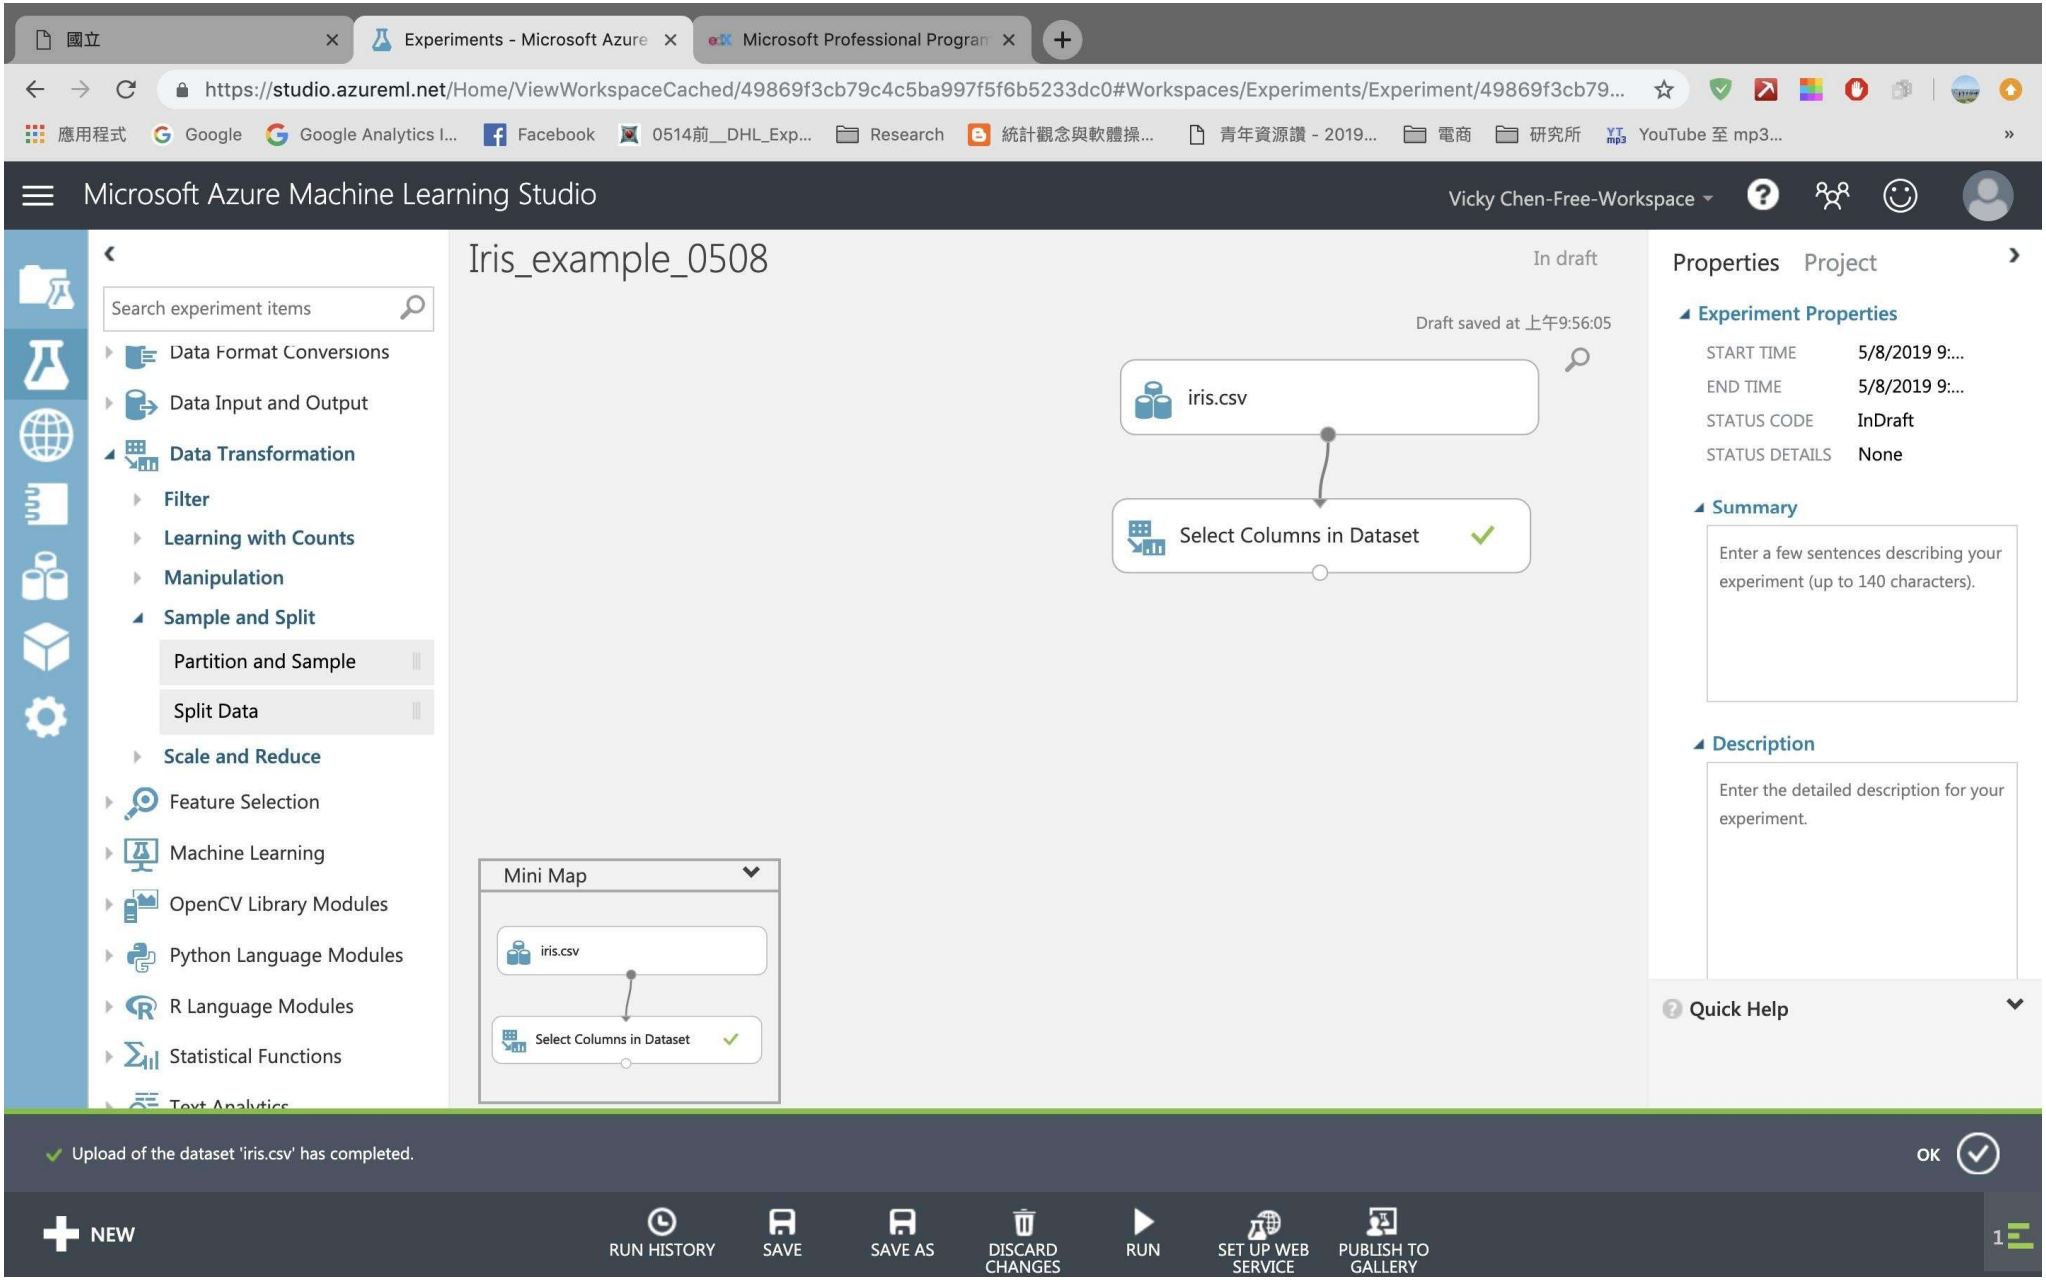

Azure Machine Learning Studio

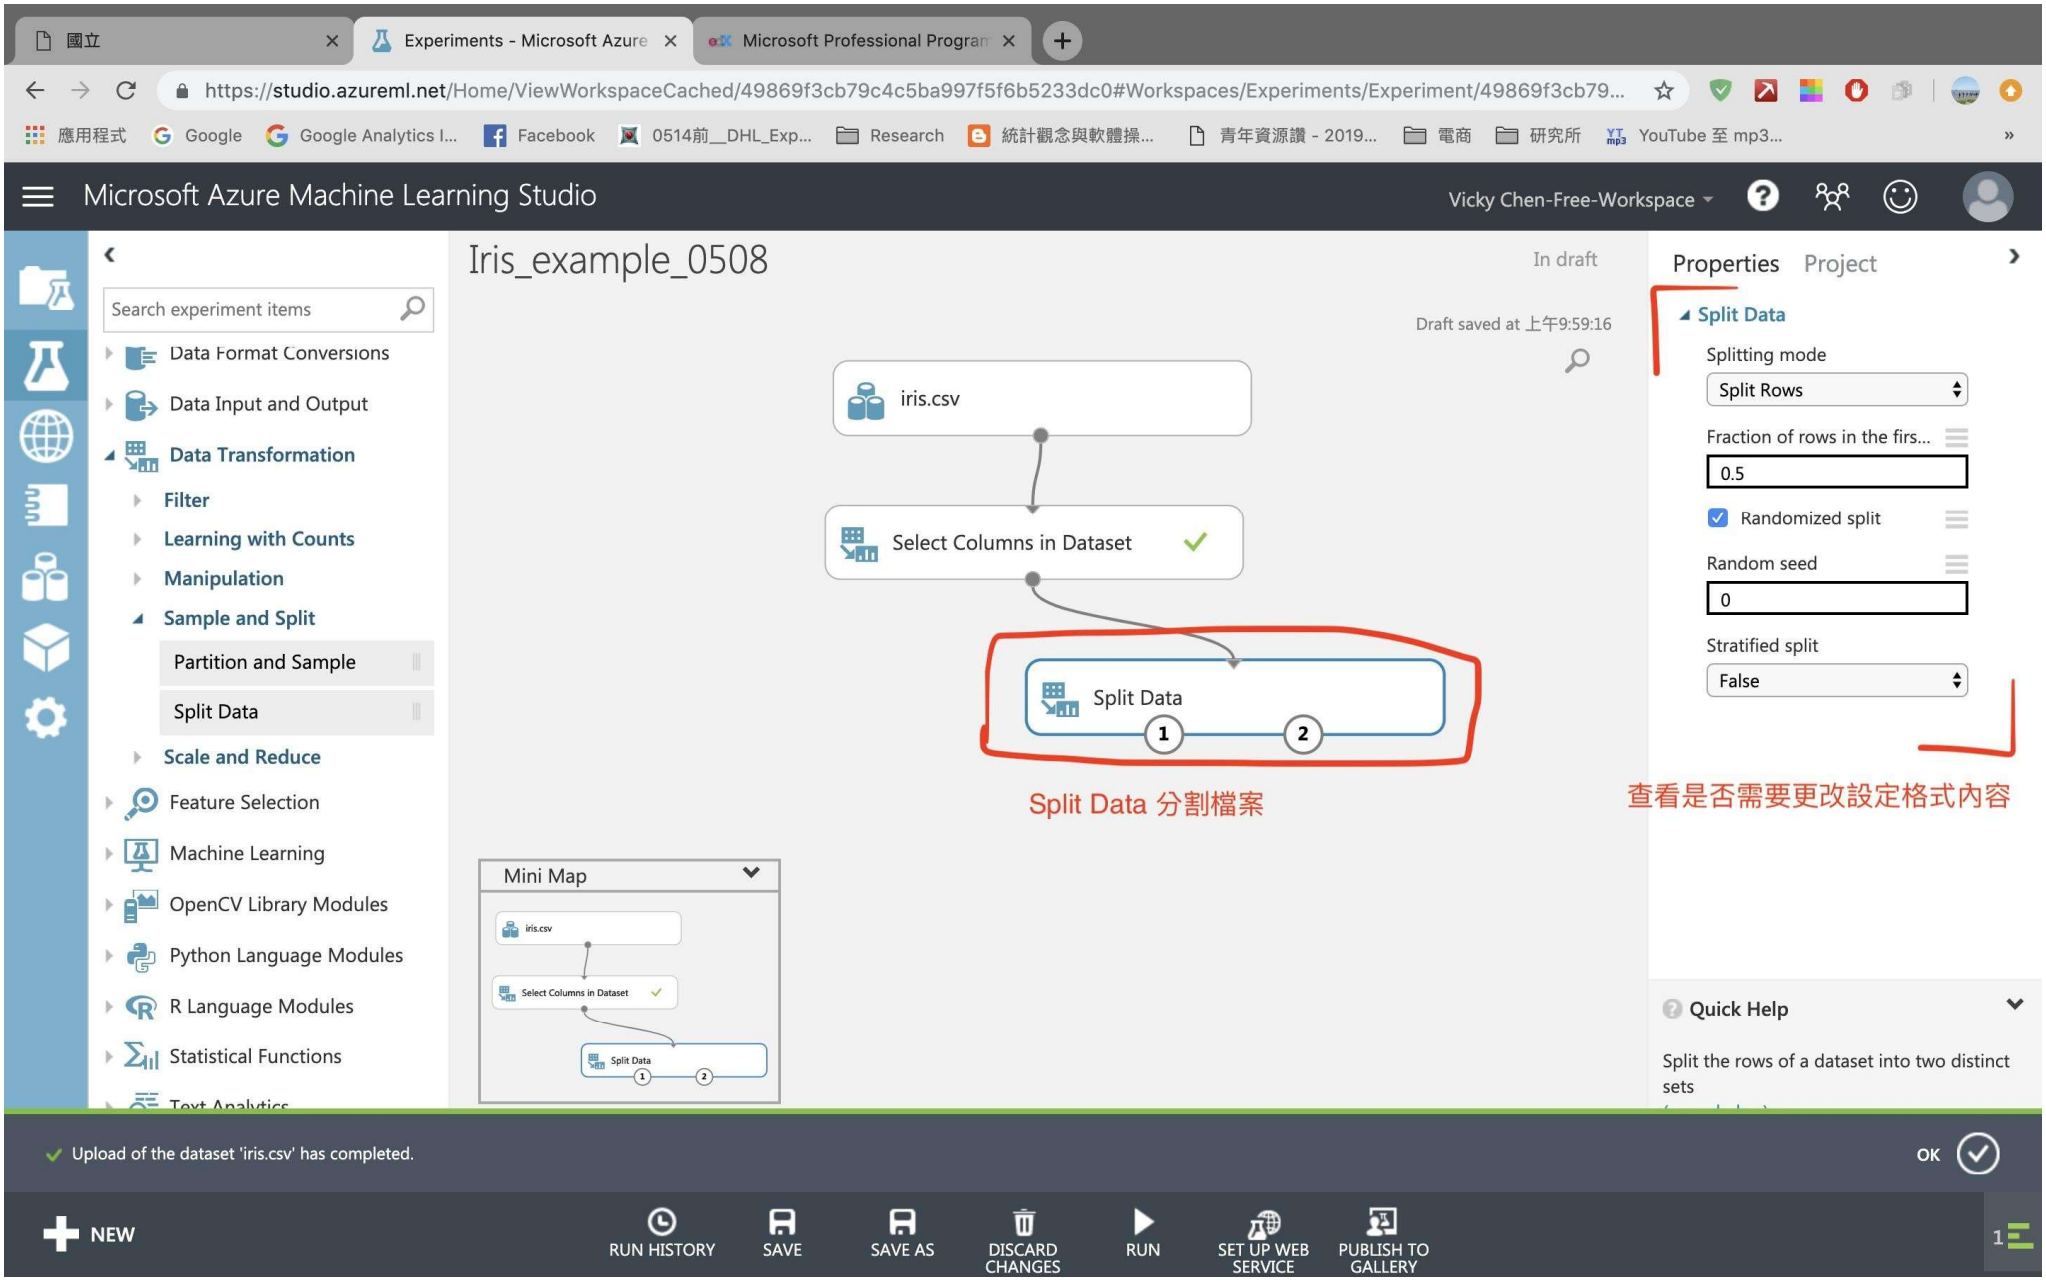

Azure Machine Learning Studio

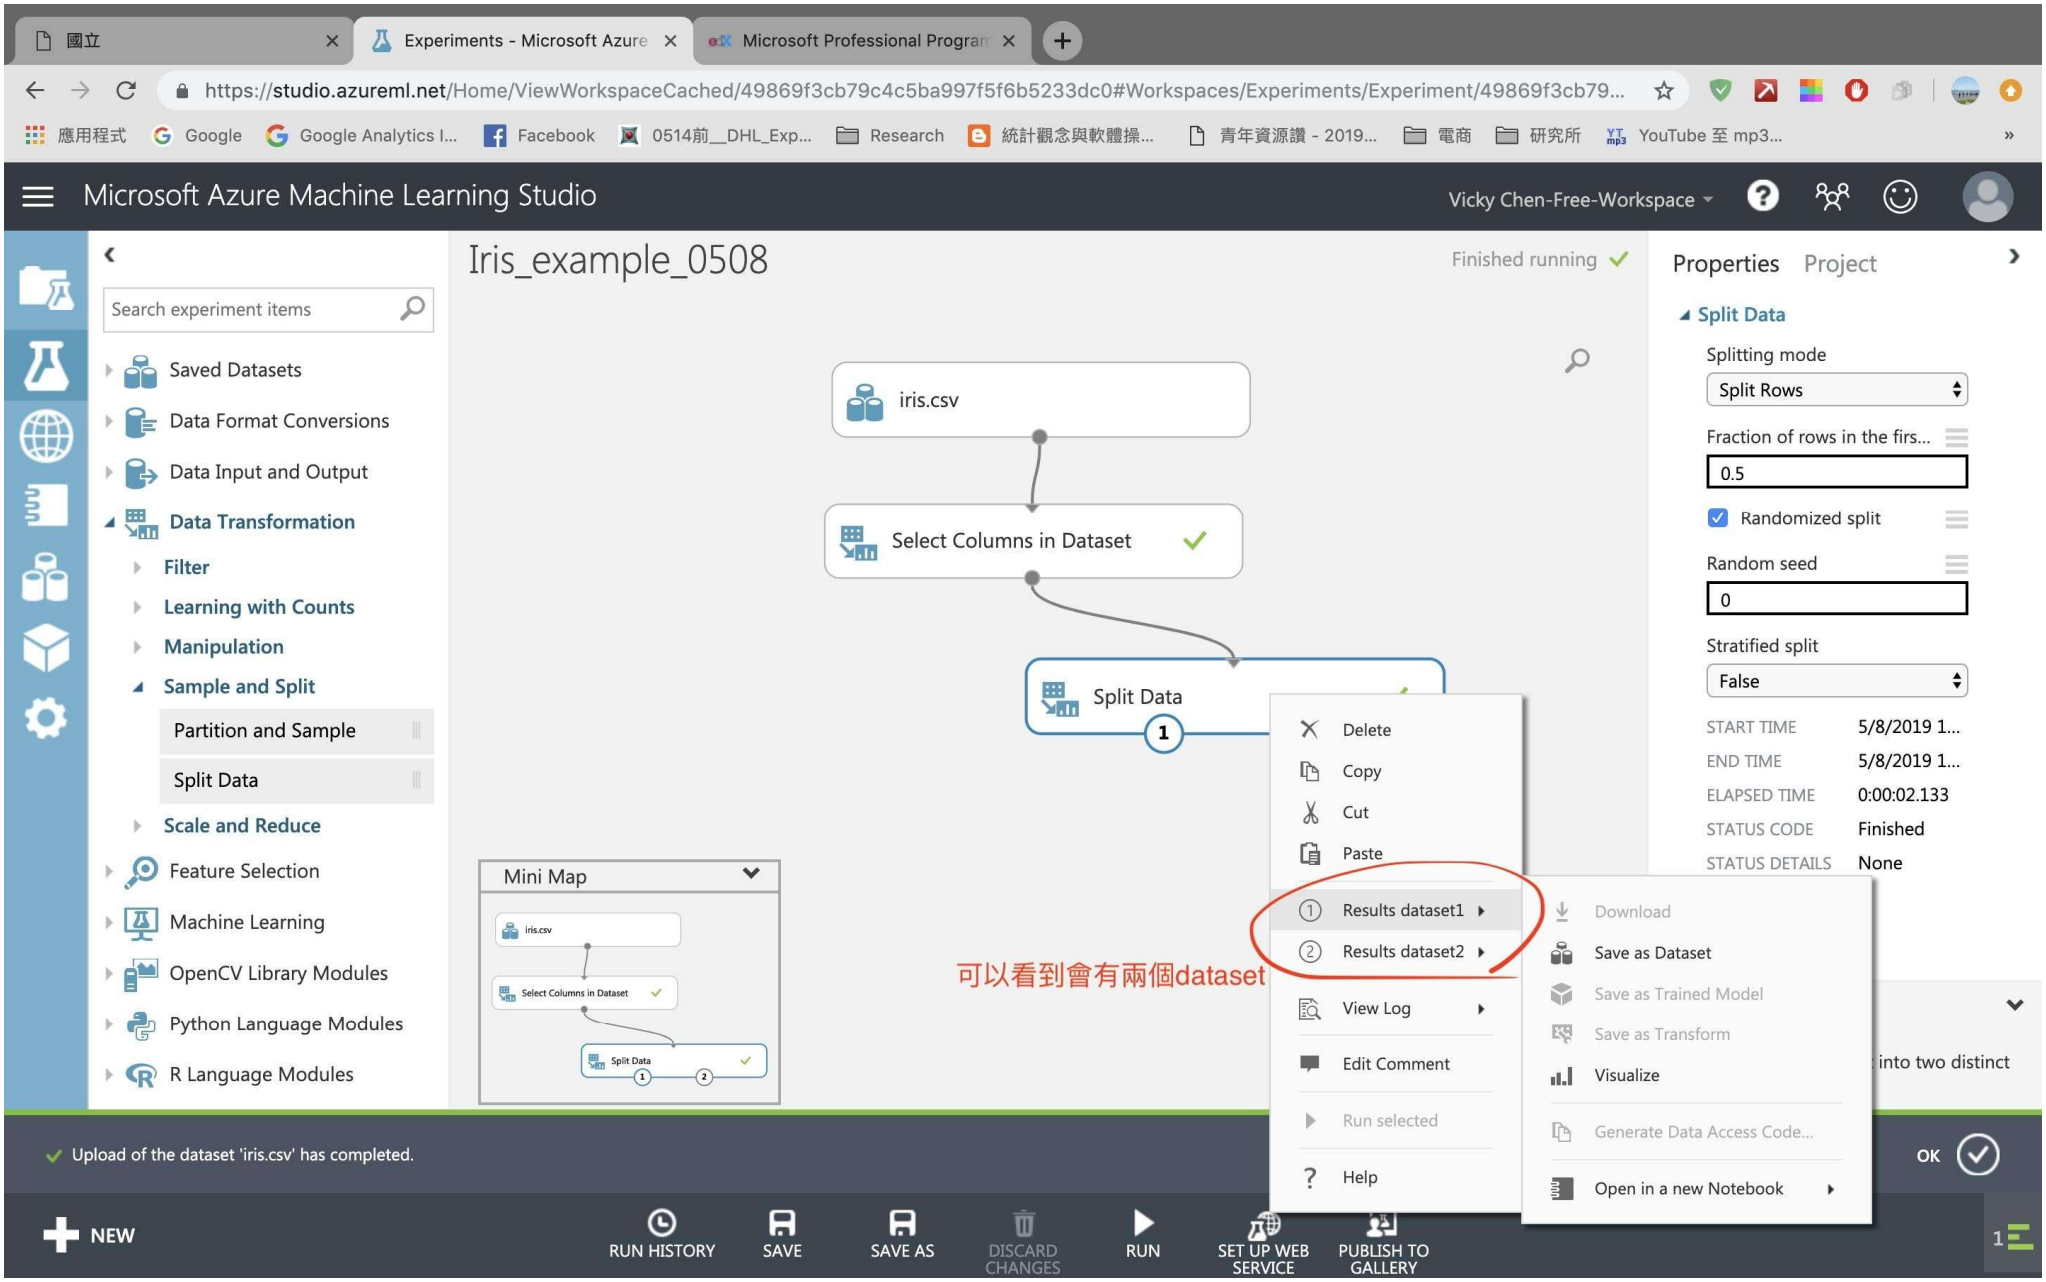

Azure Machine Learning Studio

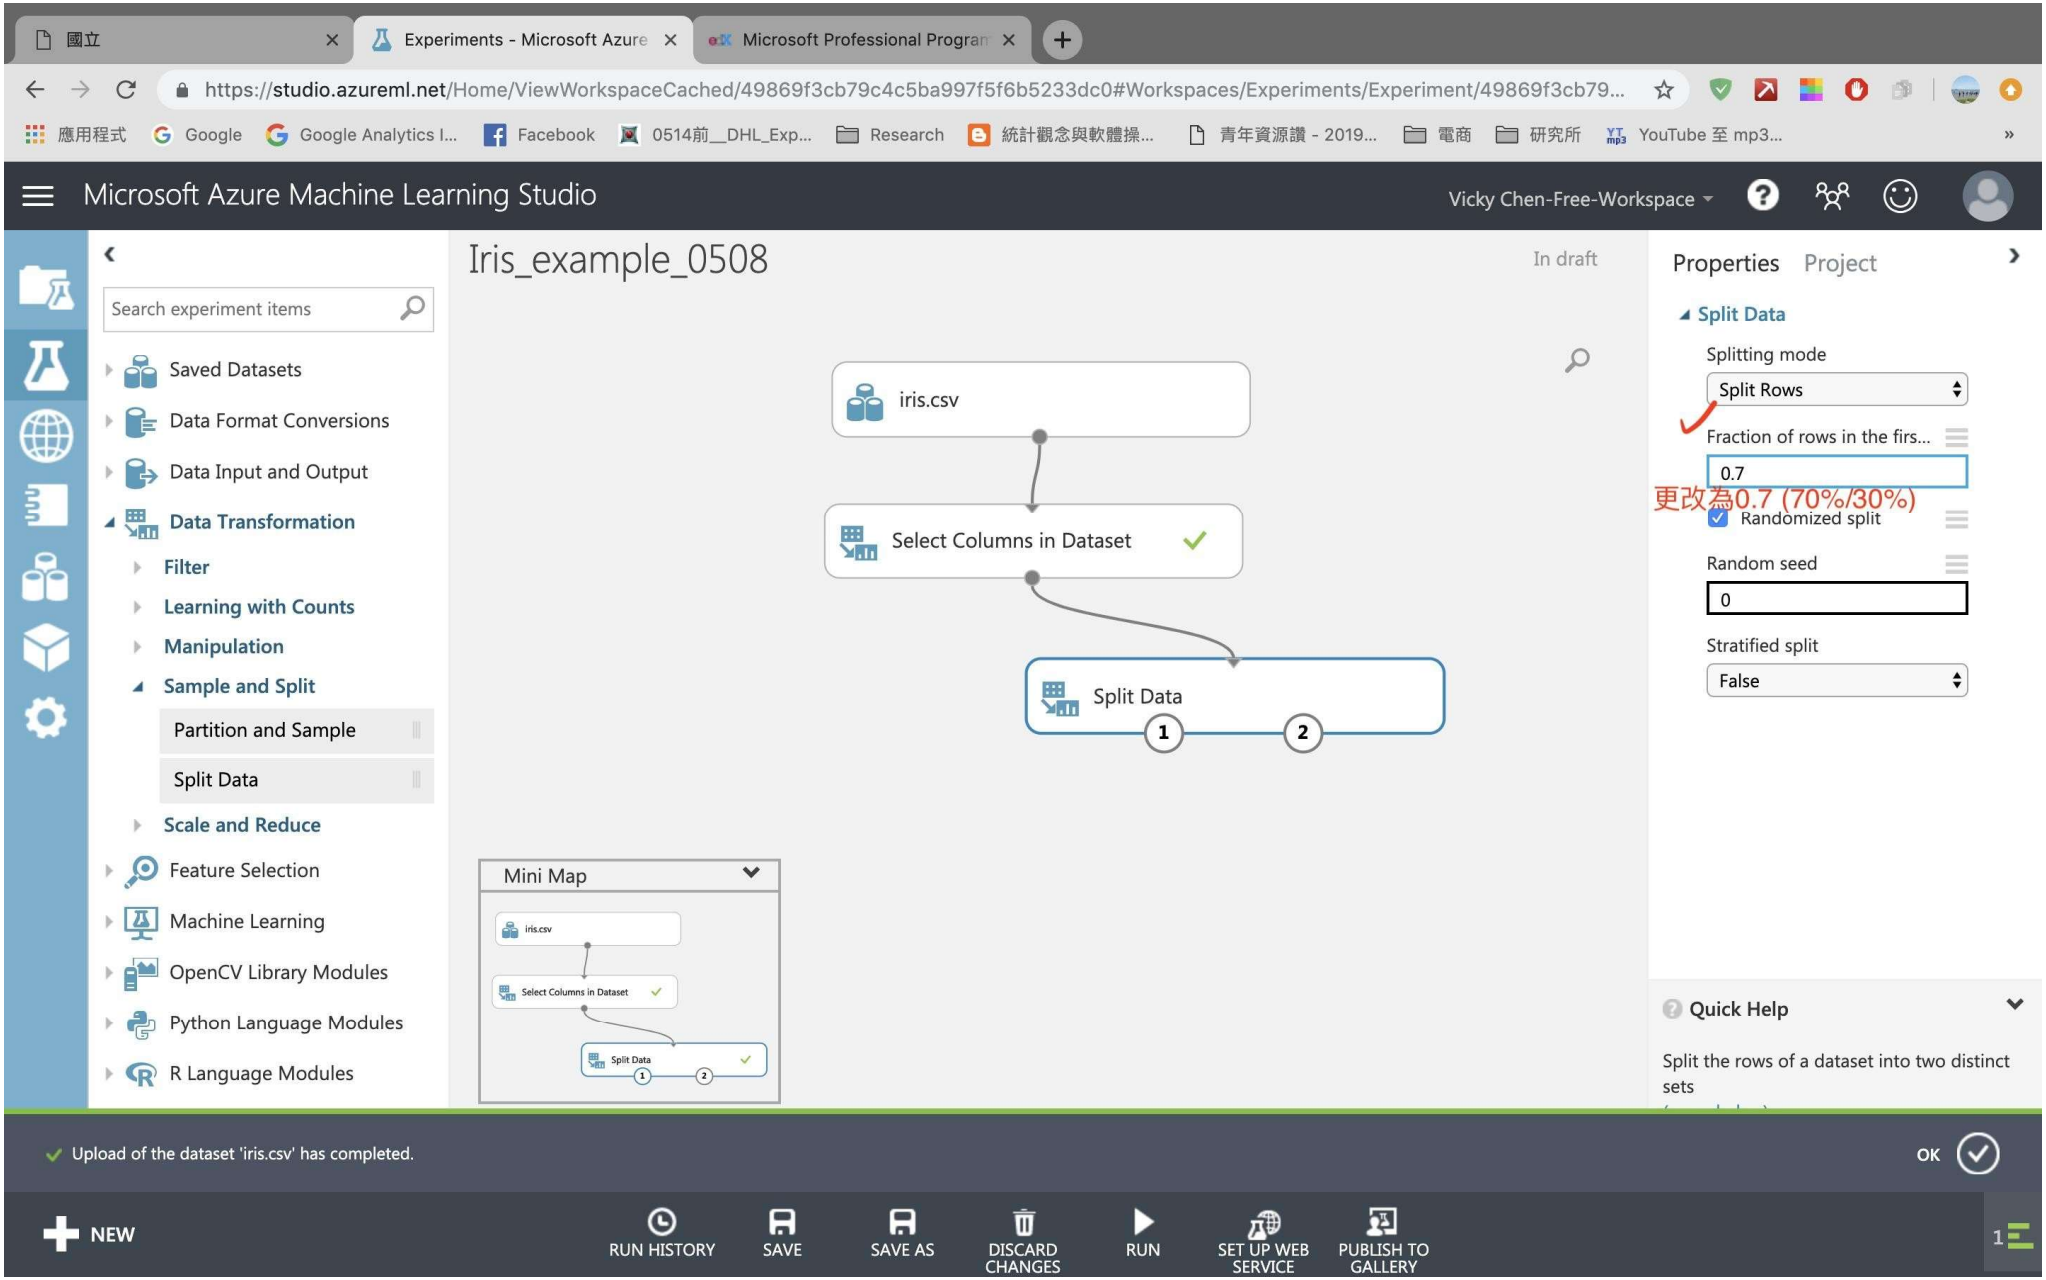

5. 選擇機器學習演算法(Initial Model)
Multiclass Neural Network

Azure Machine Learning Studio

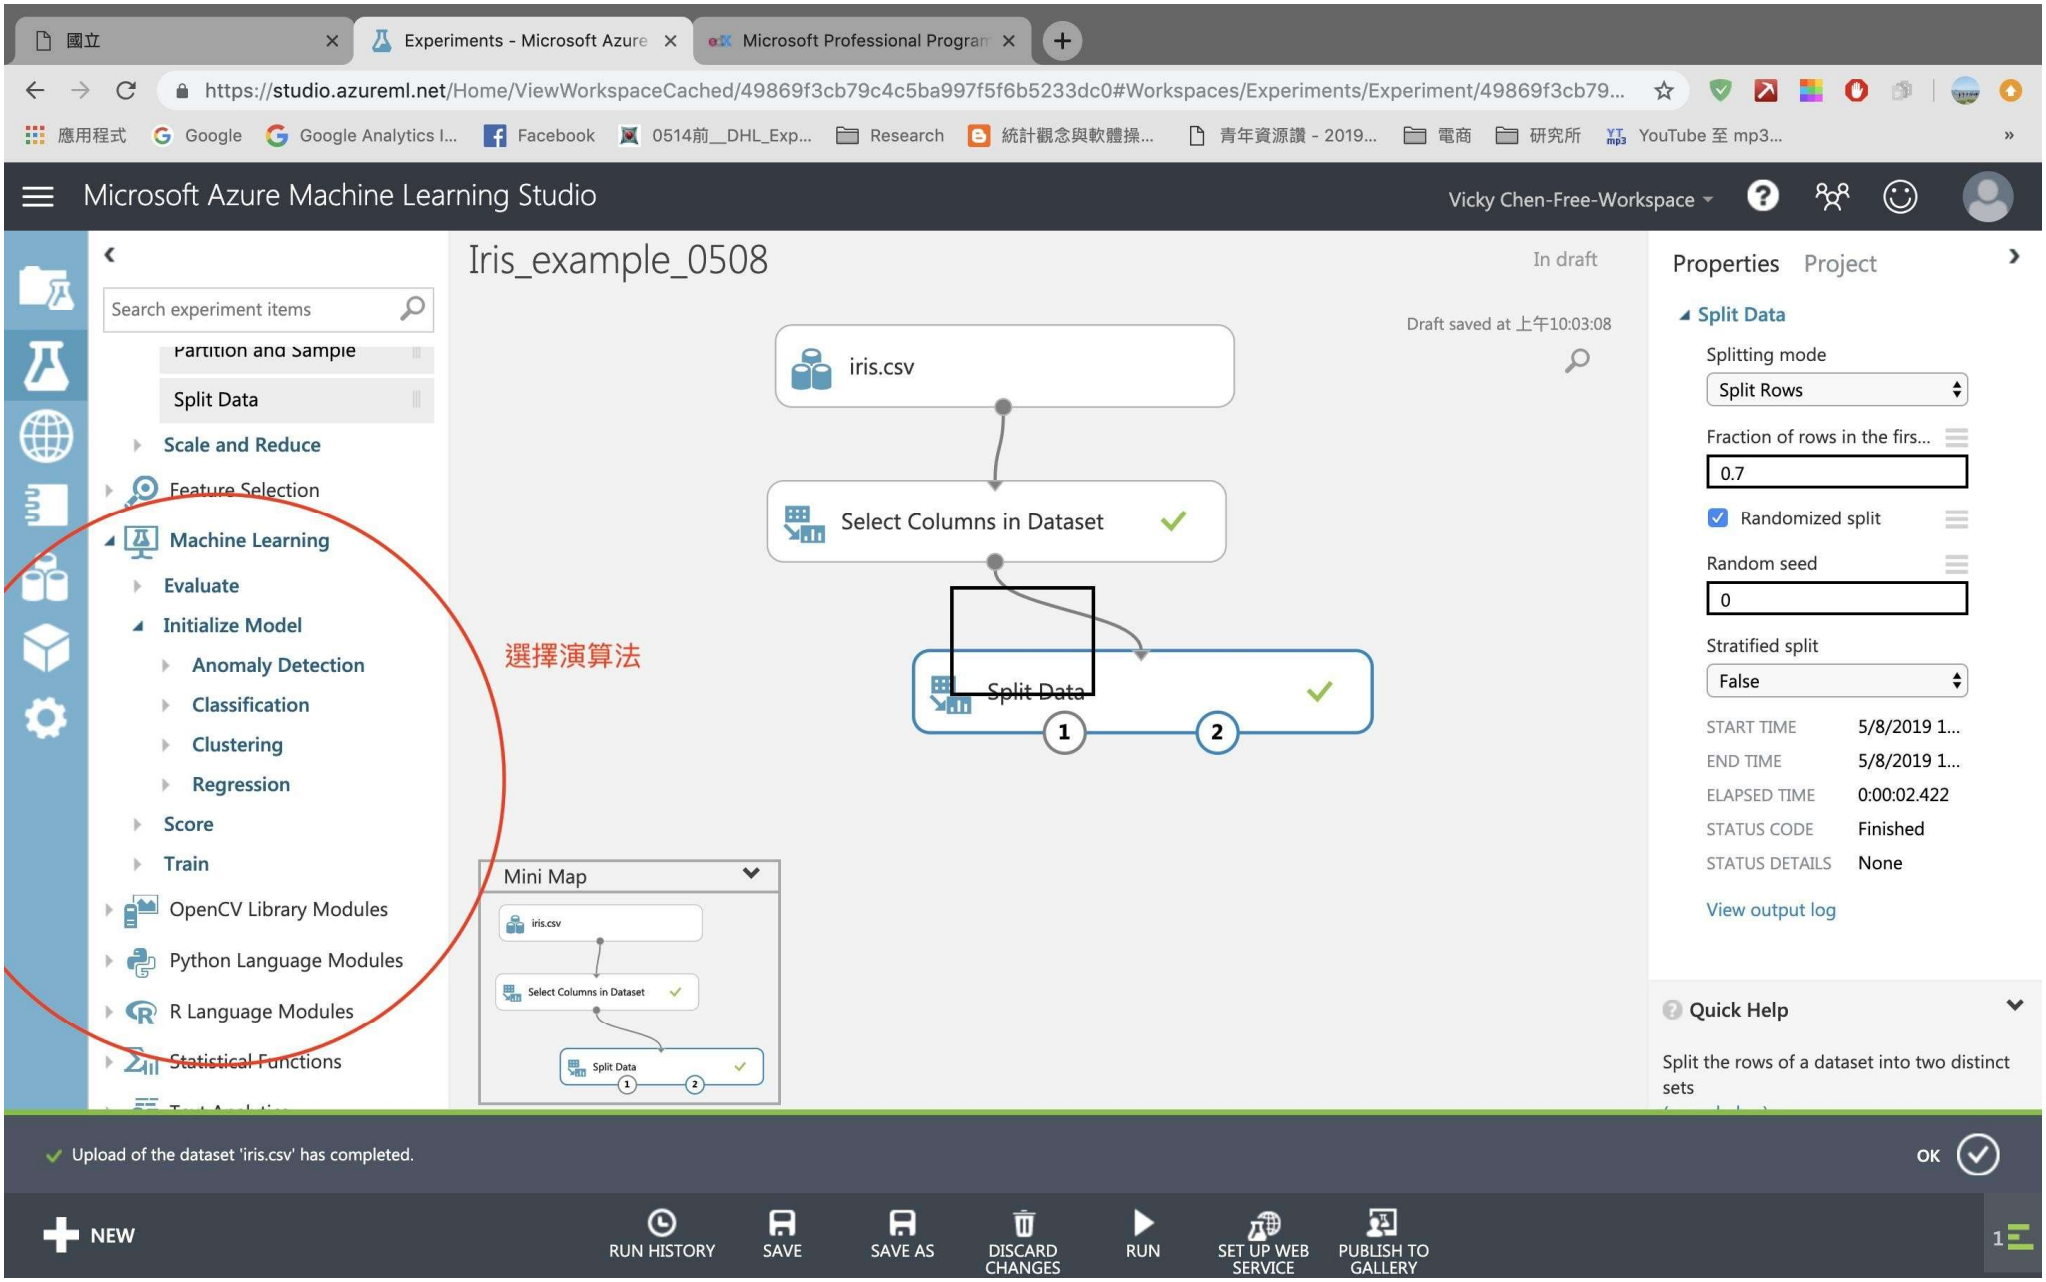

6.Train Model

Azure Machine Learning Studio

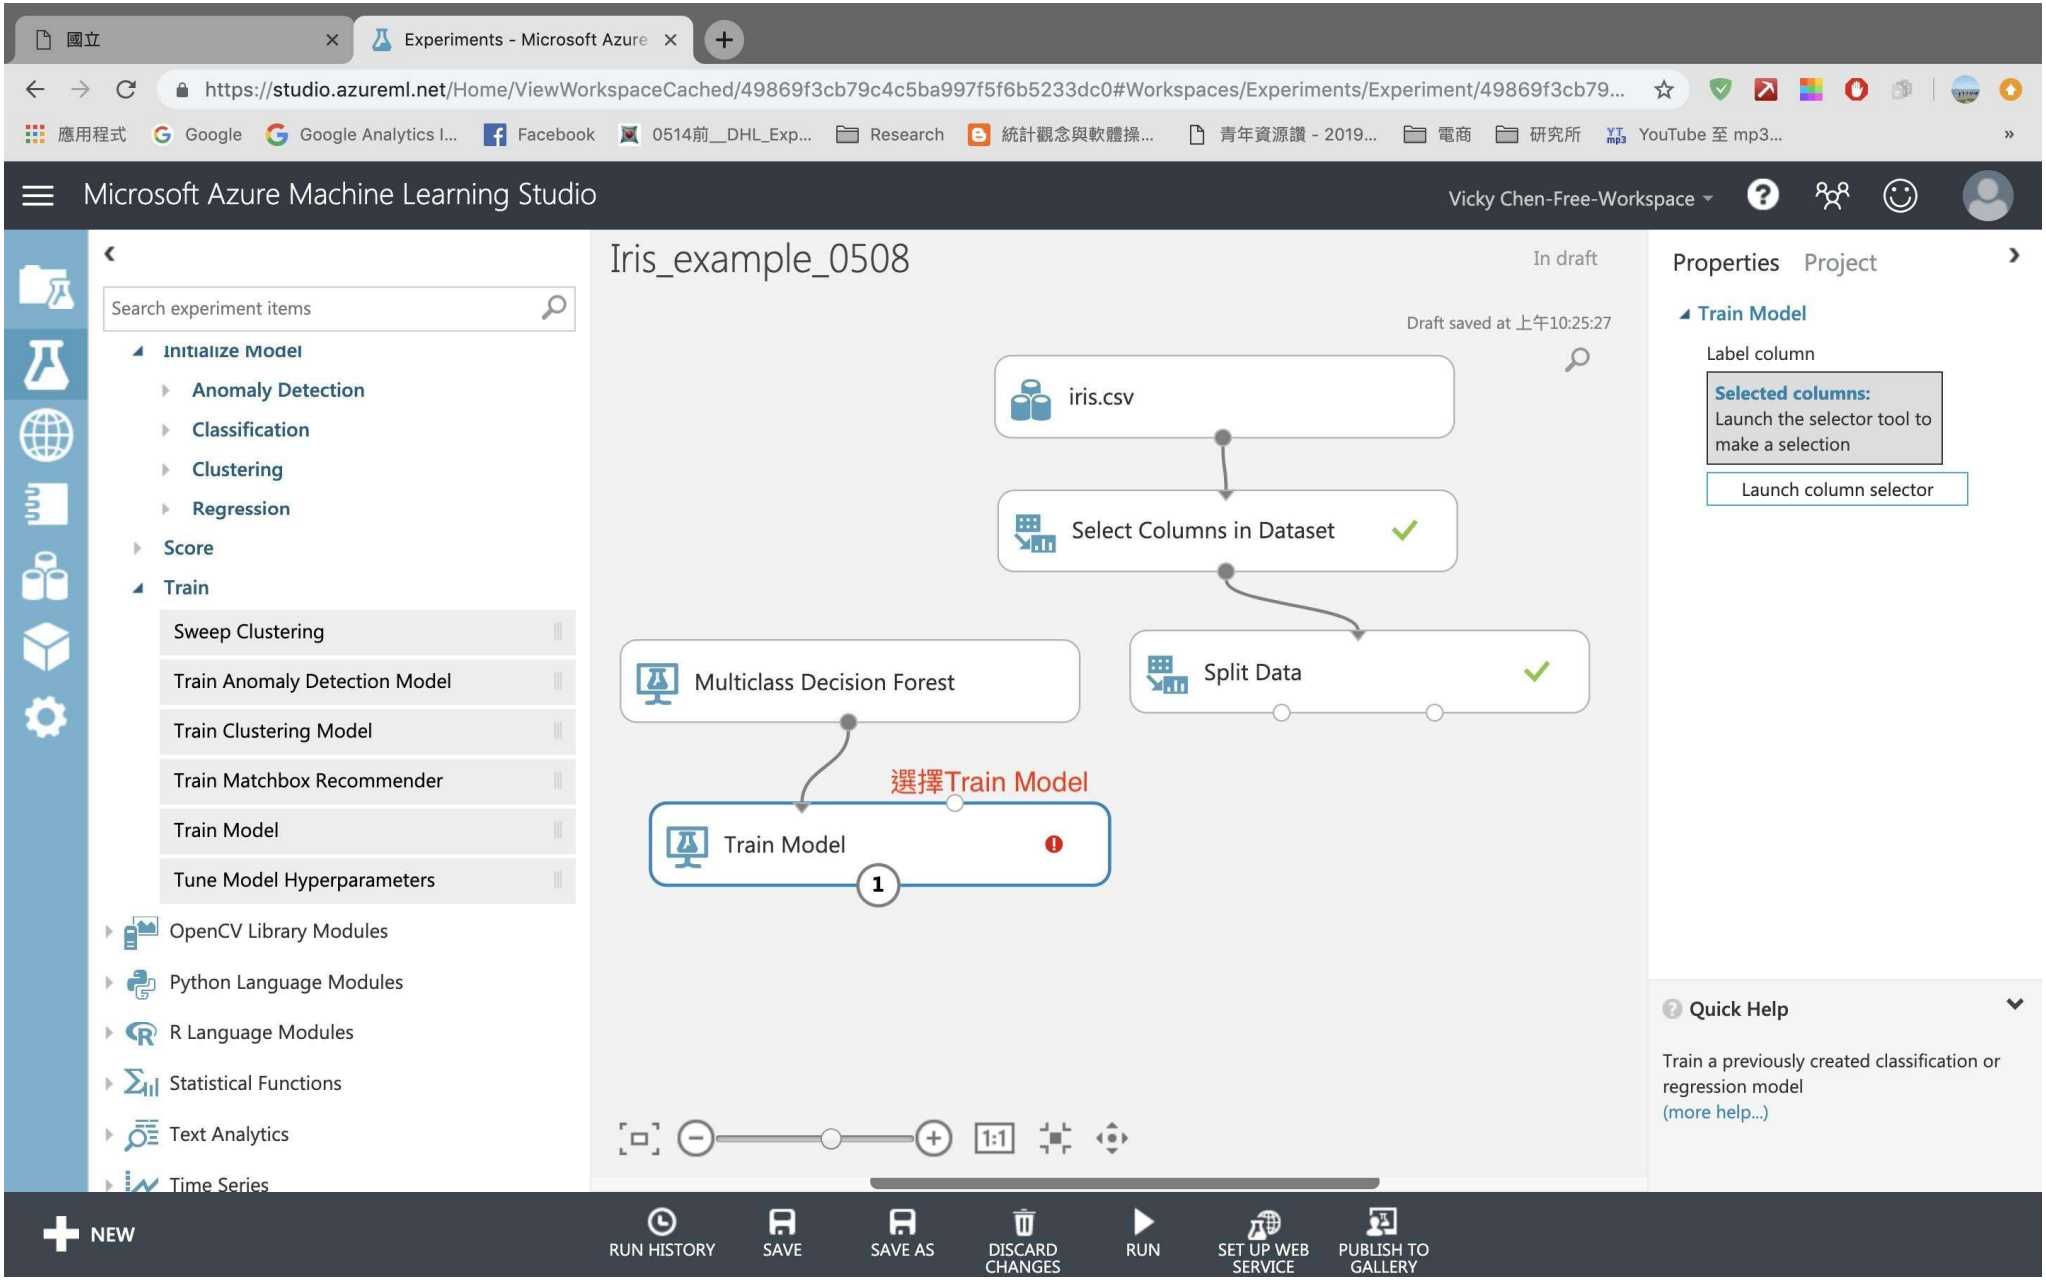

Azure Machine Learning Studio

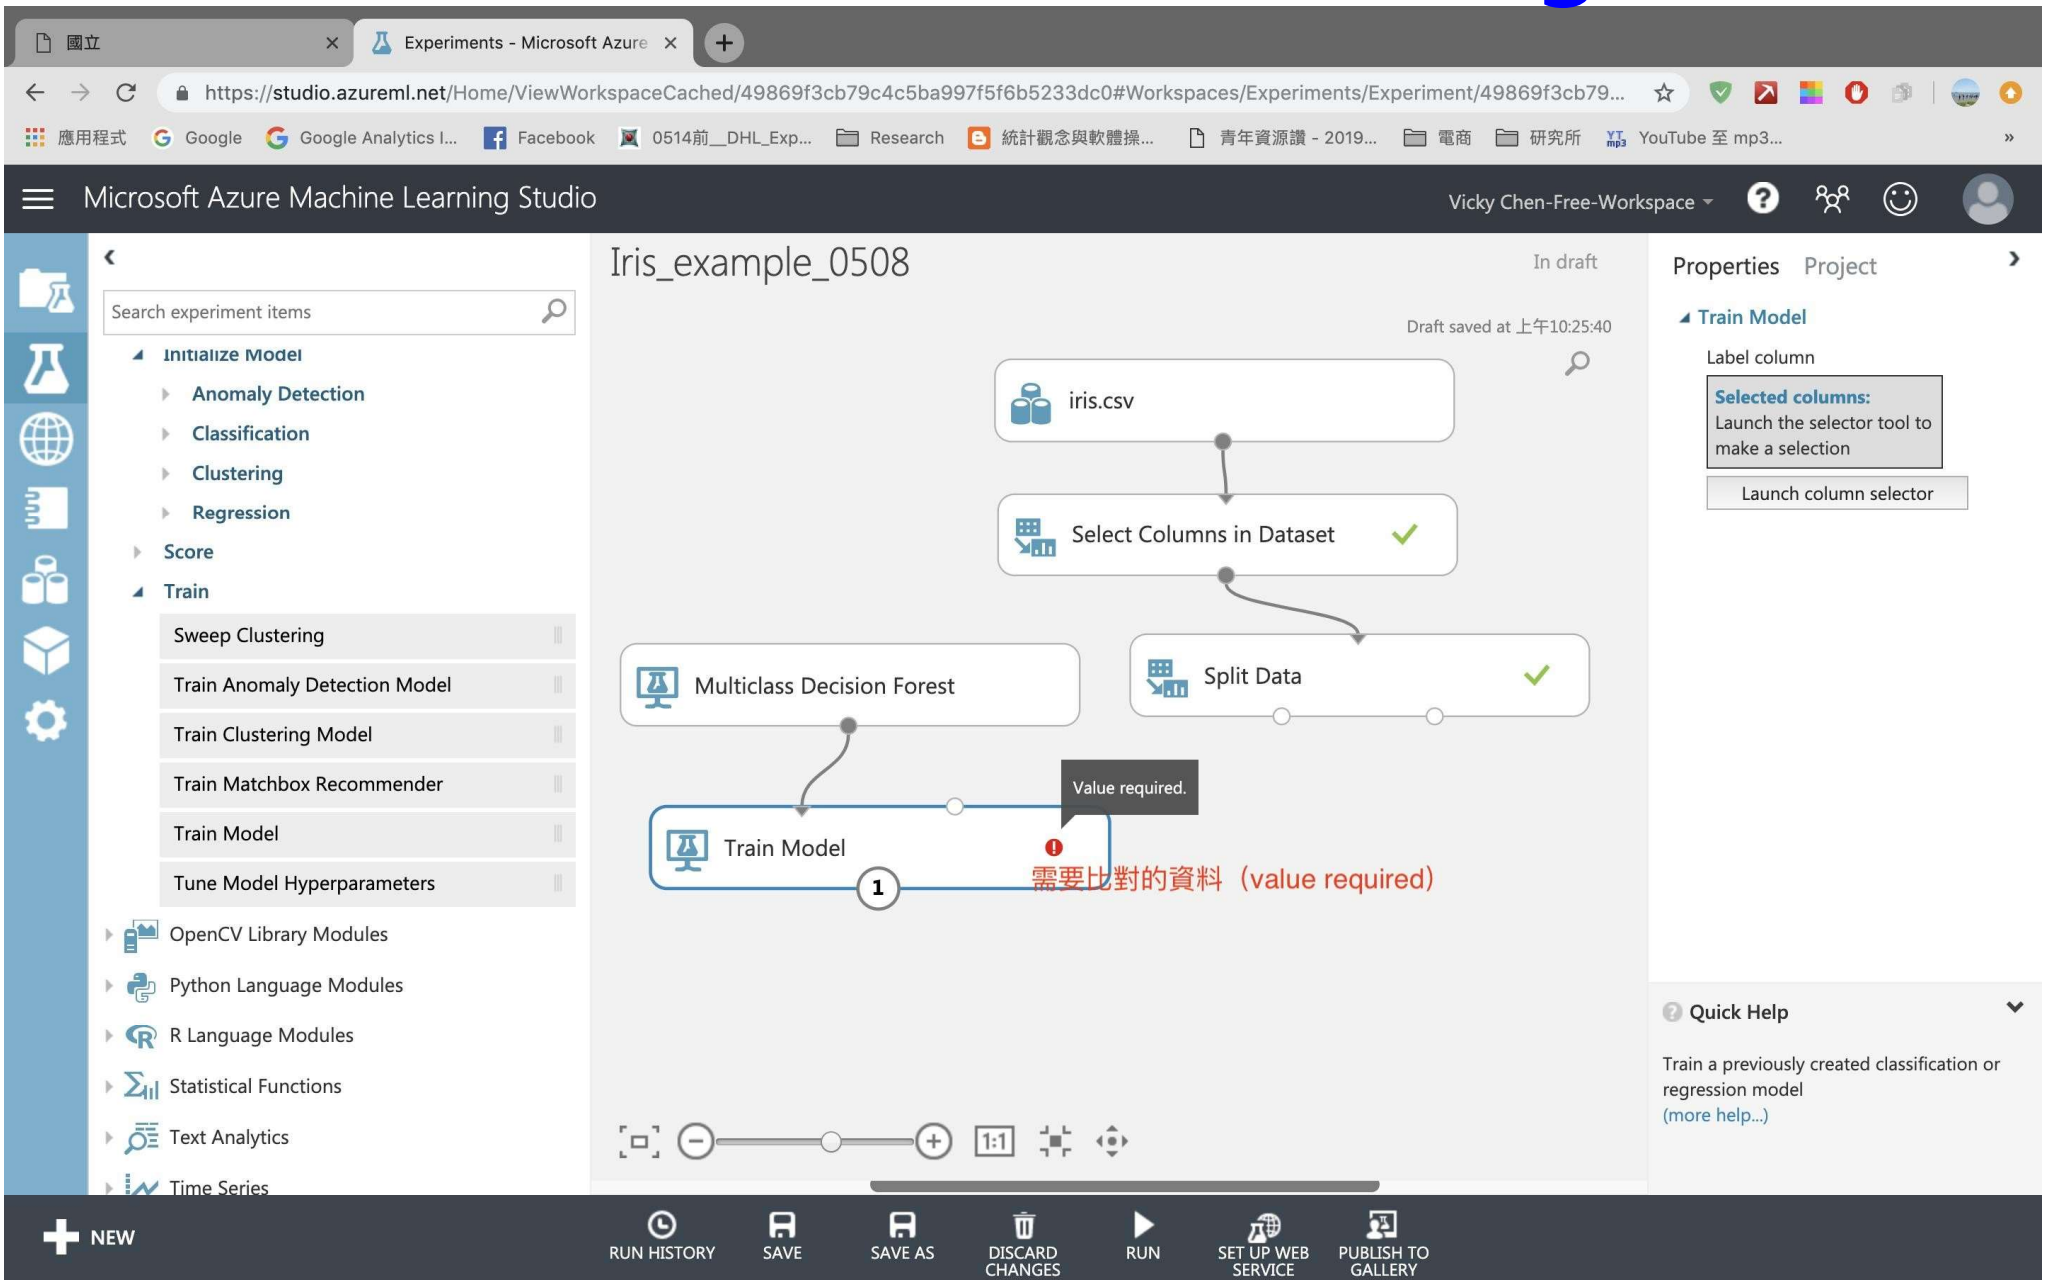

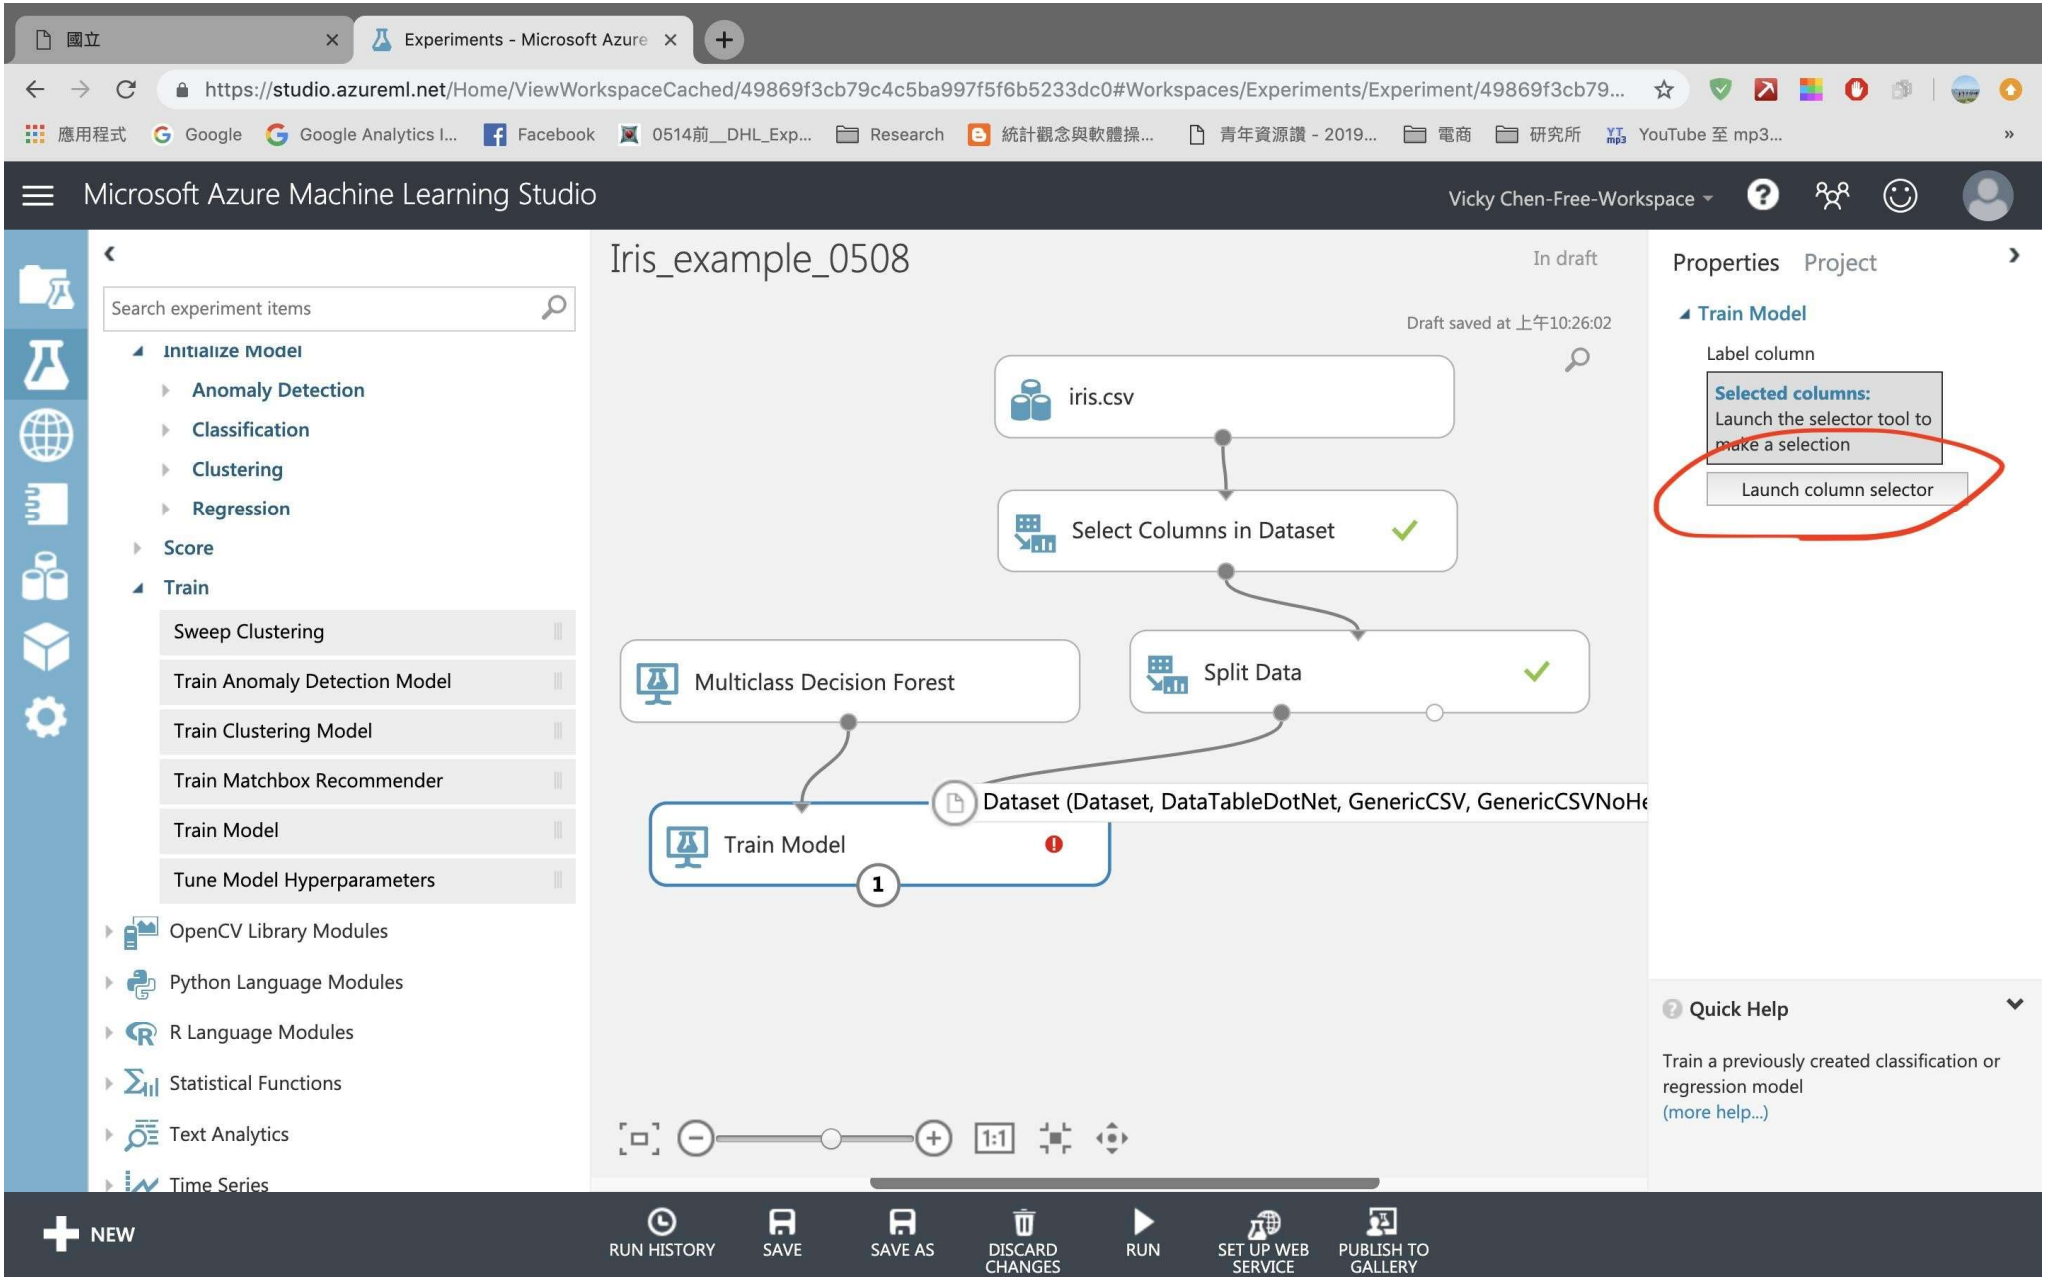
國立
Experiments - Microsoft Azure
https://studio.azureml.net/Home/ViewWorkspaceCached/49869f3cb79c4c5ba997f5f6b5233dc0#Workspaces/Experiments/Experiment/49869f3cb79...
Microsoft Azure Machine Learning Studio
Vicky Chen-Free-Workspace
Iris_example_0508
In draft
Draft saved at 上午10:26:02
Search experiment items
Initialize Model
Anomaly Detection
Classification
Clustering
Regression
Score
Train
Sweep Clustering
Train Anomaly Detection Model
Train Clustering Model
Train Matchbox Recommender
Train Model
Tune Model Hyperparameters
OpenCV Library Modules
Python Language Modules
R Language Modules
Statistical Functions
Text Analytics
Time Series
iris.csv
Select Columns in Dataset
Multiclass Decision Forest
Split Data
Dataset (Dataset, DataTableDotNet, GenericCSV, GenericCSVNoHe
Train Model
1
Properties
Project
Train Model
Label column
Selected columns:
Launch the selector tool to make a selection
Launch column selector
Quick Help
Train a previously created classification or regression model
(more help...)
NEW
RUN HISTORY
SAVE
SAVE AS
DISCARD CHANGES
RUN
SET UP WEB SERVICE
PUBLISH TO GALLERY

Azure Machine Learning Studio

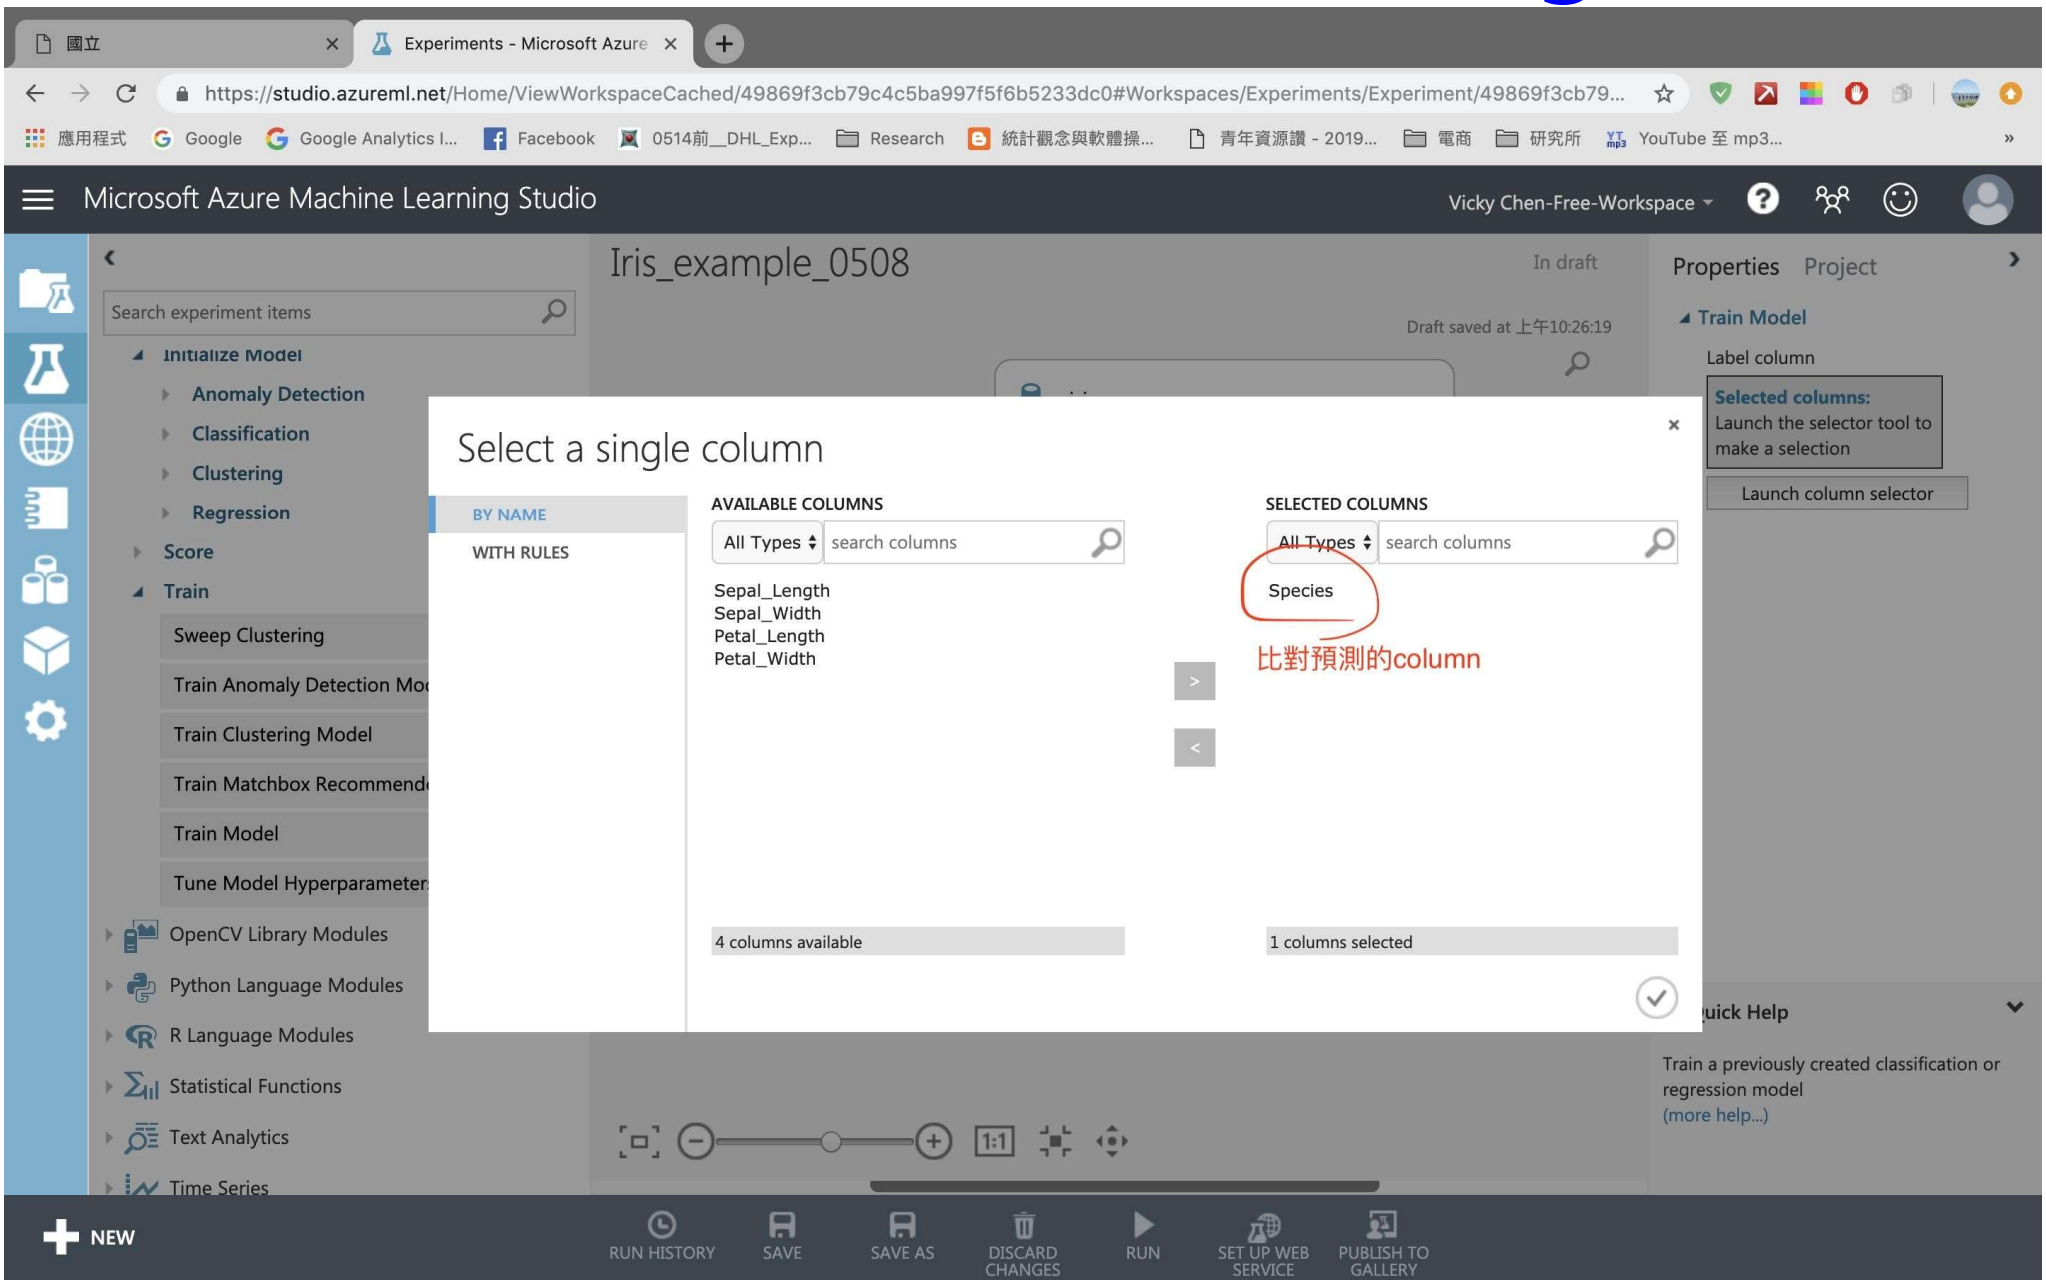

6.Train Model

7.Score Model

8.Evalute Model

連結Initial Train Score and Evaluate

Azure Machine Learning Studio

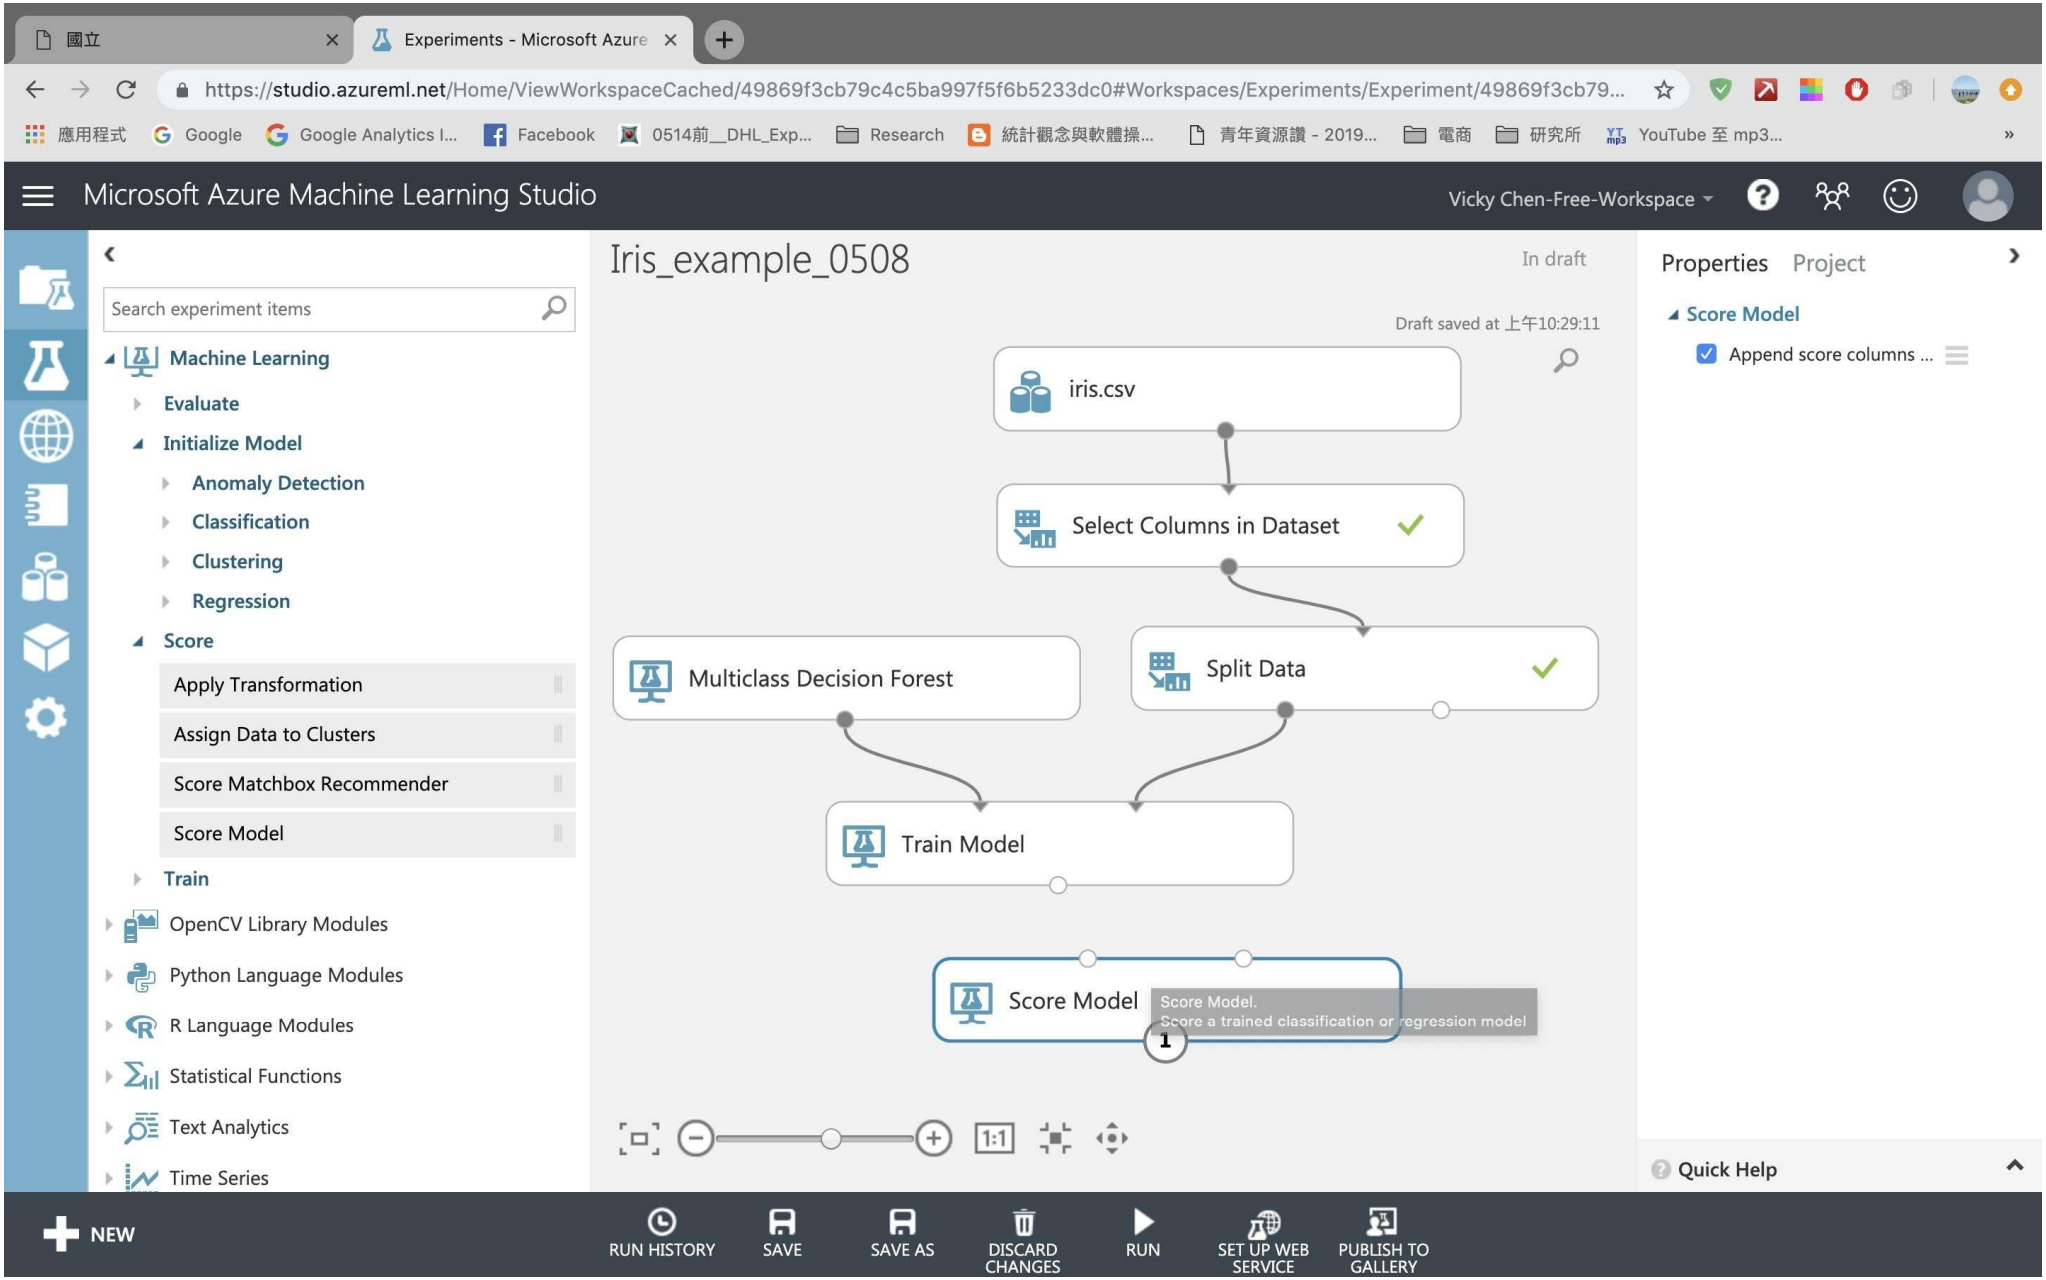

Azure Machine Learning Studio

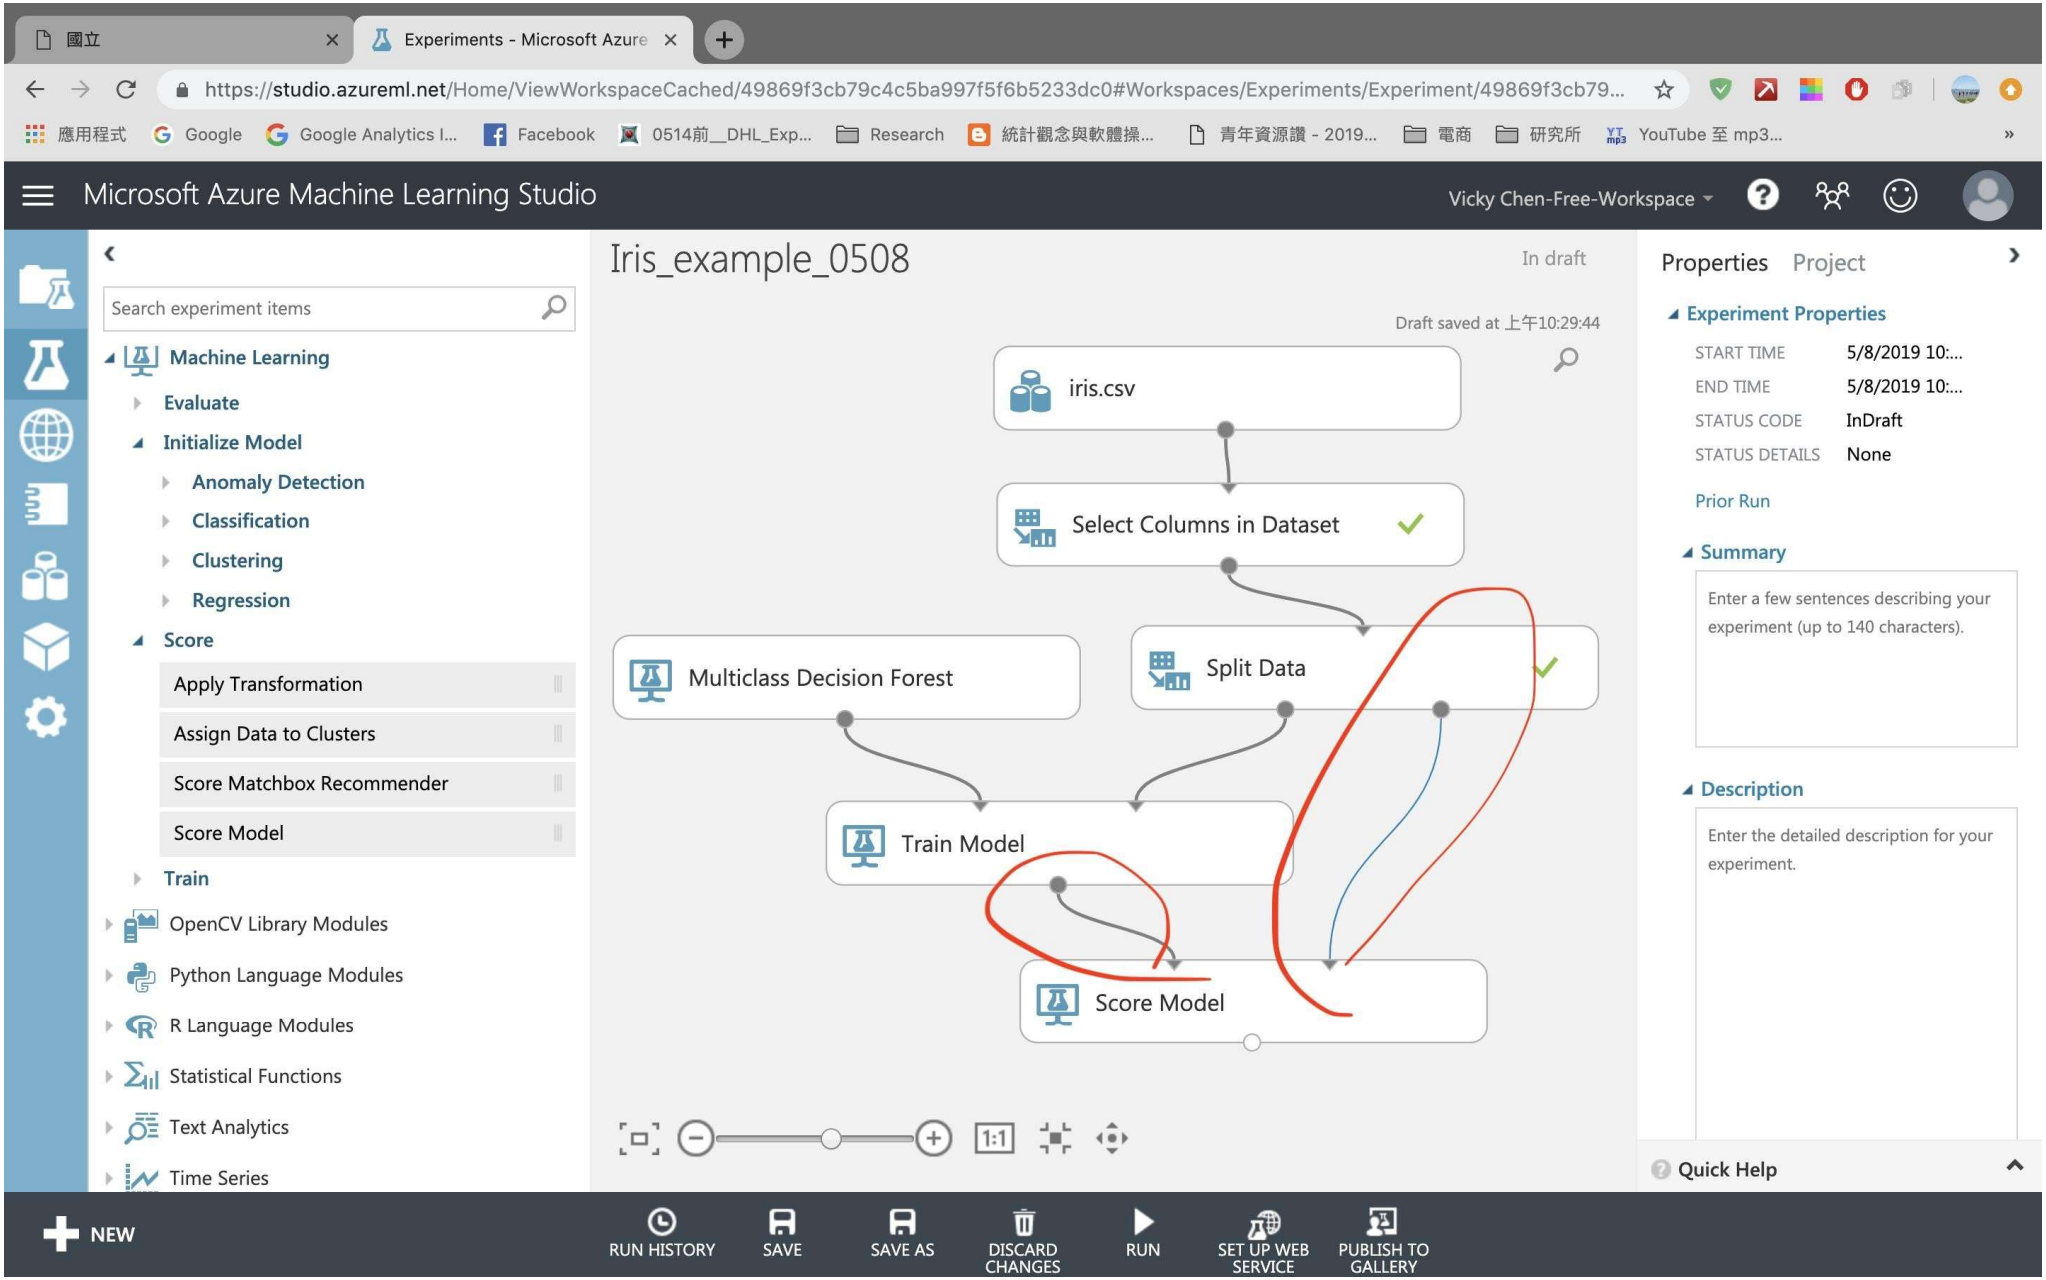

Azure Machine Learning Studio

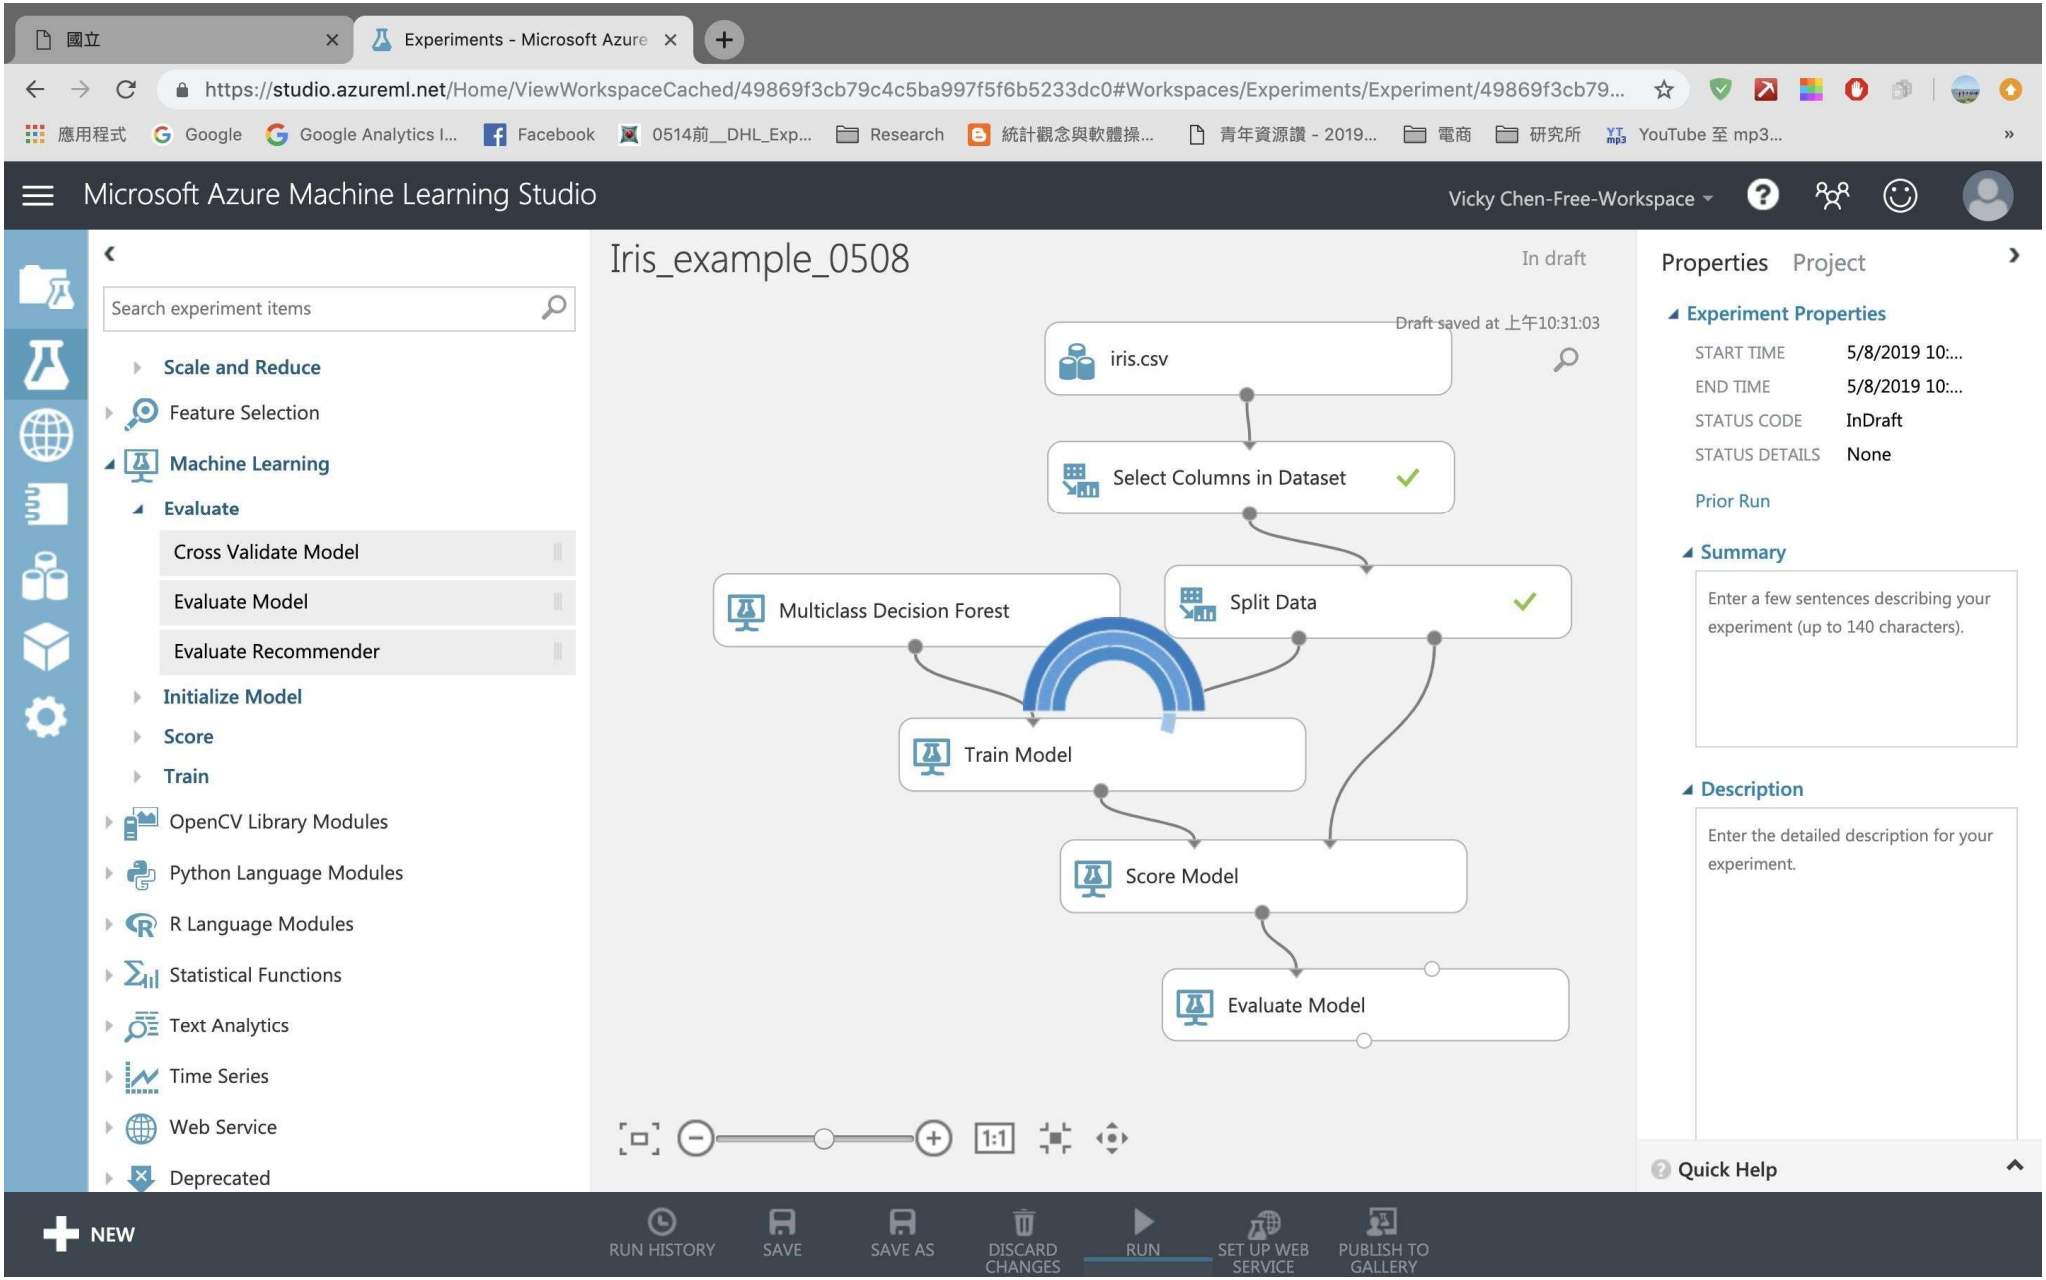

8.Evalute Model

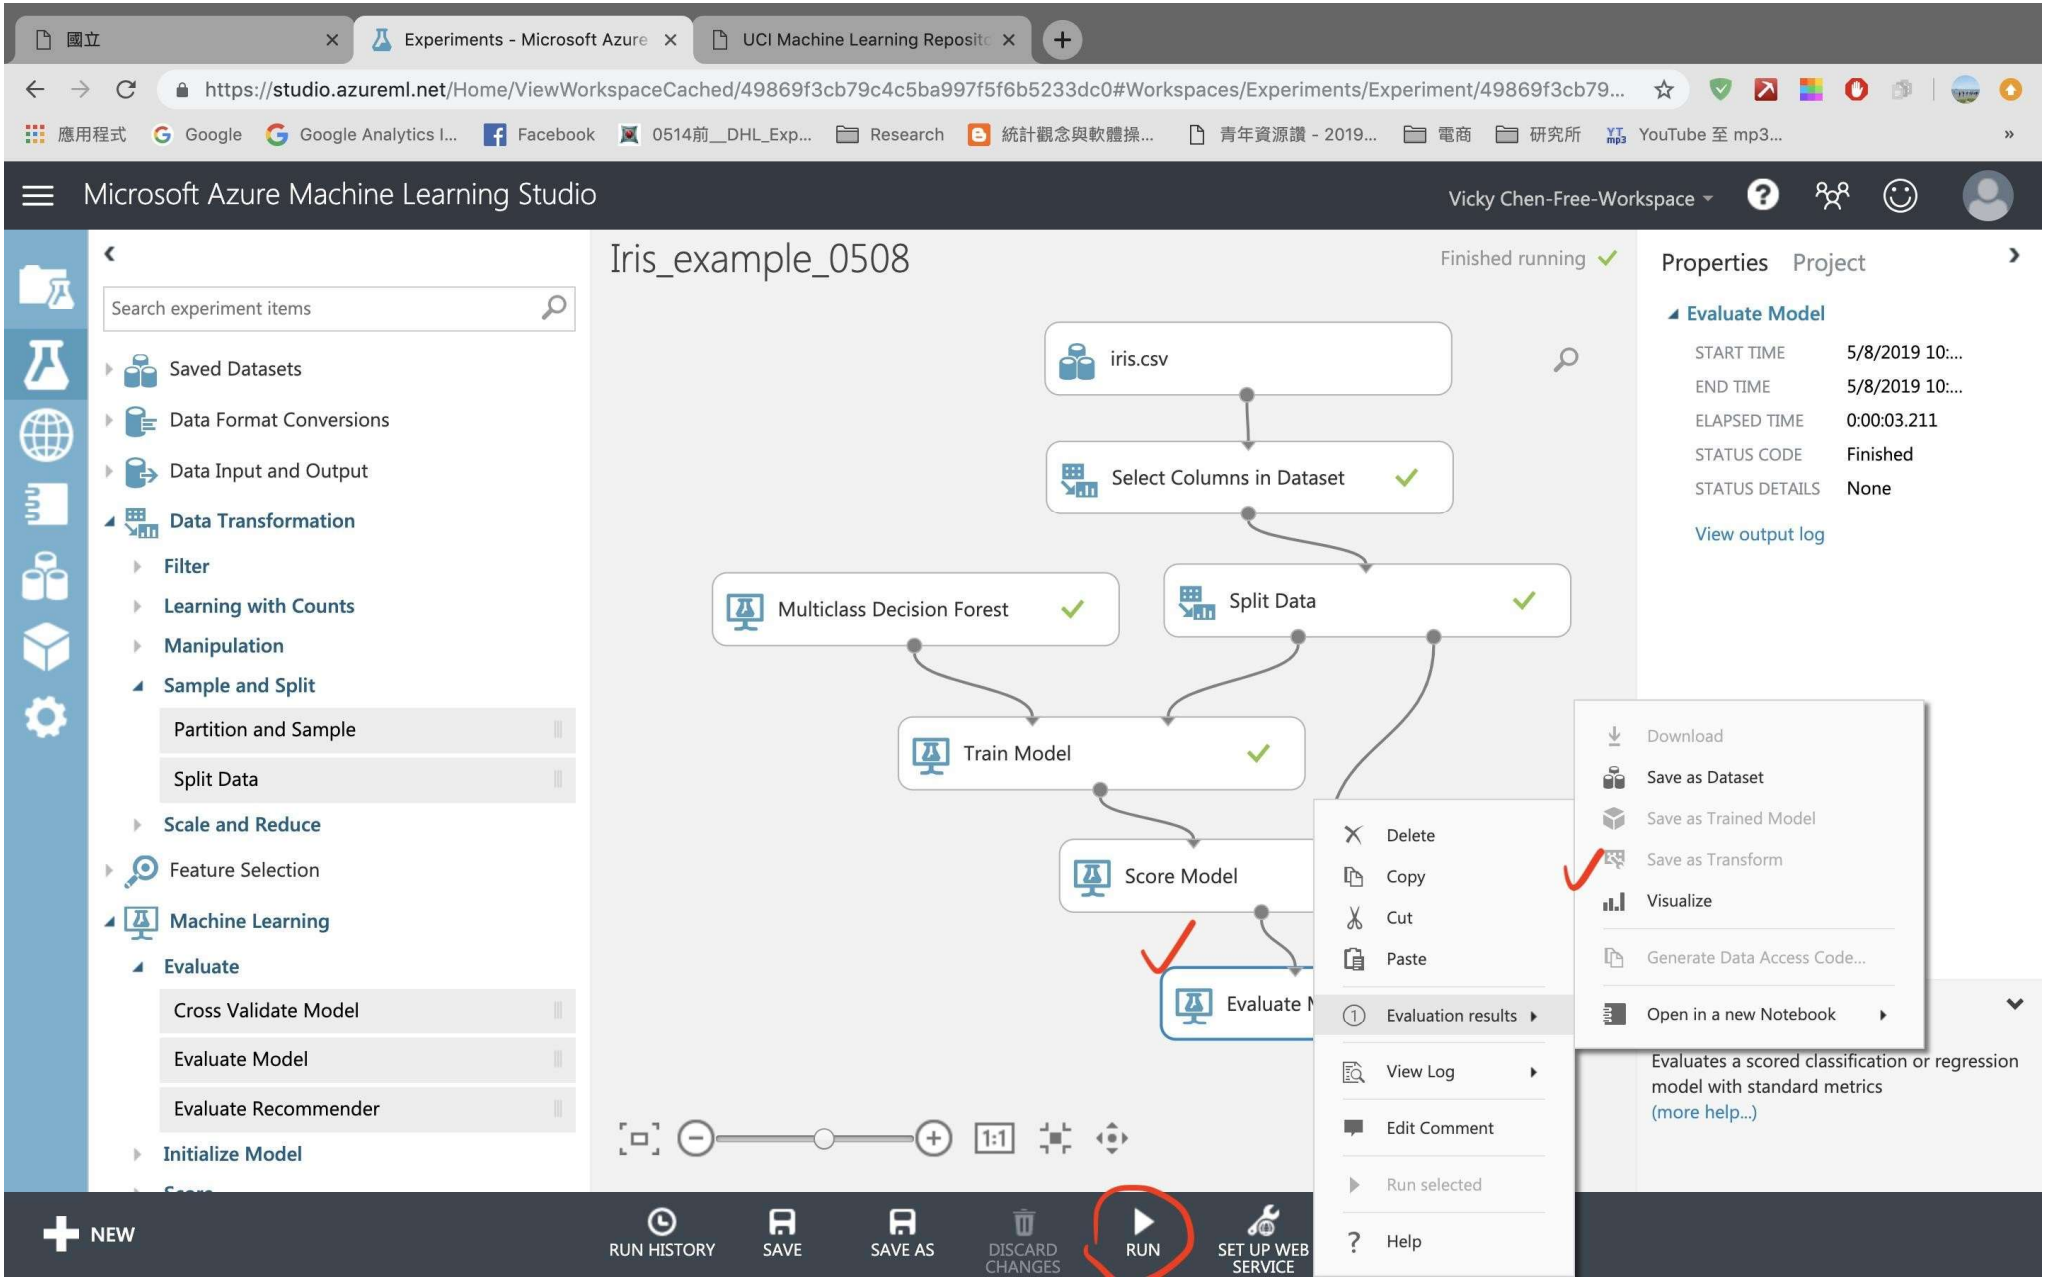
Experiments - Microsoft Azure
UCI Machine Learning Reposit
https://studio.azureml.net/Home/ViewWorkspaceCached/49869f3cb79c4c5ba997f5f6b5233dc0#Workspaces/Experiments/Experiment/49869f3cb79...
Microsoft Azure Machine Learning Studio
Vicky Chen-Free-Workspace
Iris_example_0508
Finished running
Search experiment items
Saved Datasets
Data Format Conversions
Data Input and Output
Data Transformation
Filter
Learning with Counts
Manipulation
Sample and Split
Partition and Sample
Split Data
Scale and Reduce
Feature Selection
Machine Learning
Evaluate
Cross Validate Model
Evaluate Model
Evaluate Recommender
Initialize Model
iris.csv
Select Columns in Dataset
Multiclass Decision Forest
Split Data
Train Model
Score Model
Evaluate
Delete
Copy
Cut
Paste
Evaluation results
View Log
Edit Comment
Run selected
Help
Download
Save as Dataset
Save as Trained Model
Save as Transform
Visualize
Generate Data Access Code...
Open in a new Notebook
Properties
Project
Evaluate Model
START TIME 5/8/2019 10:...
END TIME 5/8/2019 10:...
ELAPSED TIME 0:00:03.211
STATUS CODE Finished
STATUS DETAILS None
View output log
Evaluates a scored classification or regression model with standard metrics
(more help...)
NEW
RUN HISTORY
SAVE
SAVE AS
DISCARD CHANGES
RUN
SET UP WEB SERVICE

Iris_example_0508 › Evaluate Model › Evaluation results

Metrics

Overall accuracy	0.977778
Average accuracy	0.985185
Micro-averaged precision	0.977778
Macro-averaged precision	0.97619
Micro-averaged recall	0.977778
Macro-averaged recall	0.974359

Confusion Matrix

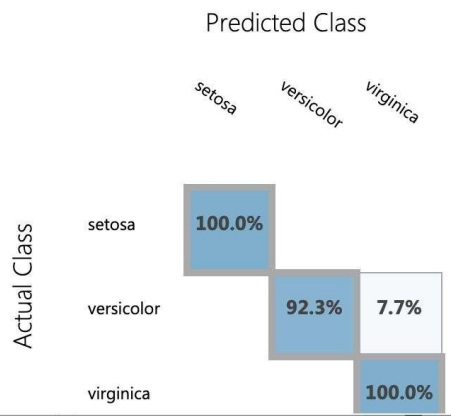

Microsoft Azure Machine Learning Studio

Iris_example_0508

Iris_example_0508 › Evaluate Model › Evaluation results

Macro-averaged recall	0.974359

Confusion Matrix

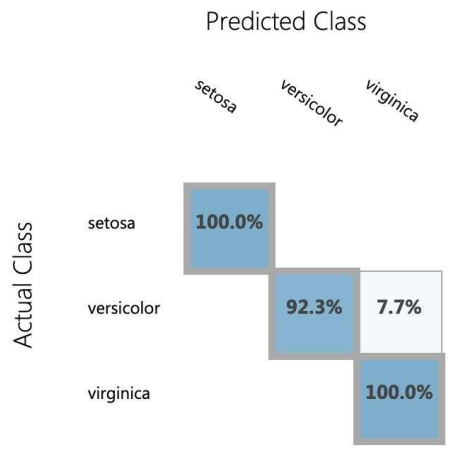

NEW RUN HISTORY SAVE SAVE AS DISCARD CHANGES RUN SET UP WEB SERVICE PUBLISH TO GALLERY

機器學習平台範例介紹

DataRobot

人工智慧醫療應用資料集選輯

中文名稱	英文名稱	資料型態	任務簡述	
心臟病資料集	UCI Cleveland Heart Disease Dataset	單一數字表格文件	分類(classification)	https://www.kaggle.com/datasets/cherngs/heart-disease-cleveland-uci
中風資料集	Stroke Prediction Dataset	單一數字文字表格文件	分類(classification)/異常檢測(anomaly detection)	https://www.kaggle.com/datasets/fedesoriano/stroke-prediction-dataset
醫療保險詐欺資料集	Healthcare Provider Fraud Analysis	多個數字文字表格文件	分類(classification)/異常檢測(anomaly detection)	https://www.kaggle.com/datasets/rohitrox/healthcare-provider-fraud-detection-analysis
醫療費用預測資料集	Medical Cost Personal Dataset	單一數字文字表格文件	回歸(regression)	https://www.kaggle.com/datasets/mirichoi0218/insurance
藥品使用反饋資料集	UCI Drug Review	單一數字文字表格文件	自然語言處理(natural language processing)/情緒分析(sentiment analysis)	https://www.kaggle.com/datasets/jessicali9530/kuc-hackathon-winter-2018
新冠肺炎全球趨勢資料集	COVID-19 Gobal Trend	多個數字文字時間表格文件	時間序列分析及預測(time series analysis/forecast)	https://www.kaggle.com/datasets/sudalairajkumar/novel-corona-virus-2019-dataset
胸部 X 光肺炎資料集	Chest X-Ray Images (Pneumonia)	圖像文件(.jpeg)	圖像分類(image classification)	https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia
新冠肺炎電腦斷層掃描資	COVID-19 CT Scans	圖像文件(.nii)	圖像分割(image segmentation)	https://www.kaggle.com/datasets/andrewmvd/covid19-ct-scans
心音檢測資料集	Heartbeat Sound	音頻文件(.wav)	音頻分類(audio classification)/音頻分割(audio segmentation)	https://www.kaggle.com/datasets/kinguistics/heartbeat-sounds
藥物交互作用資料集	Drug-Drug Interaction Network	單一文字表格文件	連接預測(link prediction)	http://snap.stanford.edu/biodata/datasets/10001/10001-ChCh-Miner.html
乳癌診斷資料集	Breast Cancer Wisconin Diagnostic	單一數字表格文件	分類(classification)	https://www.kaggle.com/datasets/uciml/breast-cancer-wisconsin-data

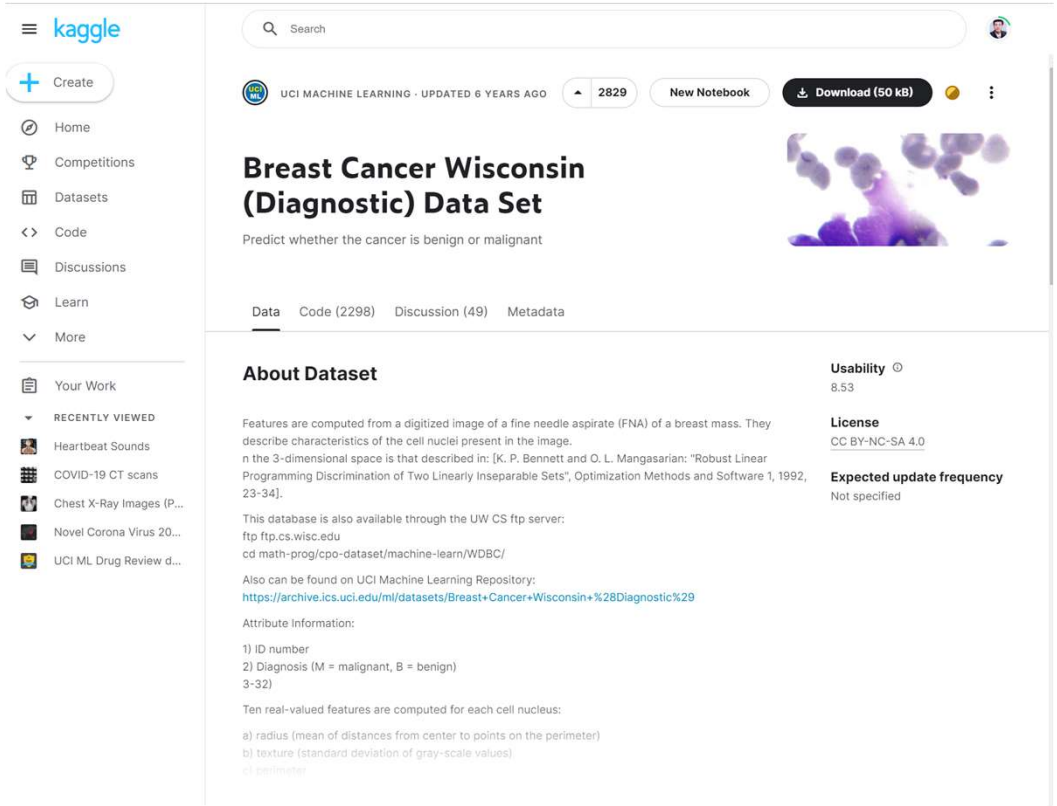

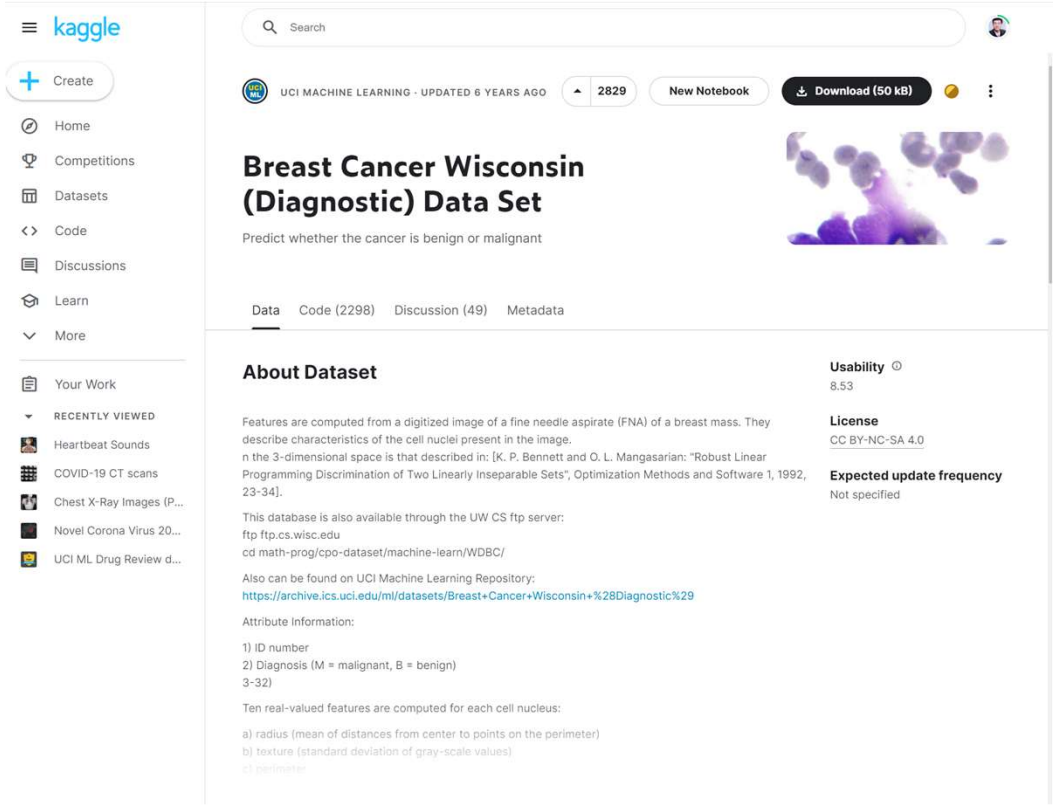

十大特徵值

1.半徑(中心到邊緣上的點的平均距離)
2.紋理(灰階值的標準差)
3.周長
4.面積
5.平滑度(半徑長度的局部變化)
6.緊密度(周長平方/面積 – 1.0)
7.凹面(輪廓凹面部分的嚴重度)
8.凹點(輪廓凹面的數量)
9.對稱性
10.分形維度(海岸線近似-1)