用OpenRefine清理資料

TaiBIF 內容經理 劉璟儀

劉璟儀

TaiBIF 內容經理/ GBIF 亞洲區諮詢顧問

melissaliu0520@gmail.com

大學唸公共衛生，碩士轉領域到海洋科學
主要研究鯨豚的重金屬和碳氮同位素

- 推動及宣傳國內生物多樣性資料標準、資料開放
- 國內生物多樣性資料庫相關單位合作
- TaiBIF 資料庫管理諮詢

- 亞洲計畫團隊開放資料諮詢
- 推動亞洲國家節點合作
- 促進亞洲區域開放資料

上傳資料前...
你應該準備好這些事

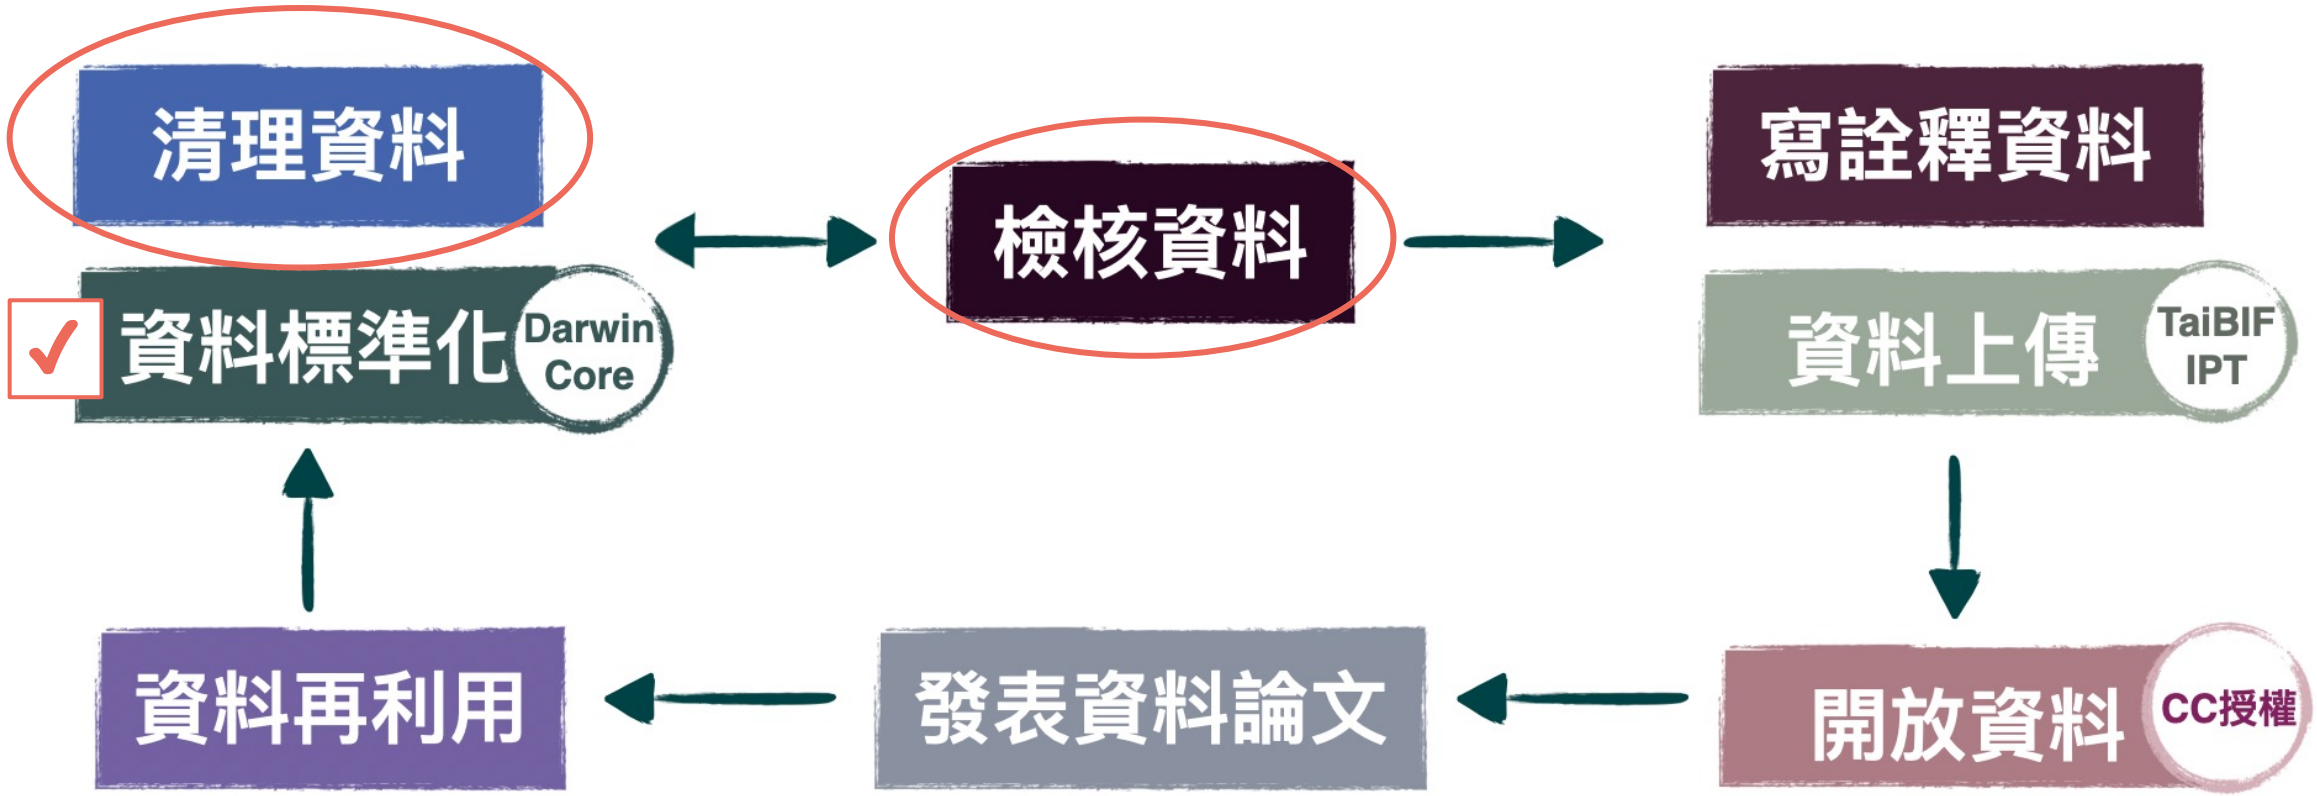

資料清理小工具

OpenRefine

不是資料庫

(無法儲存資料)

與 Excel 的使用方式不同

（只能清理資料）

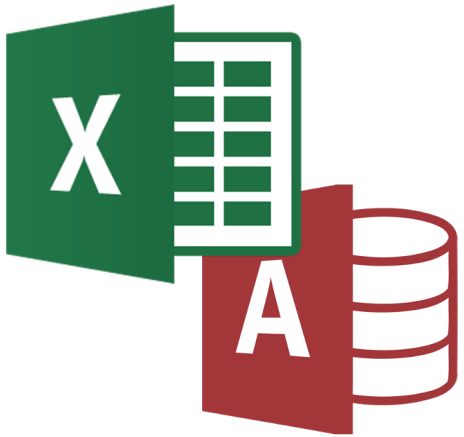

用 OpenRefine 清資料

使用介面簡單

可一次修正整批資料錯誤/格式

隨時自動暫存且離線操作

可返回任何一步操作

匯入CSV / Excel 不易出現亂碼

資料清理小工具

OpenRefine

1 Excel

產生資料/ 管理資料

2 GBIF data validator

GBIF

檢核資料

3 OpenRefine

清理資料

清理資料流程

1. 先產生並彙整資料
2. 驗證資料
   GBIF Data Validator
3. 查看資料問題
   Validation Issues
4. 清理資料
   OpenRefine
5. 上傳資料
   TaiBIF IPT
6. 再次確認資料問題
   GBIF dataset 的 Issues & flags

實作練習

1. 下載 **Data-cleaning-open-refine v20220927**
2. 使用 **GBIF Data Validator** 找出資料錯誤
3. 試著用 **OpenRefine** 找出個別錯誤並修正
4. 利用 **NomenMatch** 比對有效學名/ **Canadensys Coordinate conversion** 轉換座標格式
5. 進階題：使用 **GBIF backbone API** 新增分類階層欄位

用OpenRefine清理資料

等等會需要用到的連結

練習檔案下載
GBIF 資料驗證工具
NomenMatch 學名比對
Canadensys 座標/日期轉換工具

用 OpenRefine 清資料

下載並安裝在電腦 https://openrefine.org/download.html

Download OpenRefine

OpenRefine is free software released under the BSD 3-clause license, brought to you by our contributors.

Download OpenRefine 3.8.0 for Windows
ZIP file, with embedded Java install

Privacy notice – Release notes

Other platforms and versions

Version	Windows (installer)	Windows (zip file)	Mac OS	Linux
3.8.0 (2024-04-29)	EXE	ZIP	DMG	TAR.GZ
3.7.9 (2024-02-10)		ZIP	DMG	TAR.GZ
3.6.2 (2022-10-03)		ZIP	DMG	TAR.GZ

用 OpenRefine 清資料

下載到電腦打開exe檔

https://openrefine.org/download.html

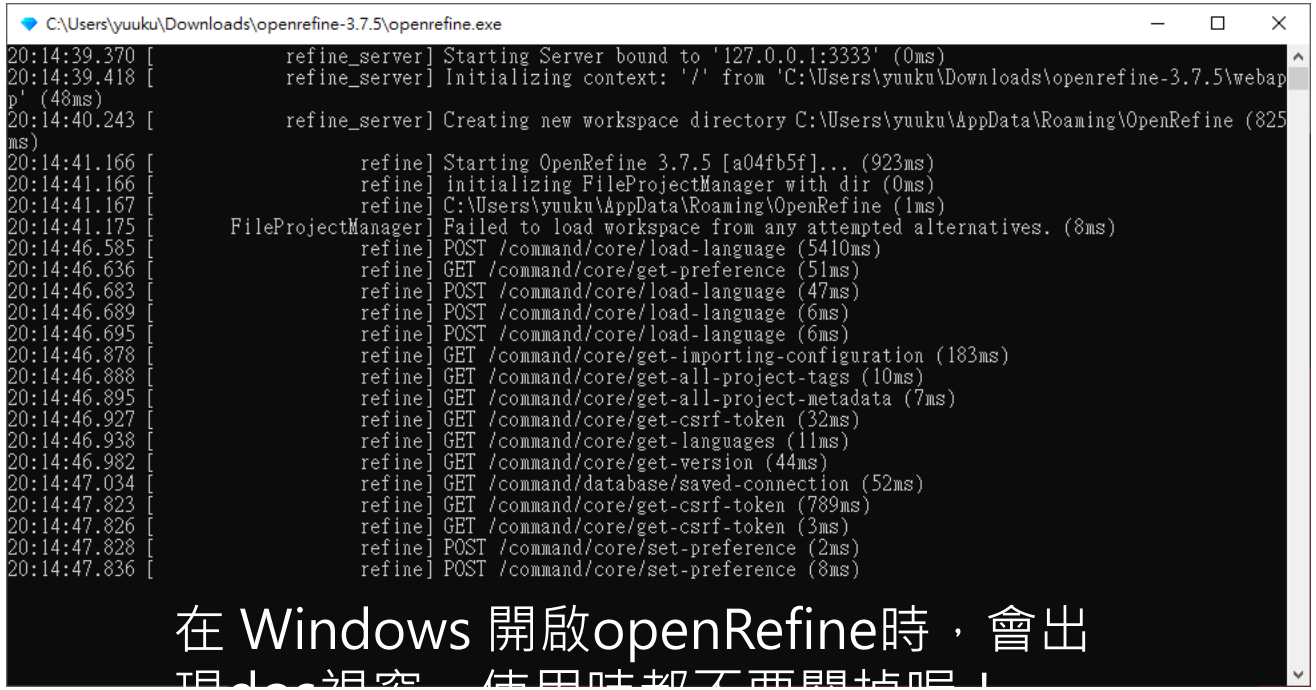

用 OpenRefine 清資料

要看到這個畫面出現在瀏覽器上才是對的

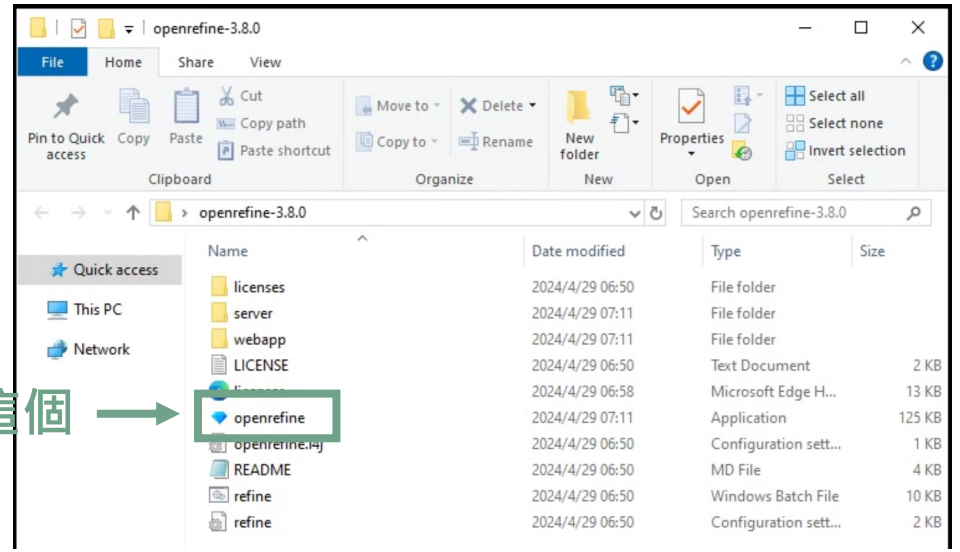

Windows 下載後打開資料夾直接點這個 →

檢核資料—先找出可能的資料錯誤

- **GBIF data validator** https://www.gbif.org/tools/data-validator

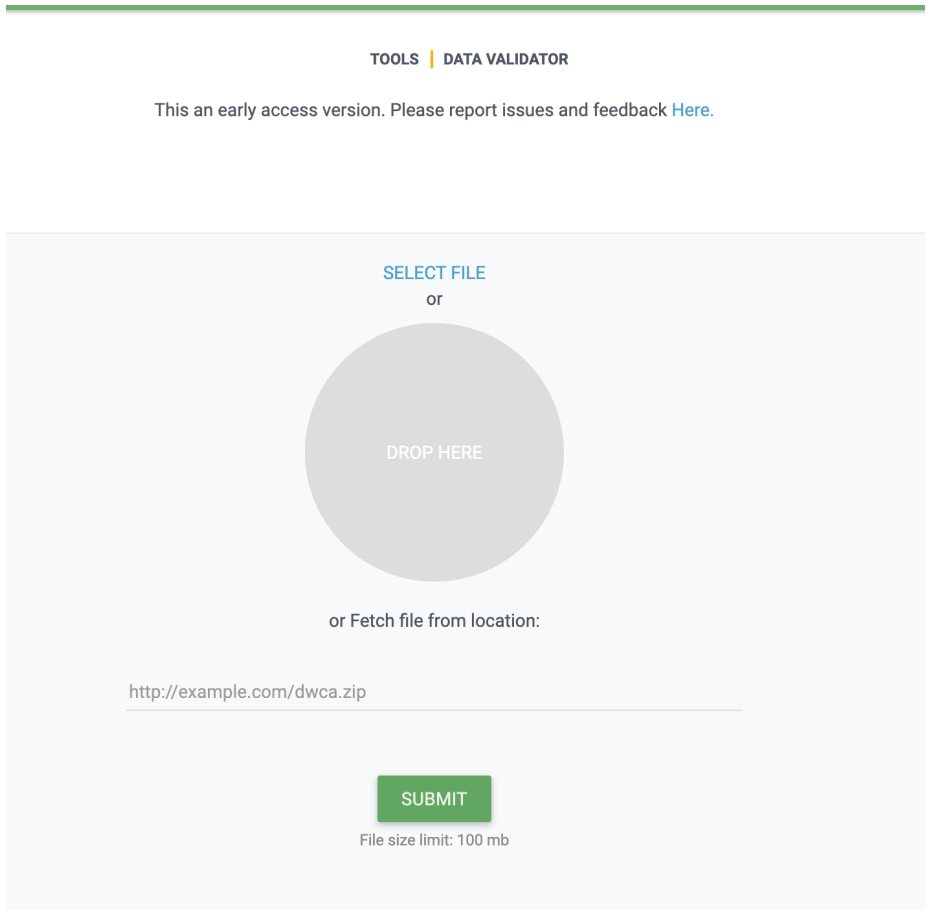

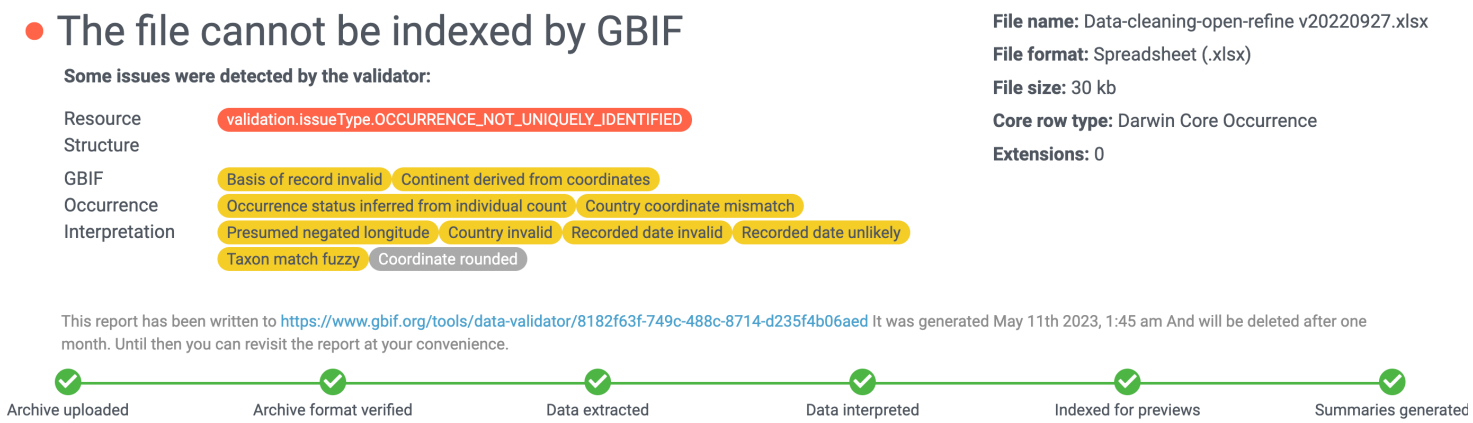

資料問題

- 找出重複 ID occurrenceID
- 新增欄位 basisOfRecord
- 內容錯誤或與欄位不符
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- 學名比對&清理 scientificName
- 修正學名格式 ^[A-Z].*\s[A-Z]
- 清除多餘空格 country
- 找出相似文字並合併 County

用 OpenRefine 清資料

選擇檔案並按 Next

用 OpenRefine 清資料

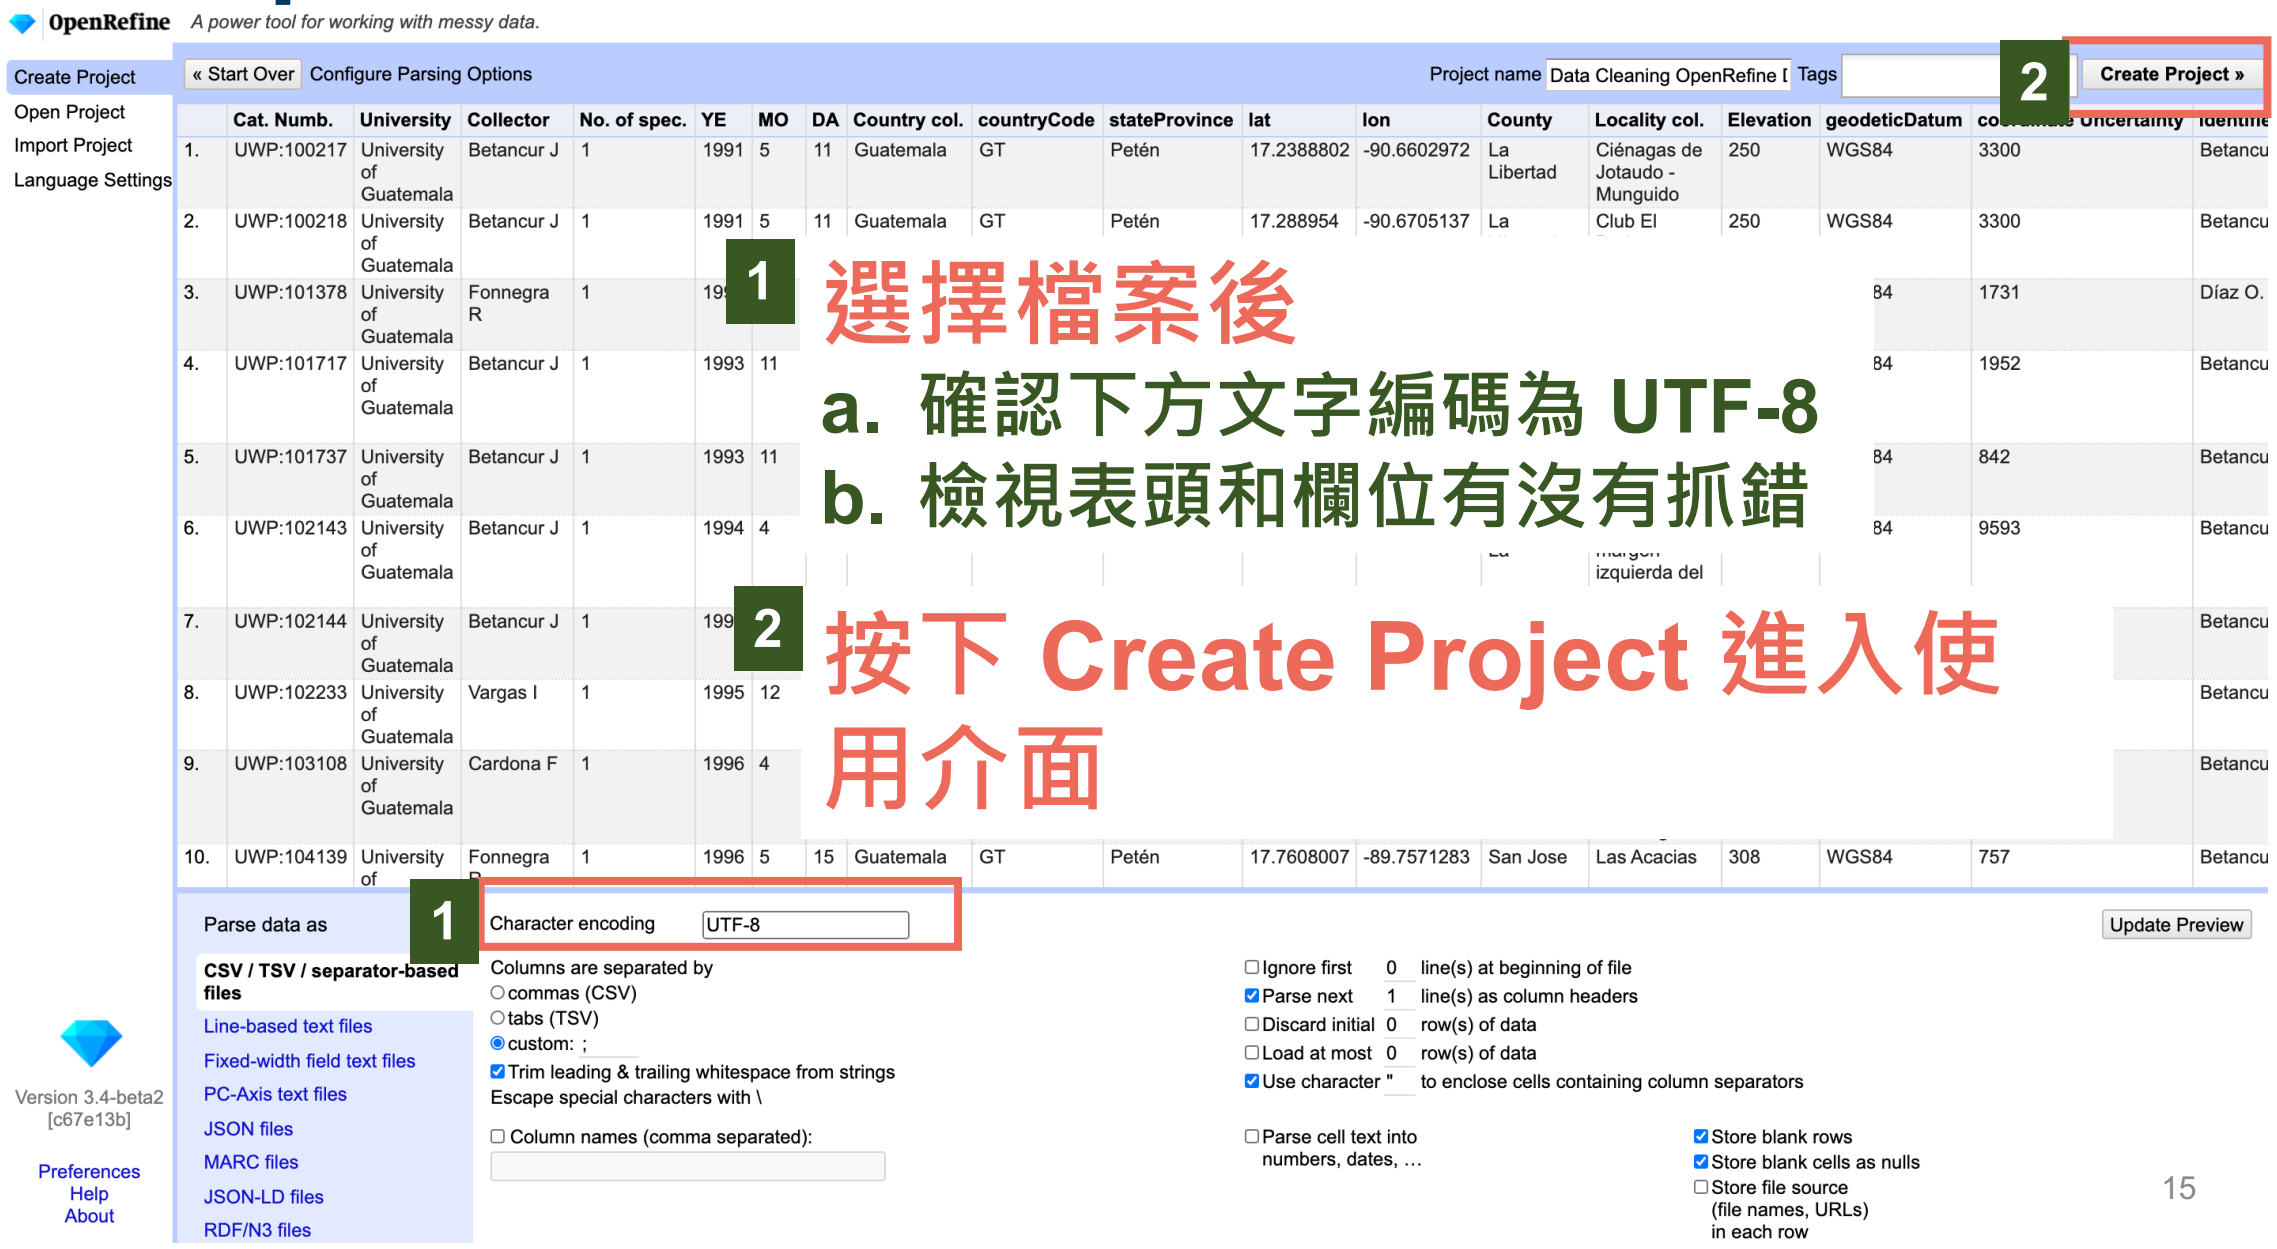

	Cat. Numb.	University	Collector	No. of spec.	YE	MO	DA	Country col.	countryCode	stateProvince	lat	lon	County	Locality col.	Elevation	geodeticDatum	Identifie
1.	UWP:100217	University of Guatemala	Betancur J	1	1991	5	11	Guatemala	GT	Petén	17.2388802	-90.6602972	La Libertad	Ciénagas de Jotaudo - Munguido	250	WGS84	Betancu
2.	UWP:100218	University of Guatemala	Betancur J	1	1991	5	11	Guatemala	GT	Petén	17.288954	-90.6705137	La	Club El	250	WGS84	Betancu
3.	UWP:101378	University of Guatemala	Fonnegra R	1	19											84	Díaz O.
4.	UWP:101717	University of Guatemala	Betancur J	1	1993	11										84	Betancu
5.	UWP:101737	University of Guatemala	Betancur J	1	1993	11										84	Betancu
6.	UWP:102143	University of Guatemala	Betancur J	1	1994	4								izquierda del		84	Betancu
7.	UWP:102144	University of Guatemala	Betancur J	1	199												Betancu
8.	UWP:102233	University of Guatemala	Vargas I	1	1995	12											Betancu
9.	UWP:103108	University of Guatemala	Cardona F	1	1996	4											Betancu
10.	UWP:104139	University of	Fonnegra	1	1996	5	15	Guatemala	GT	Petén	17.7608007	-89.7571283	San Jose	Las Acacias	308	WGS84	Betancu

用 OpenRefine 清資料

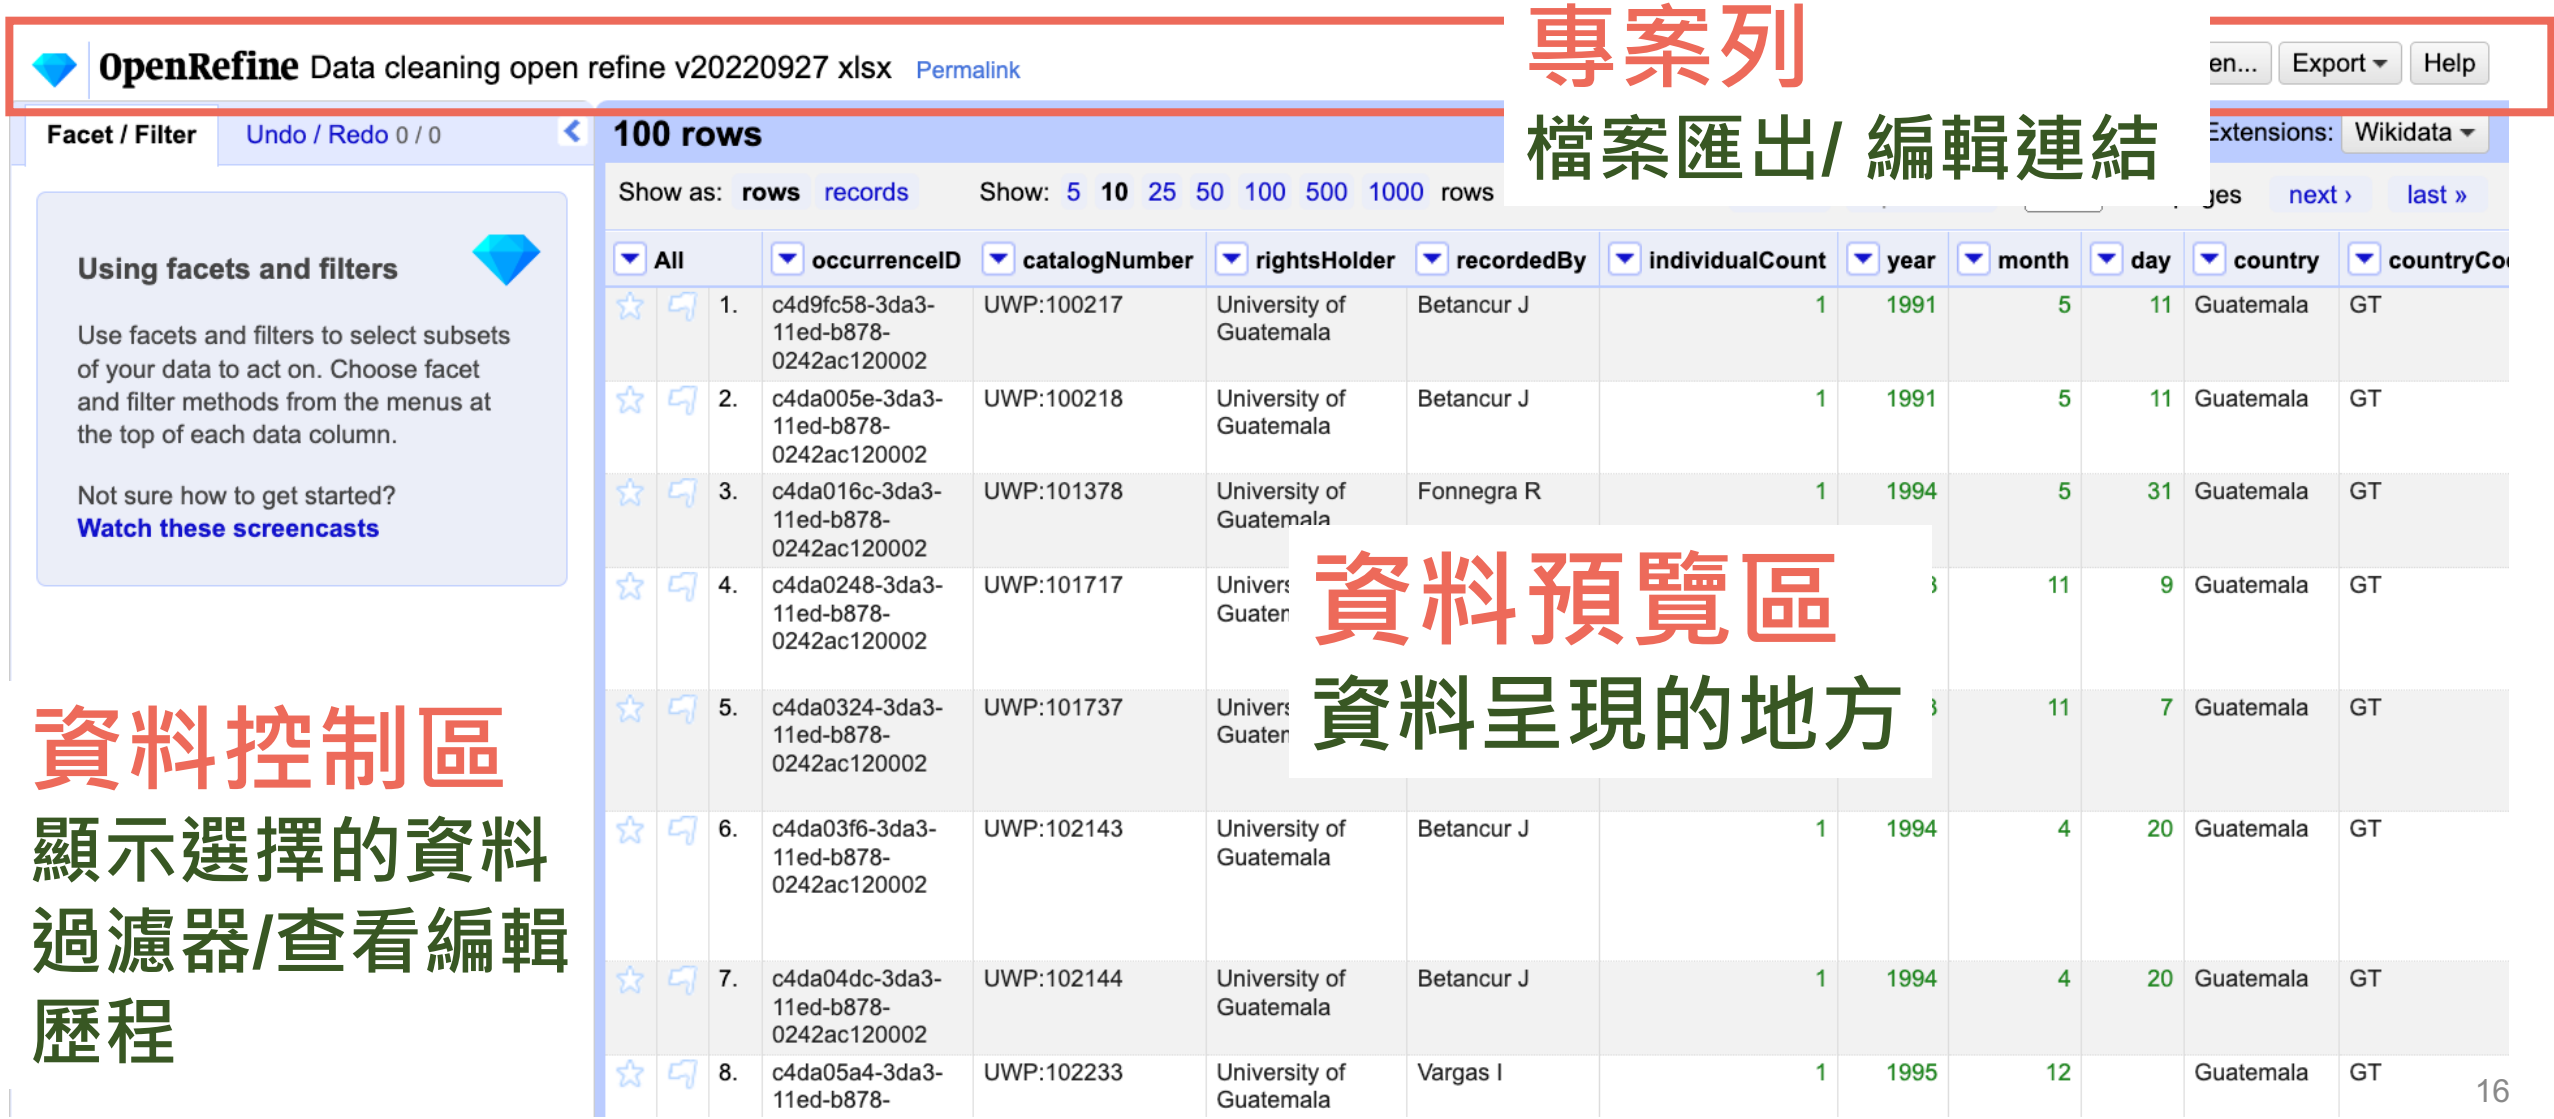

All		occurrenceID	catalogNumber	rightsHolder	recordedBy	individualCount	year	month	day	country	countryCo
1.		c4d9fc58-3da3-11ed-b878-0242ac120002	UWP:100217	University of Guatemala	Betancur J	1	1991	5	11	Guatemala	GT
2.		c4da005e-3da3-11ed-b878-0242ac120002	UWP:100218	University of Guatemala	Betancur J	1	1991	5	11	Guatemala	GT
3.		c4da016c-3da3-11ed-b878-0242ac120002	UWP:101378	University of Guatemala	Fonnegra R	1	1994	5	31	Guatemala	GT
4.		c4da0248-3da3-11ed-b878-0242ac120002	UWP:101717	Univers Guater				11	9	Guatemala	GT
5.		c4da0324-3da3-11ed-b878-0242ac120002	UWP:101737	Univers Guater				11	7	Guatemala	GT
6.		c4da03f6-3da3-11ed-b878-0242ac120002	UWP:102143	University of Guatemala	Betancur J	1	1994	4	20	Guatemala	GT
7.		c4da04dc-3da3-11ed-b878-0242ac120002	UWP:102144	University of Guatemala	Betancur J	1	1994	4	20	Guatemala	GT
8.		c4da05a4-3da3-11ed-b878-	UWP:102233	University of Guatemala	Vargas I	1	1995	12		Guatemala	GT

案例練習- 進階作業

資料問題

- 找出重複 ID occurrenceID
- 新增欄位 basisOfRecord
- 內容錯誤或與欄位不符
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- 學名比對&清理 scientificName
- 修正學名格式 ^[A-Z].*\s[A-Z]
- 清除多餘空格 country
- 找出相似文字並合併 County

用 OpenRefine 清資料- 找出重複 ID

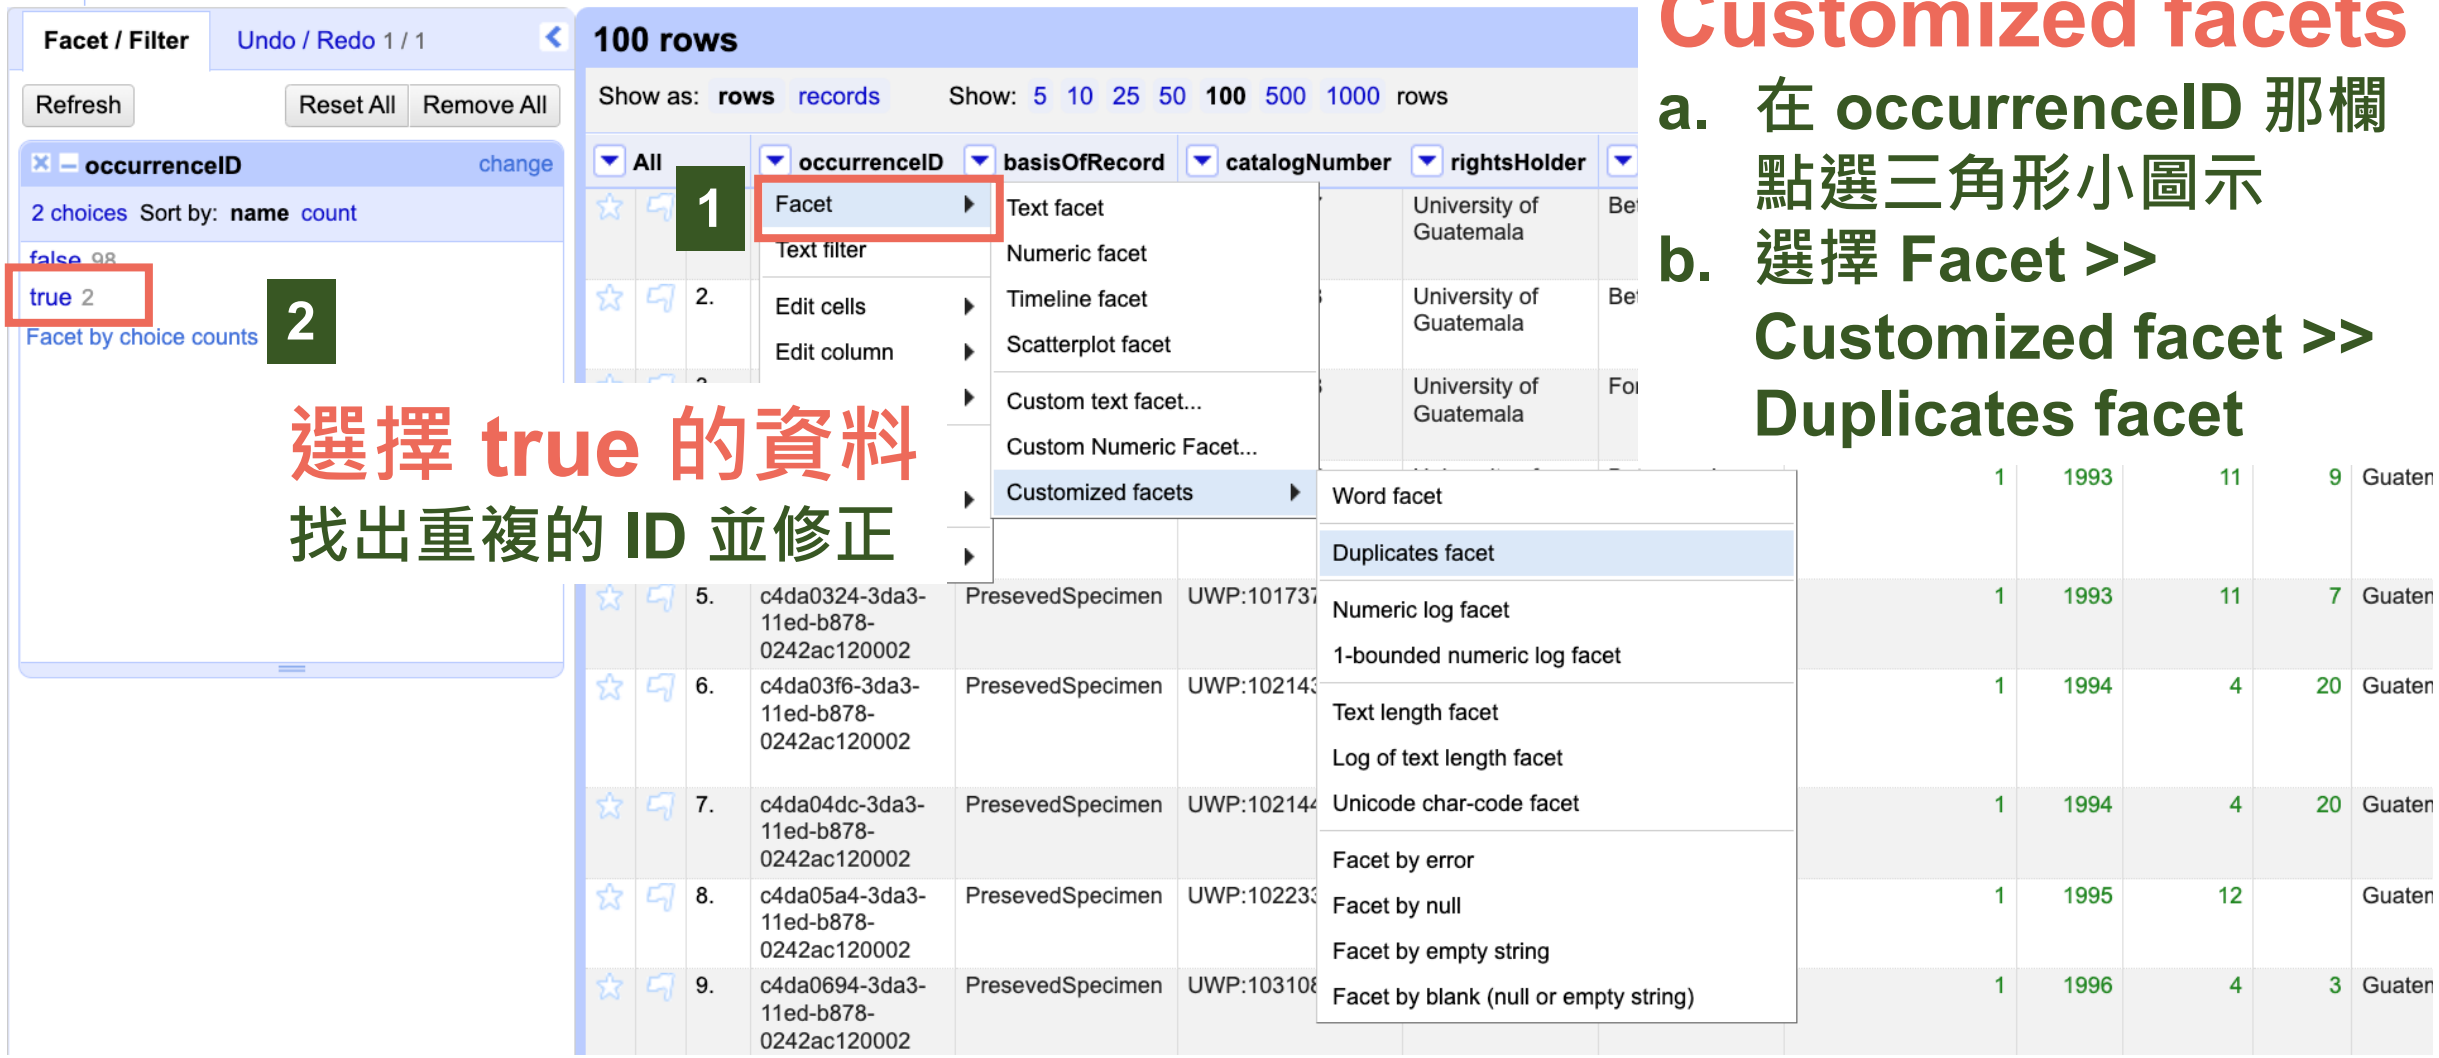

選擇 true 的資料

找出重複的 ID 並修正

Customized facets

a. 在 occurrenceID 那欄點選三角形小圖示

b. 選擇 Facet >> Customized facet >> Duplicates facet

案例練習- 進階作業

資料問題

- 找出重複 ID occurrenceID
- **新增欄位 basisOfRecord**
- 內容錯誤或與欄位不符
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- 學名比對&清理 scientificName
- 修正學名格式 ^[A-Z].*\s[A-Z]
- 清除多餘空格 country
- 找出相似文字並合併 County

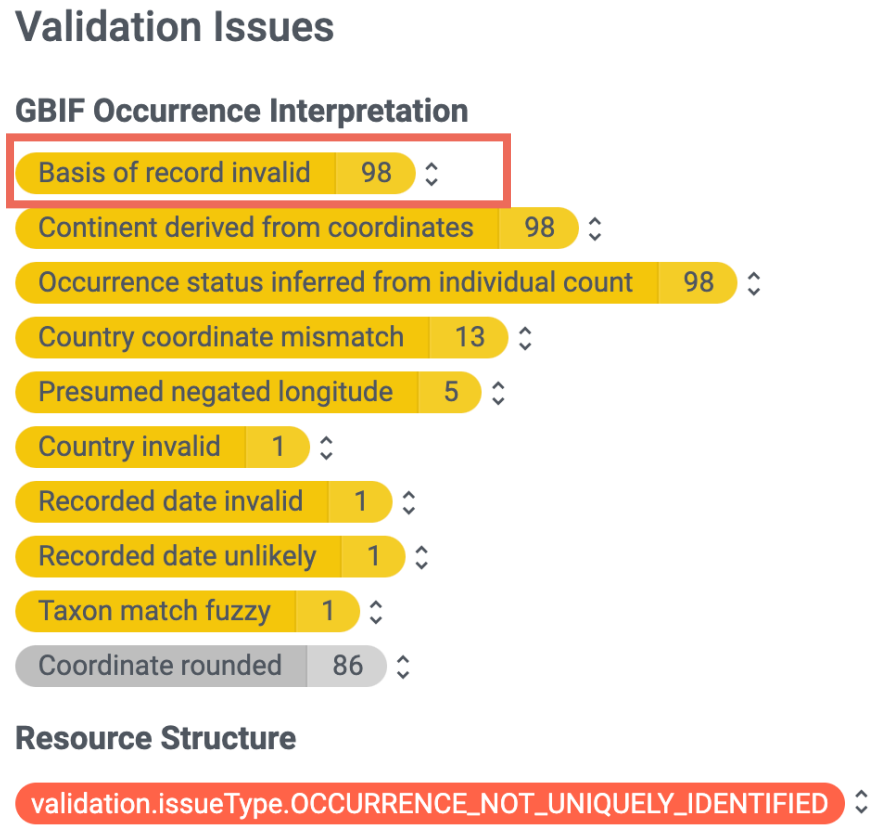

用 OpenRefine 清資料- 新增欄位

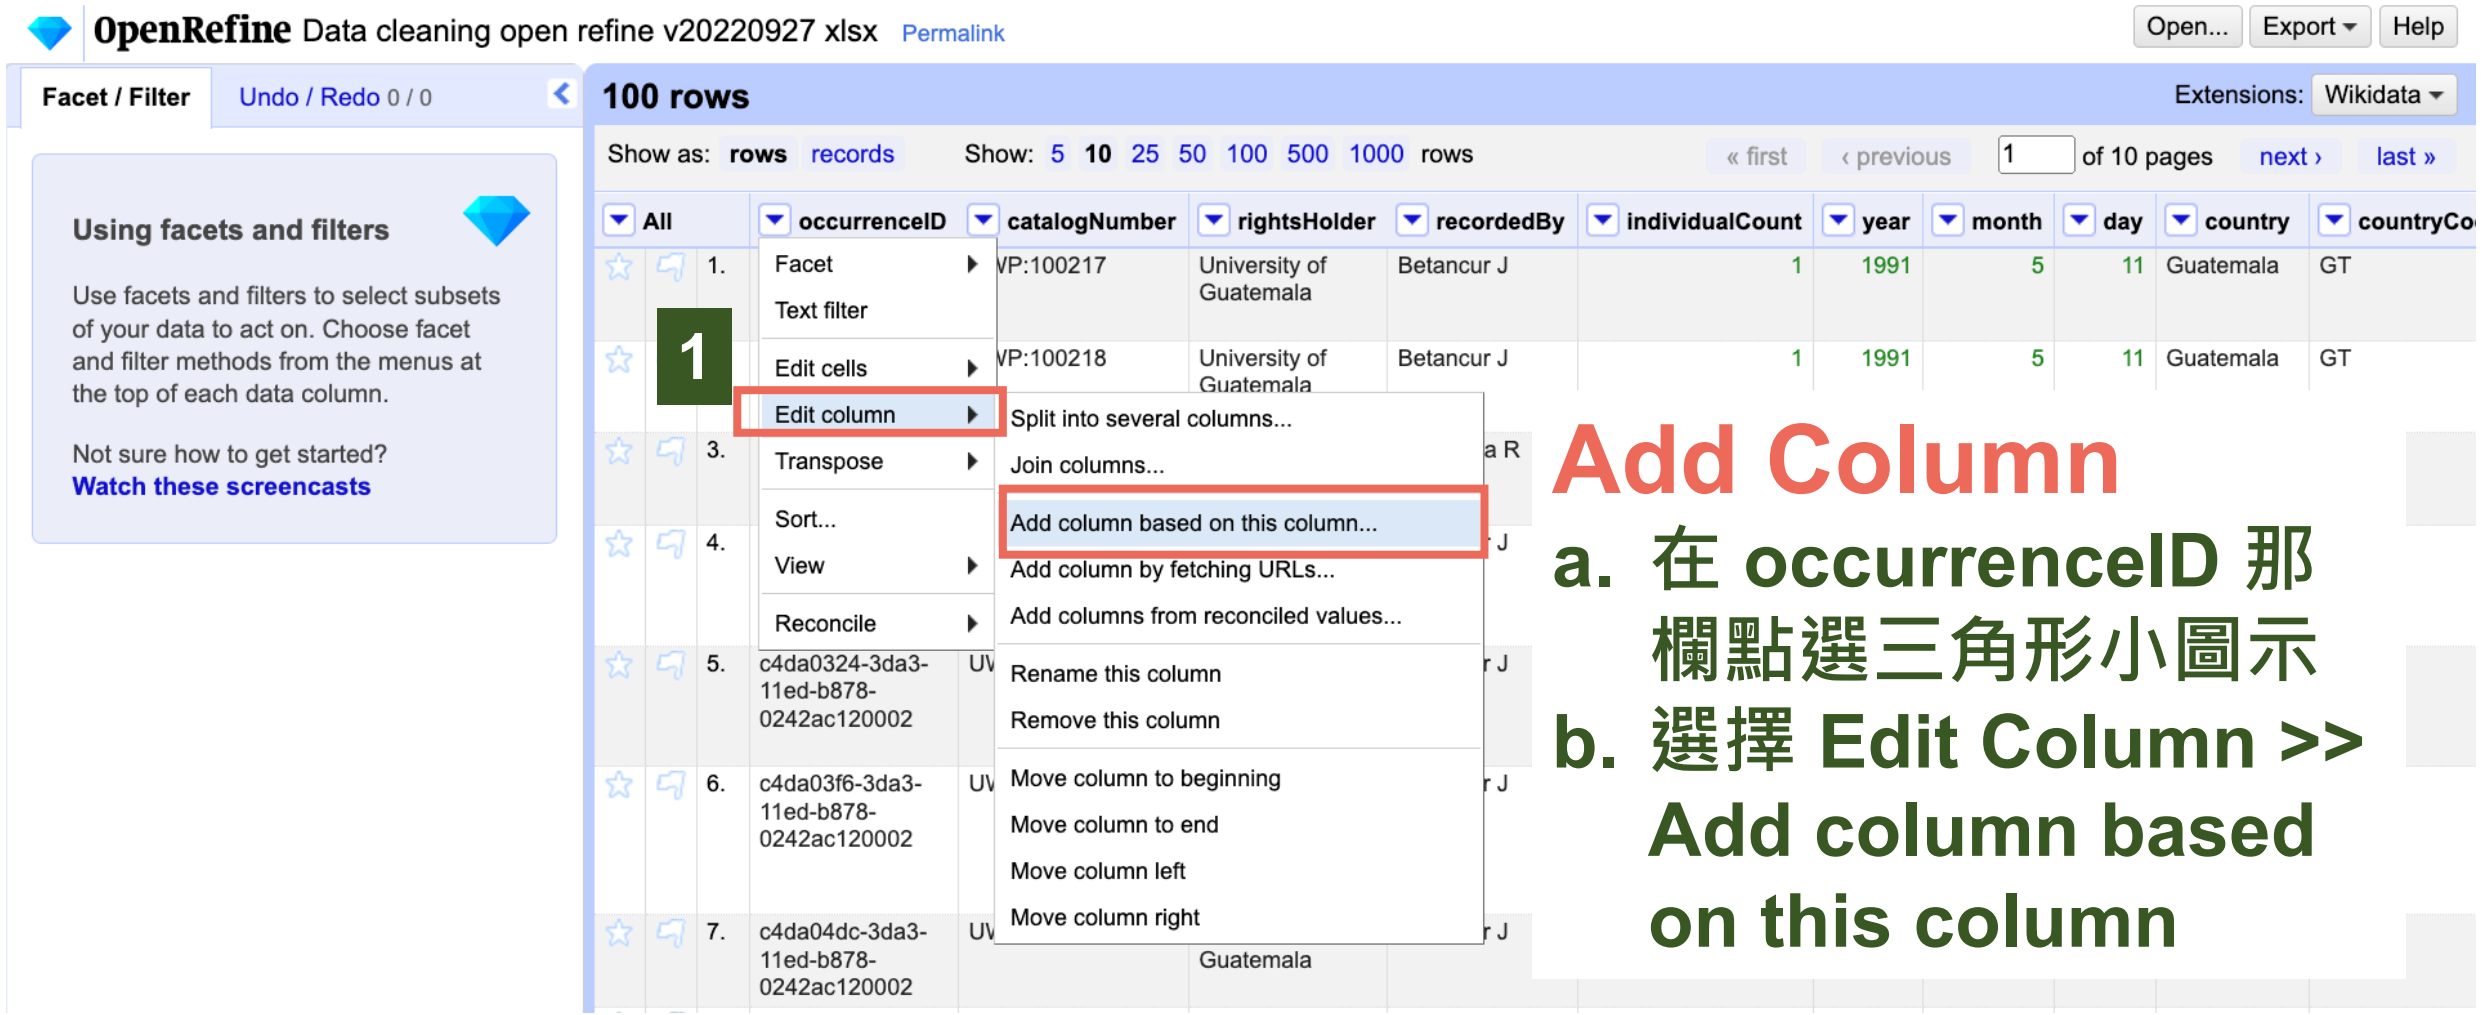

Add Column

a. 在 occurrenceID 那欄點選三角形小圖示
b. 選擇 Edit Column >> Add column based on this column

用 OpenRefine 清資料- 新增欄位

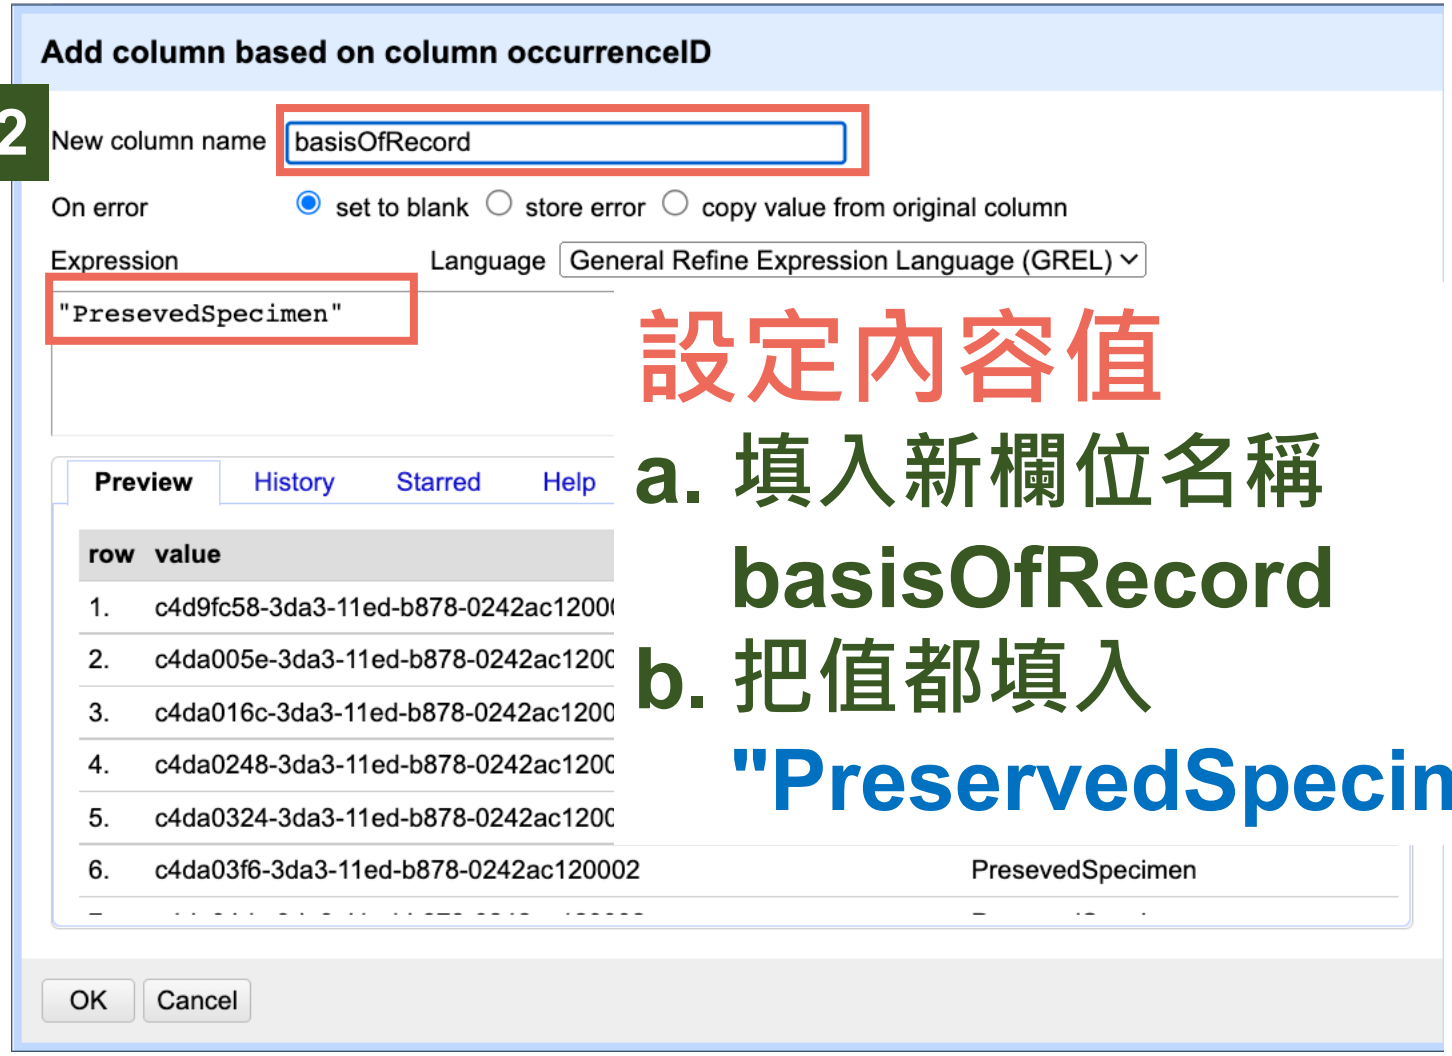

設定內容值

a. 填入新欄位名稱 basisOfRecord

b. 把值都填入 "PreservedSpecimen"

案例練習- 進階作業

資料問題

- 找出重複 ID occurrenceID
- 新增欄位 basisOfRecord
- **內容錯誤或與欄位不符**
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- 學名比對&清理 scientificName
- 修正學名格式 ^[A-Z].*\s[A-Z]
- 清除多餘空格 country
- 找出相似文字並合併 County

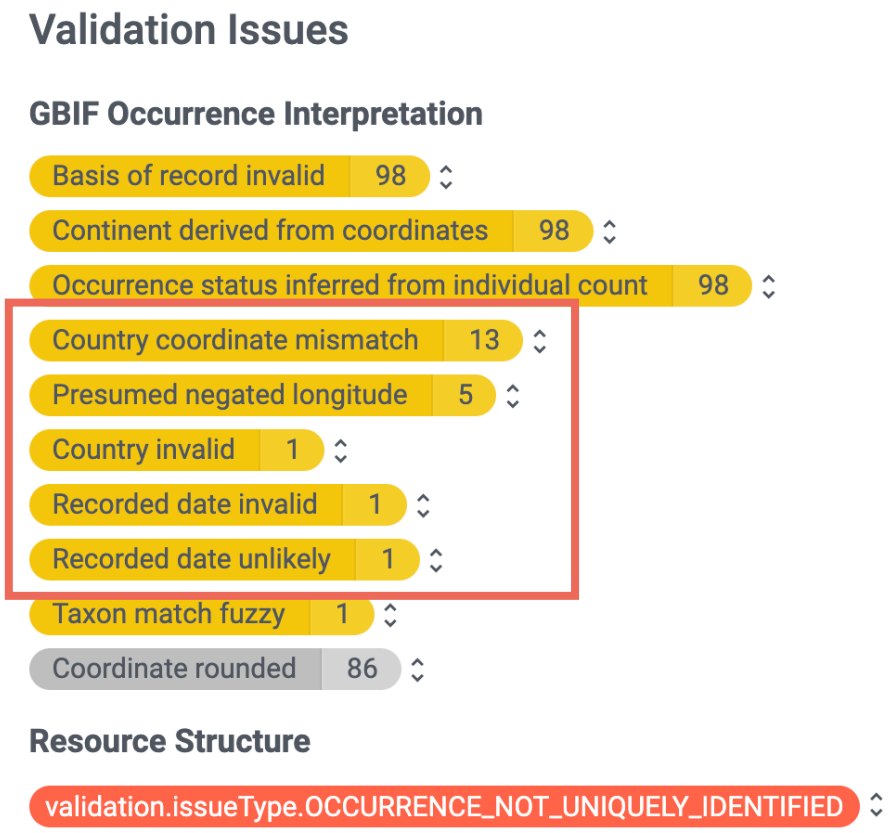

案例練習- 進階作業

資料問題

Country coordinate mismatch 13

座標和國家不符

recordId	dwc:decimalLatitude	dwc:decimalLongitude	dwc:geodeticDatum	dwc:country	dwc:cour
c4da5630-3da3-11ed-b878-0242ac120002	17.563668	0.10294211	WGS84	Guatemala	GT
c4da05a4-3da3-11ed-b878-0242ac120002	5° 35' 12" N	75° 46' 18" W	WGS84	Guatemala	GT
c4da20d4-3da3-11ed-b878-0242ac120002	7° 18' 10.12" N	75° 04' 25.03" W	WGS84	Guatemala	GT

用 OpenRefine 清資料- 內容錯誤(座標)

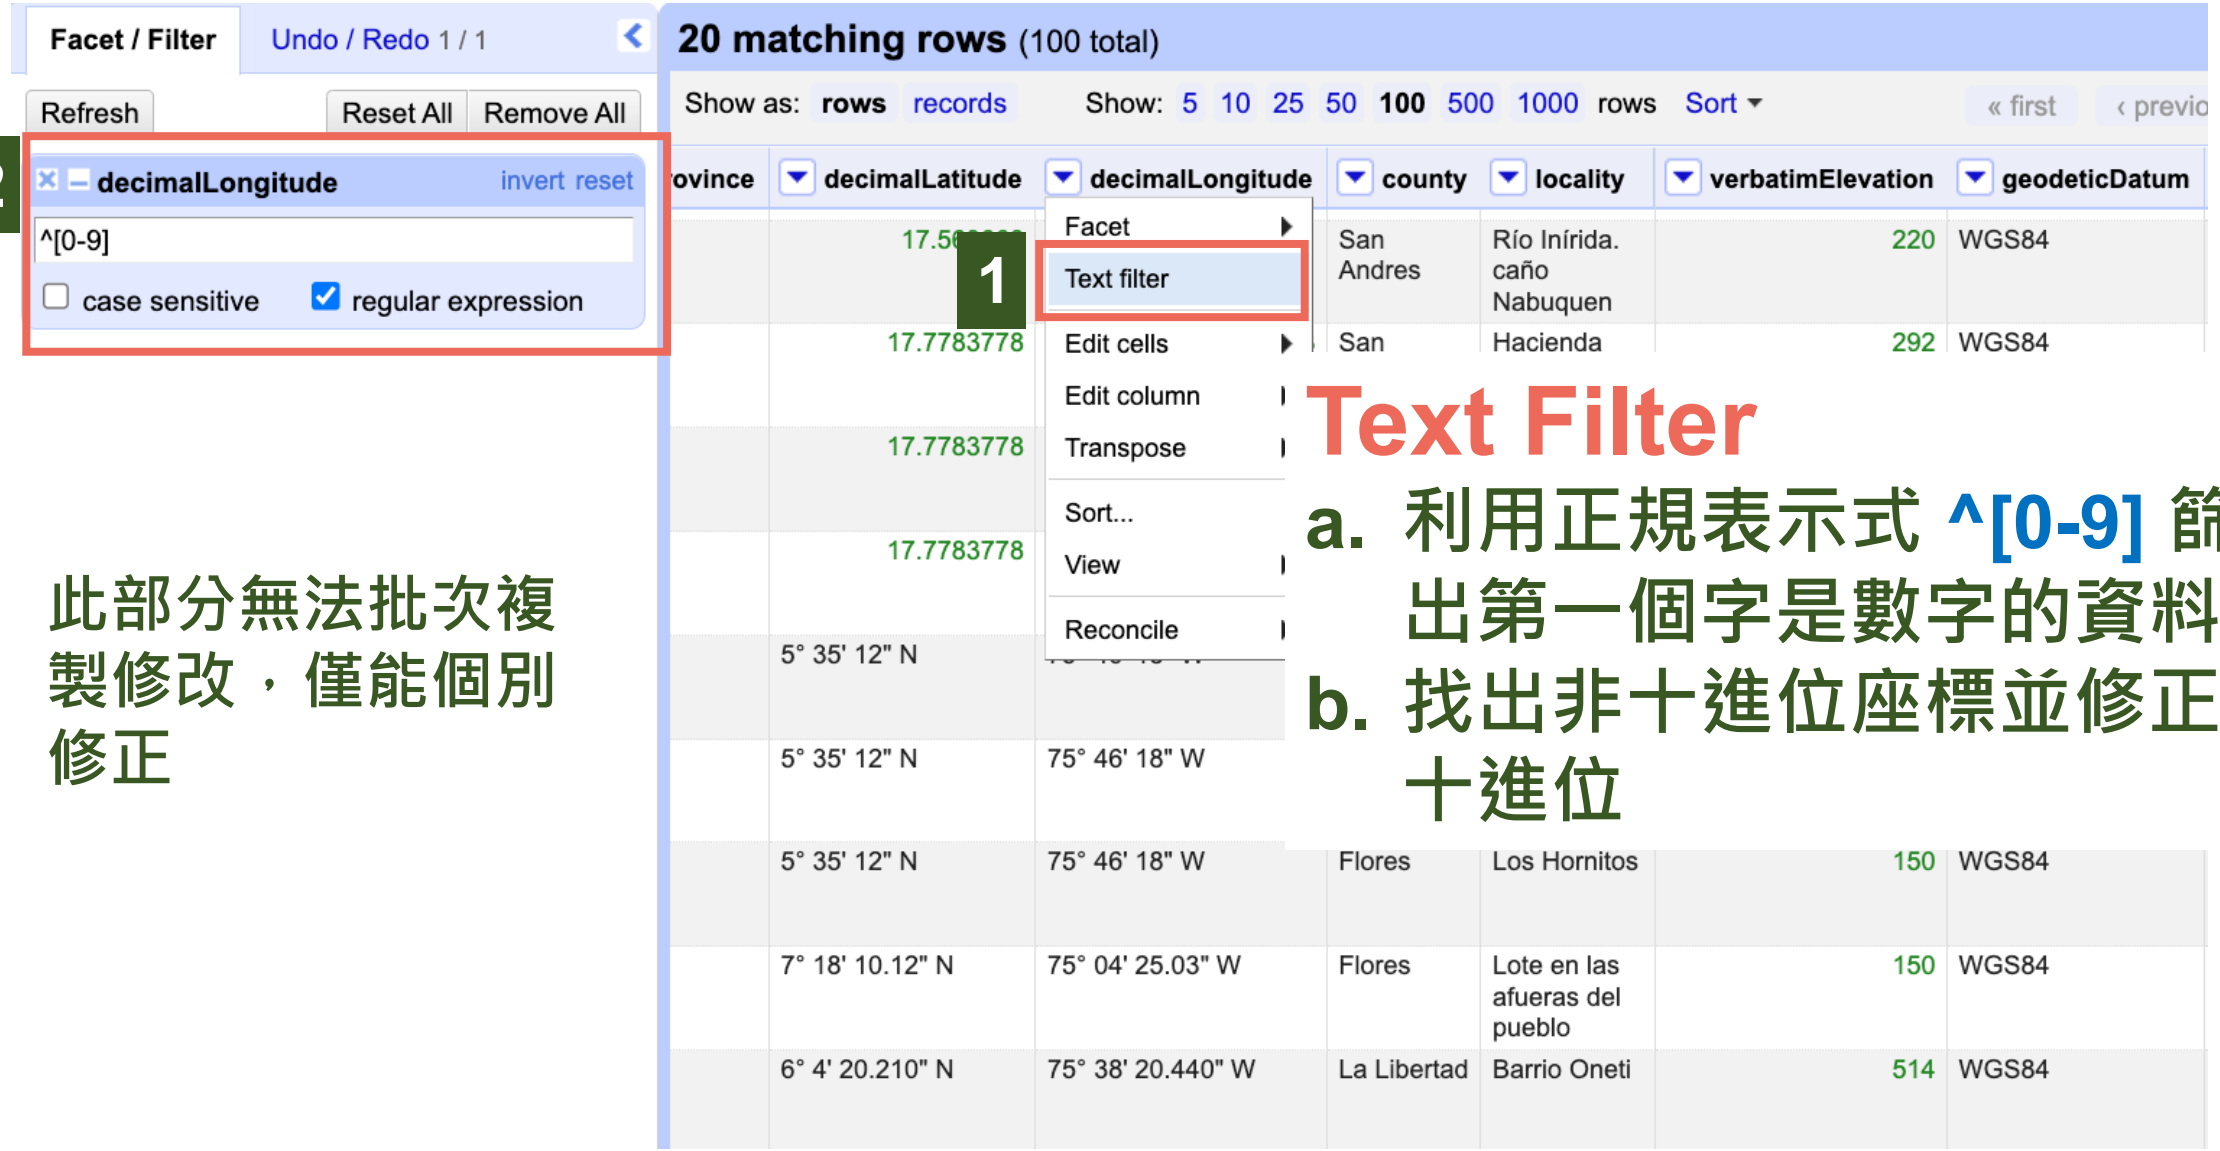

此部分無法批次複製修改，僅能個別修正

Text Filter

a. 利用正規表示式 ^[0-9] 篩選出第一個字是數字的資料
b. 找出非十進位座標並修正成十進位

用 OpenRefine 清資料- 內容錯誤(座標)

Coordinate conversion

Use this tool to convert geographic coordinates from DDMMSS to decimal degrees. Type coordinate pairs on separate lines or paste la
longitude columns from a spreadsheet. Each row may be optionally preceded by an identifier followed by a pipe or tab.

1

5° 35' 12" N, 75° 46' 18" W

貼上座標並按Submit

Canadensys

Coordinate conversion

利用座標轉換工具，將度分秒的座標格式換成十進位

Coordinate conversion results

original	decimalLatitude	decimalLongitude
5° 35' 12" N, 75° 46' 18" W	5.5866667	-75.7716667

案例練習- 進階作業

資料問題

推定經度應為負值

Presumed negated longitude 5

recordId	dwc:decimalLatitude	dwc:decimalLongitude
c4da1594-3da3-11ed-b878-0242ac120002	17.7783778	90.84424953
c4da4f50-3da3-11ed-b878-0242ac120002	17.7783778	90.84424953
c4da21a6-3da3-11ed-b878-0242ac120002	17.7783778	90.84424953
c4da5b26-3da3-11ed-b878-0242ac120002	17.2160555	89.50767314
c4da499c-3da3-11ed-b878-0242ac120002	17.4114231	90.18308898

用 OpenRefine 清資料- 內容錯誤(座標)

Text Filter

a. 利用正規表示式 ^[0-9] 篩選出第一個字是數字的資料

b. 再從此篩選結果點選 Text Facet，找出那幾筆錯誤的十進位座標並修正成負值

案例練習- 進階作業

資料問題

國家代碼無效

Country invalid 1

recordId	dwc:country	dwc:countryCode
c4da28ea-3da3-11ed-b878-0242ac120002	Guatemala	17.3857972

用 OpenRefine 清資料- 內容錯誤(countryCode)

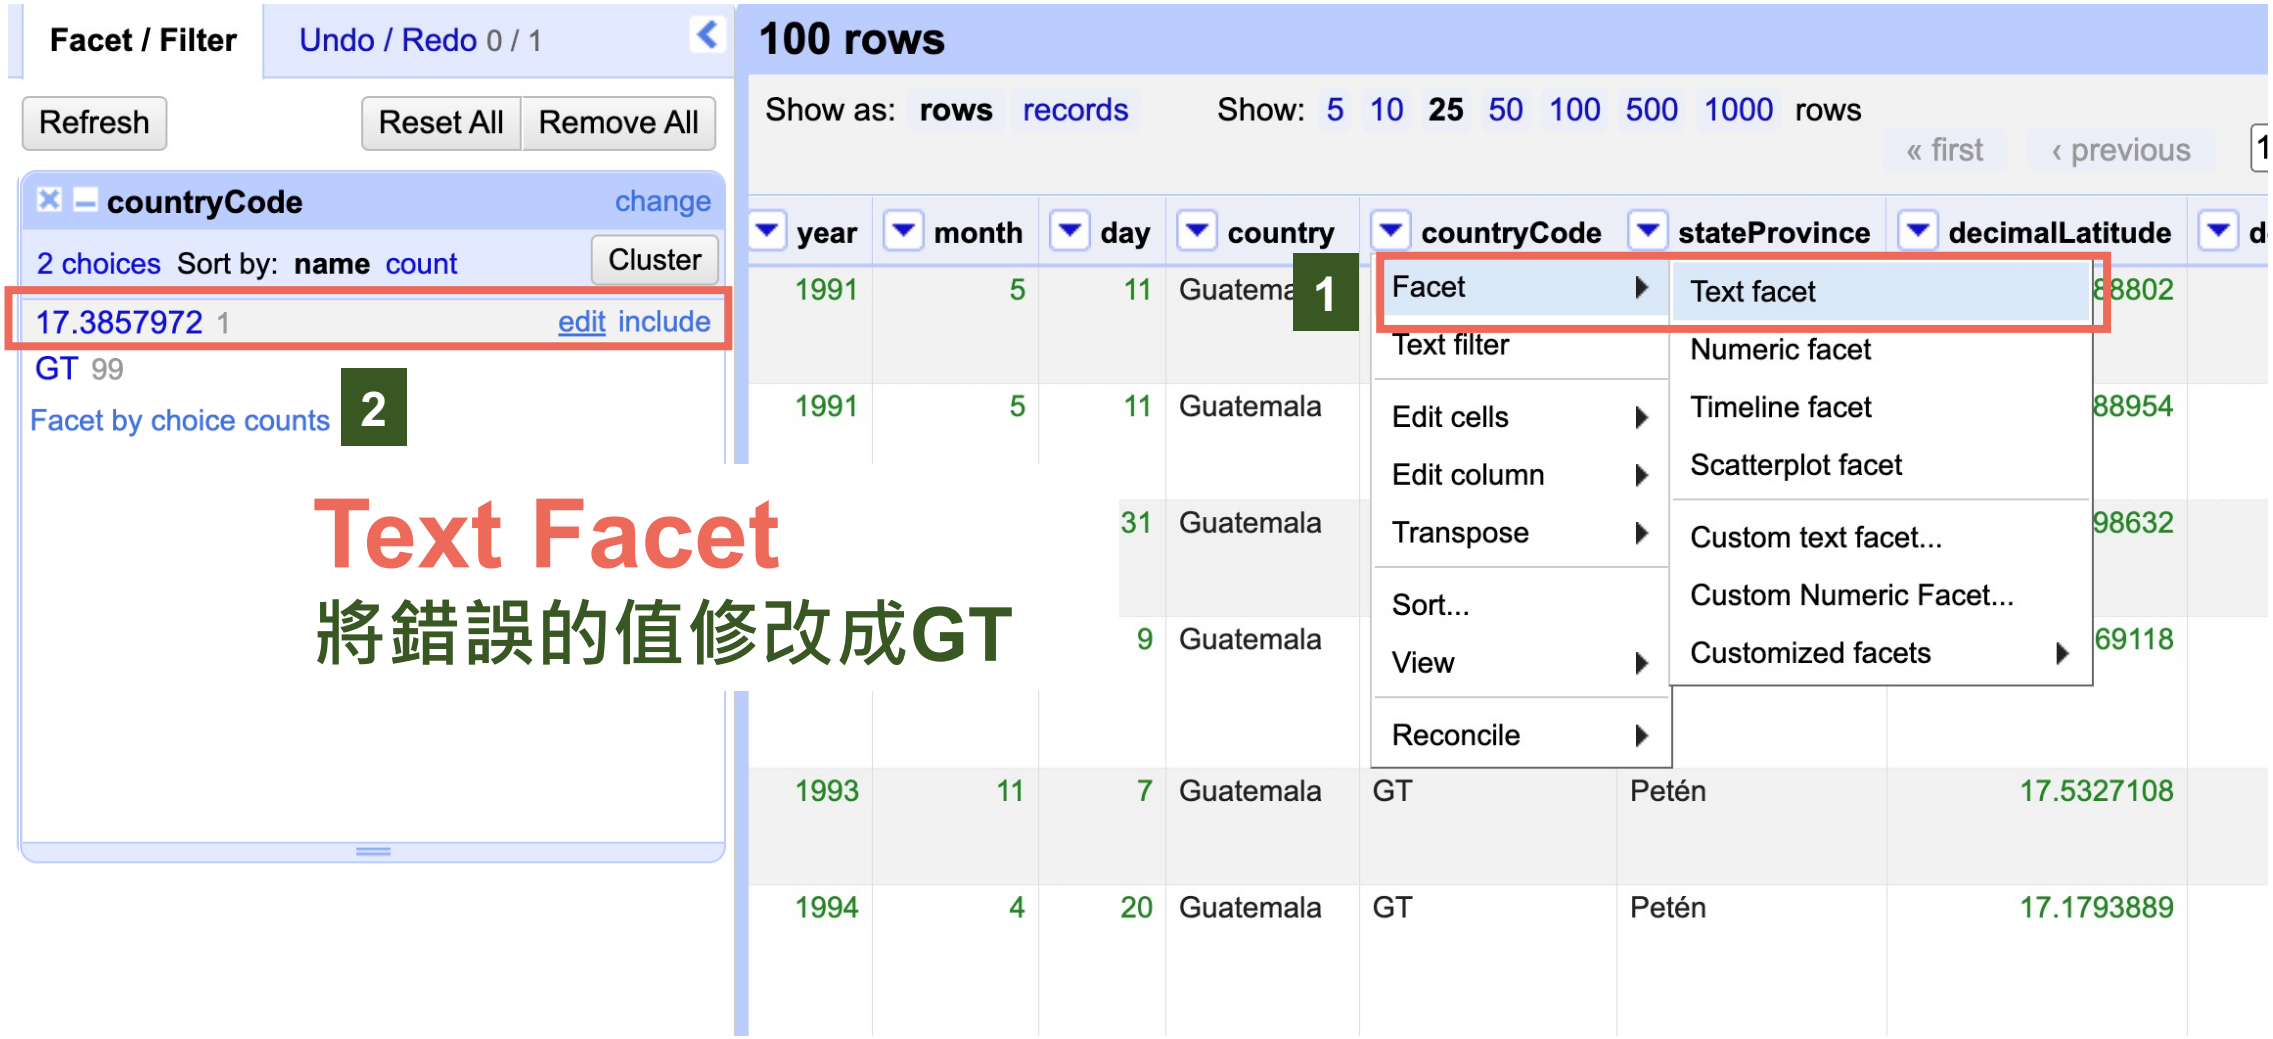

Text Facet

將錯誤的值修改成GT

案例練習- 進階作業

資料問題

- 找出重複 ID occurrenceID
- 新增欄位 basisOfRecord
- 內容錯誤或與欄位不符
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- **學名比對&清理 scientificName**
- 修正學名格式 ^[A-Z].*\s[A-Z]
- 清除多餘空格 country
- 找出相似文字並合併 County

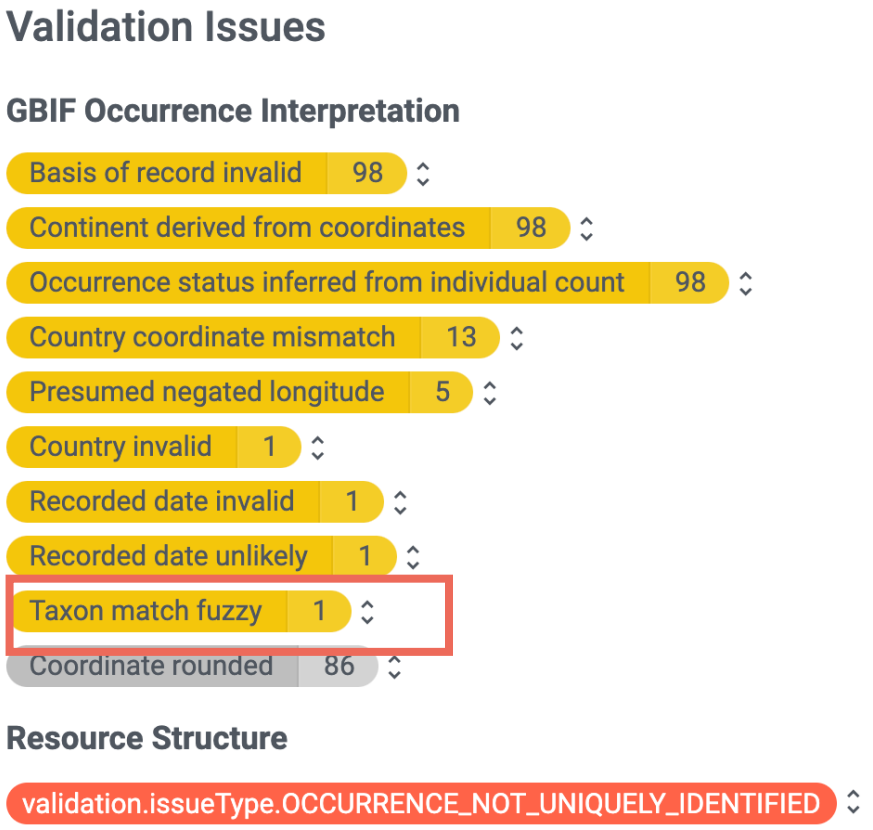

用 OpenRefine 清資料- 學名比對

Taxon match fuzzy 1

分類未對應 GBIF backbone

recordId	dwc:genus	dwc:class	dwc:phylum	dwc:scientificNameAuthorship	
c4da38bc-3da3-11ed-b878-0242ac120002	Paepalanthus	Equisetopsida	Magnoliophyta	(Körn.) Tissot-Squalli	

用 OpenRefine 清資料- 學名比對

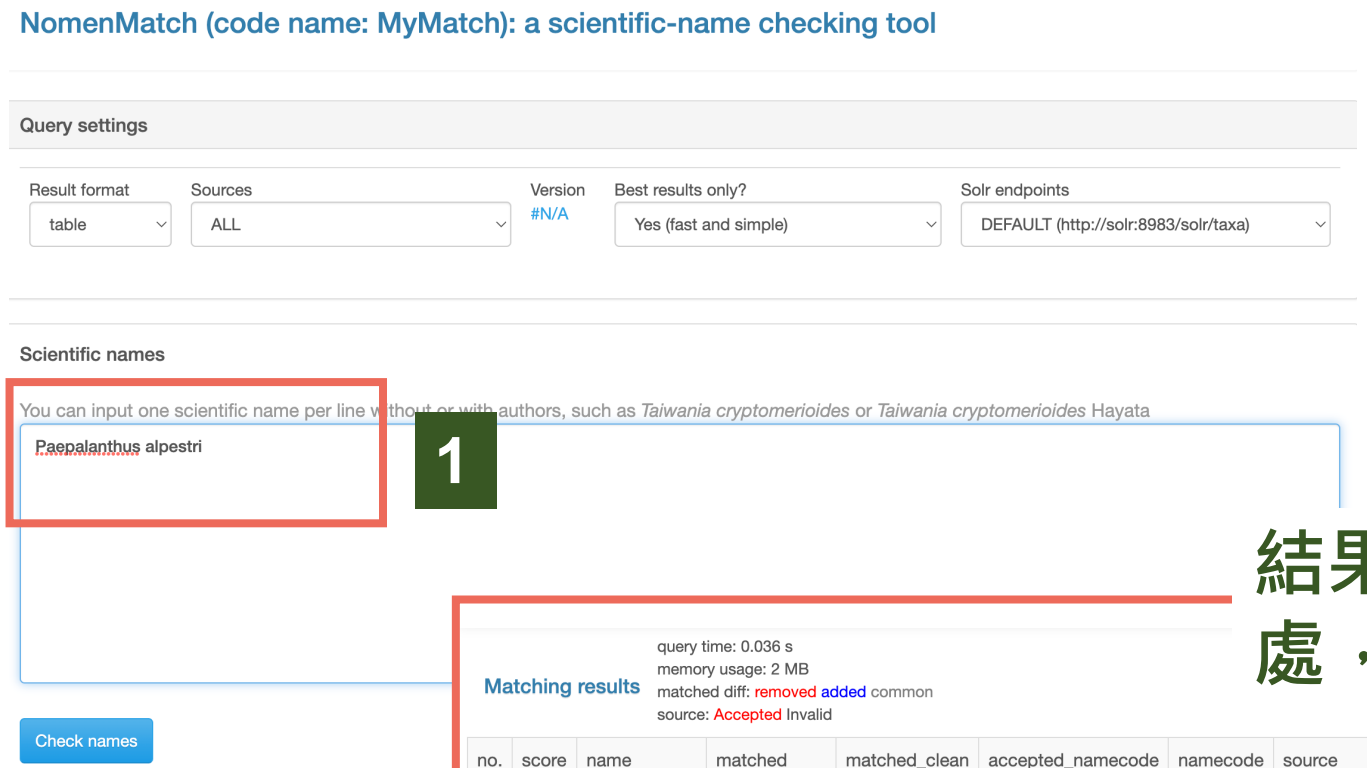

NomenMatch

將有問題的學名貼上按 **Check names**

結果會顯示與有效學名差異之處，以及比對吻合度的分數

Matching results

query time: 0.036 s
memory usage: 2 MB
matched diff: removed added common
source: Accepted Invalid

no.	score	name	matched	matched_clean	accepted_namecode	namecode	source	family	higher_than_family	type	best
1	0.968	Paepalanthus alpestri	Paepalanthus alpestris (Körn.) M.L.Tissot-Squalli H Paepalanthus alpestris (Körn.) M.L.Tissot-Squalli H	Paepalanthus alpestris	8963029.0 8963029 4BYFH	5287145 8963029 4BYFH	gbif_backbone_txn gbif_backbone_txn col	Eriocaulaceae Eriocaulaceae	Poales-Liliopsida-Tracheophyta-Plantae Poales-Liliopsida-Tracheophyta-Plantae ---	Full match with minor error in species or infra-species	gbif_backbone_txn:8963029 col:4BYFH

用 OpenRefine 清資料- 學名比對

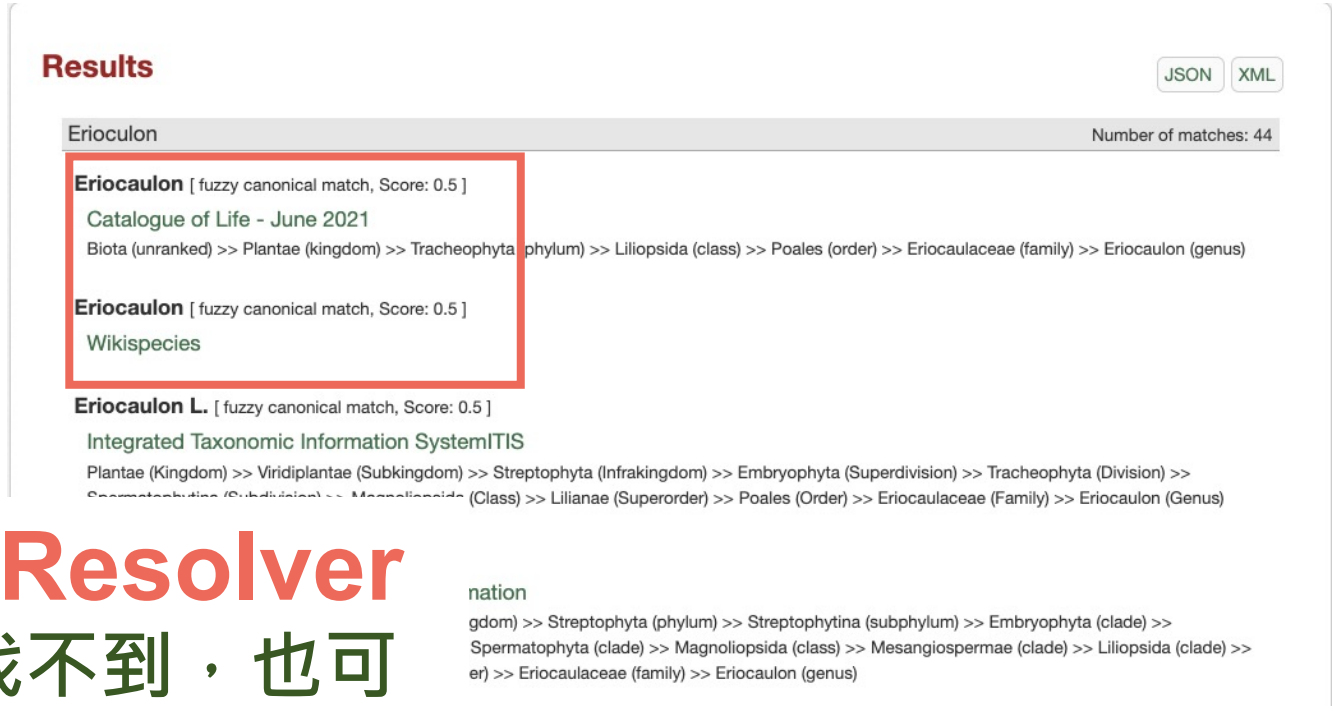

Global Names Resolver

如果NomenMatch找不到，也可以用這個比對看看

用 OpenRefine 清資料- 學名清理

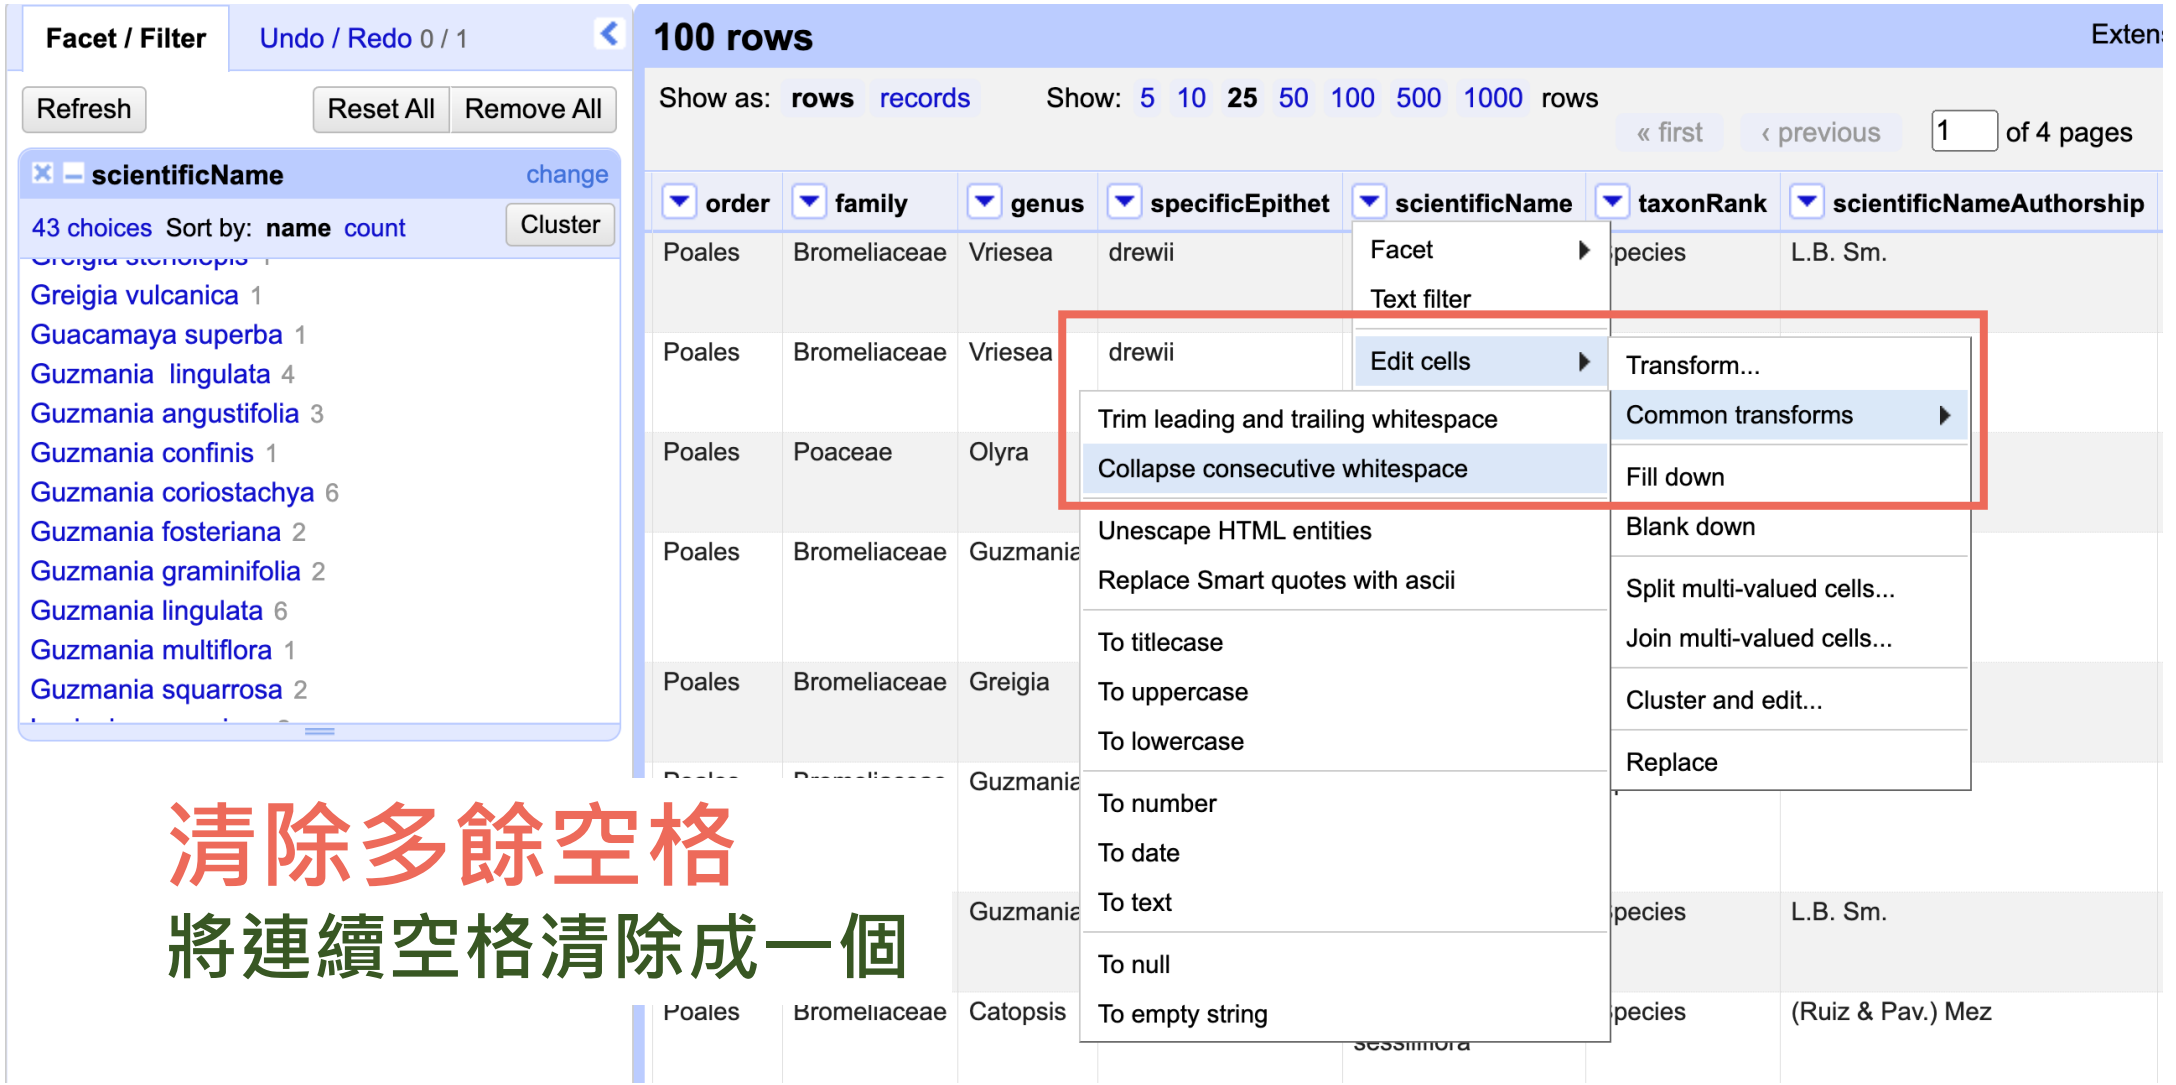

清除多餘空格

將連續空格清除成一個

案例練習- 進階作業

資料問題

- 找出重複 ID occurrenceID
- 新增欄位 basisOfRecord
- 內容錯誤或與欄位不符
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- 學名比對&清理 scientificName
- **修正學名格式 ^[A-Z].*\s[A-Z]**
- 清除多餘空格 country
- 找出相似文字並合併 County

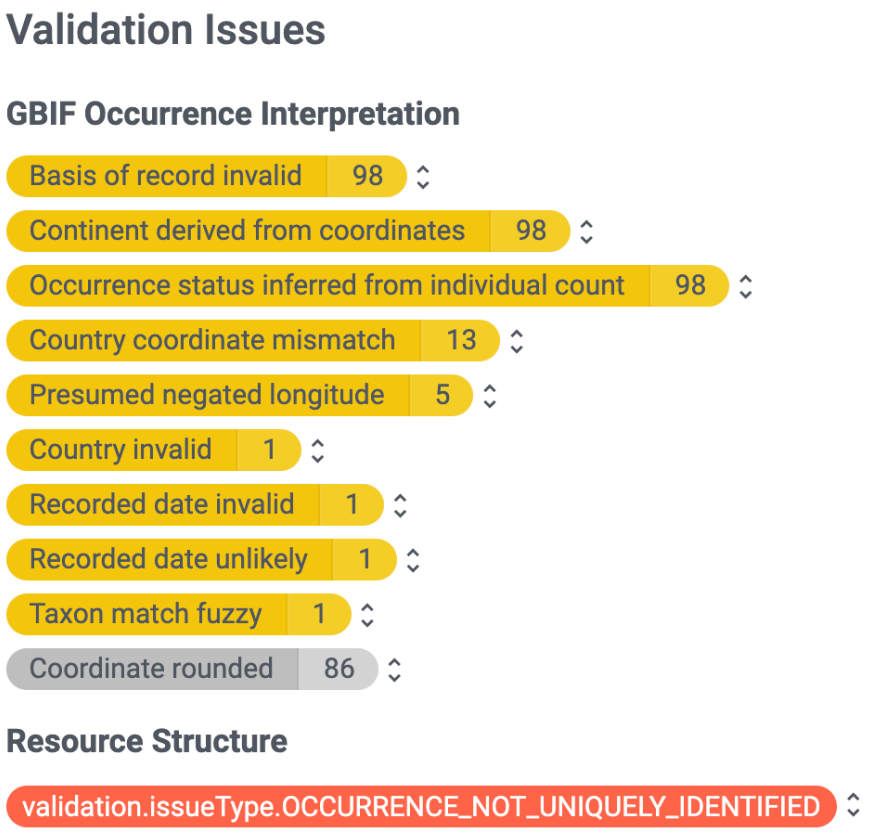

用 OpenRefine 清資料- 修正學名格式

記得下面兩個選項要打勾

Text Filter

a. 利用正規表示式 ^[A-Z].*\s[A-Z] 篩選出第一個字開頭是大寫字母，同時第二個字開頭也是大寫字母的資料

用 OpenRefine 清資料- 修正學名格式

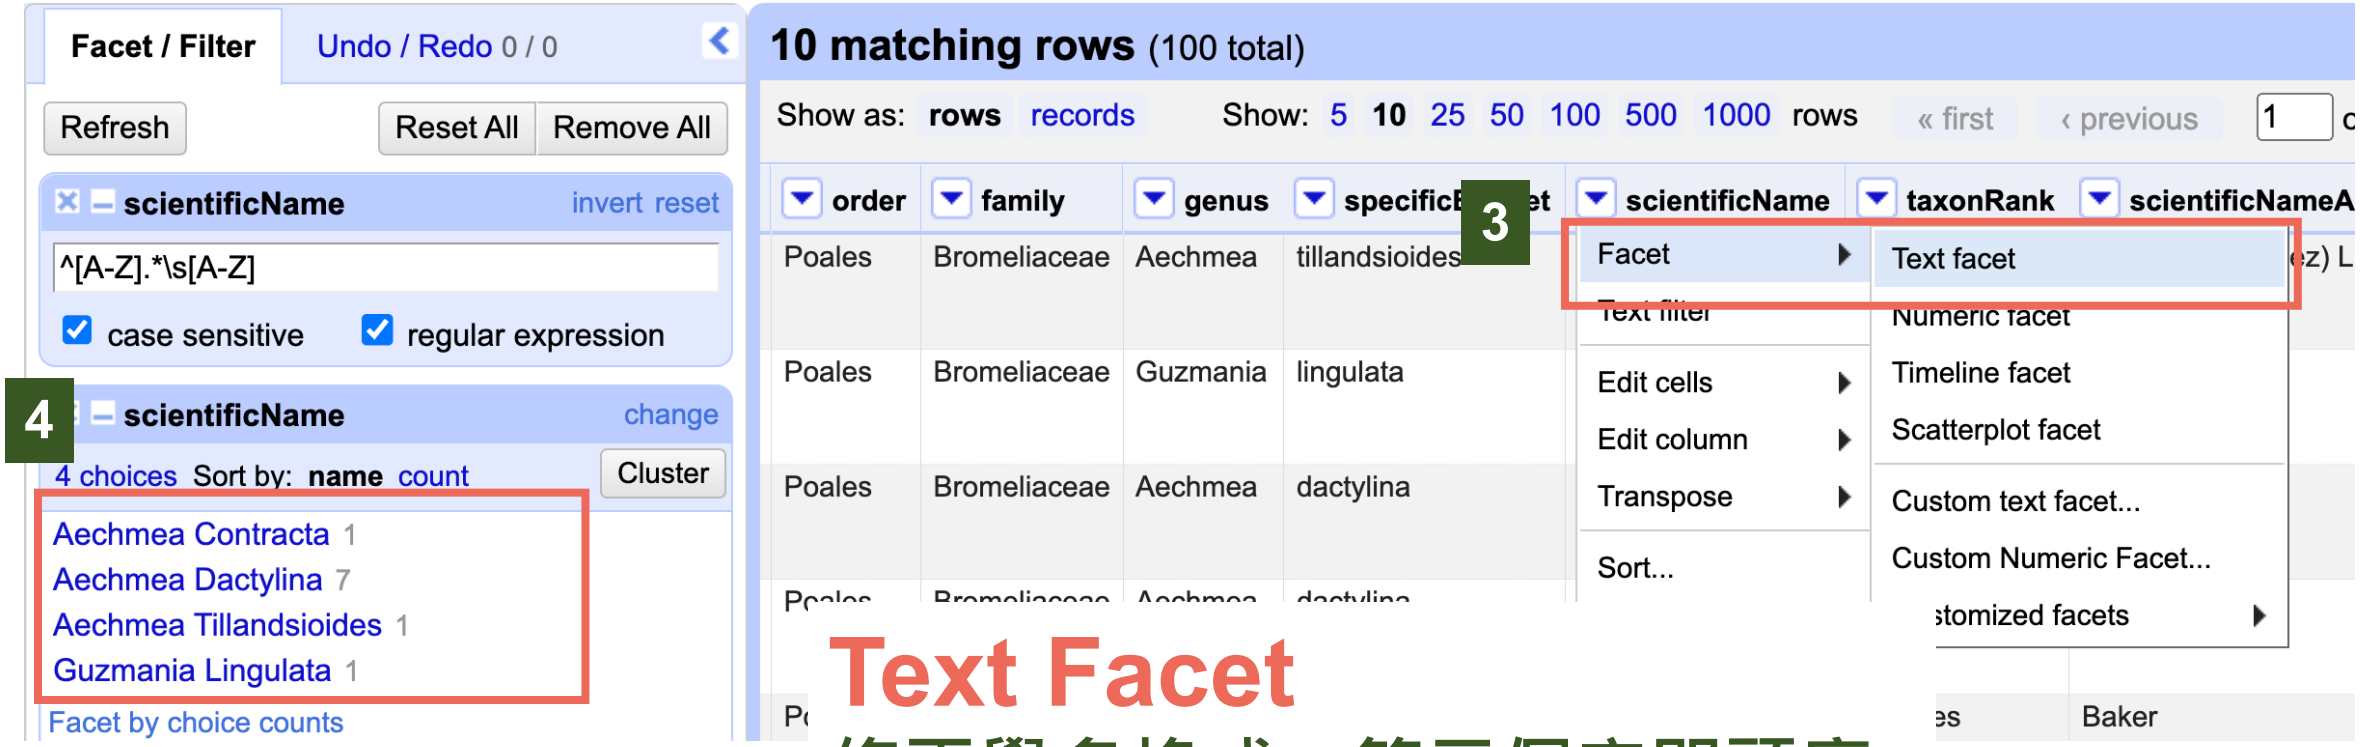

可以批次修改

Text Facet

修正學名格式，第二個字開頭應為小寫字母

用 OpenRefine 清資料- 修正學名格式

記得下面兩個選項要打勾

Text Filter

1. 利用正規表示式 ^[a-z].*\s[a-z] 篩選出第一個字開頭是小寫字母，同時第二個字開頭也是小寫字母的資料
2. 將第一個字開頭修正為大寫

案例練習- 進階作業

資料問題

- 找出重複 ID occurrenceID
- 新增欄位 basisOfRecord
- 內容錯誤或與欄位不符
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- 學名比對&清理 scientificName
- 修正學名格式 ^[A-Z].*\s[A-Z]
- **清除多餘空格 country**
- 找出相似文字並合併 County

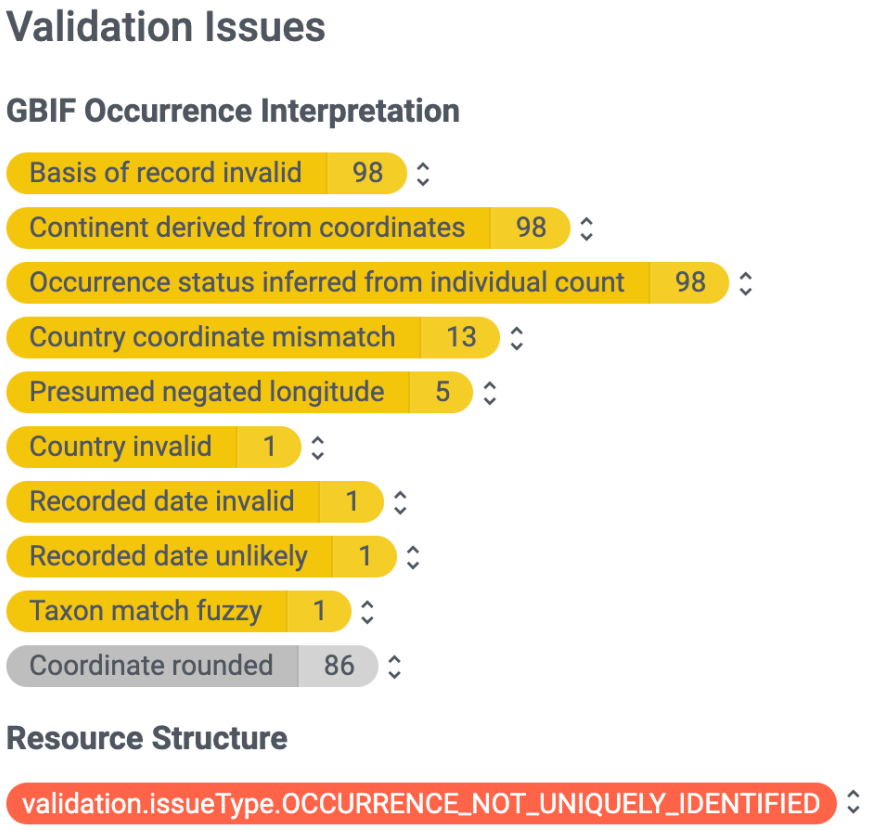

用 OpenRefine 清資料- 清除多餘空格2

清除多餘空格

a. 選擇 Country 那欄
b. 點選 Edit cells >> Common transforms >> Trim leading and trailing whitespace
c. 將文字前後的多餘空格去除

案例練習- 進階作業

資料問題

- 找出重複 ID occurrenceID
- 新增欄位 basisOfRecord
- 內容錯誤或與欄位不符
  decimalLatitude, decimalLongitude, countryCode, country, day, year
- 學名比對&清理 scientificName
- 修正學名格式 ^[A-Z].*\s[A-Z]
- 清除多餘空格 country
- **找出相似文字並合併 county**

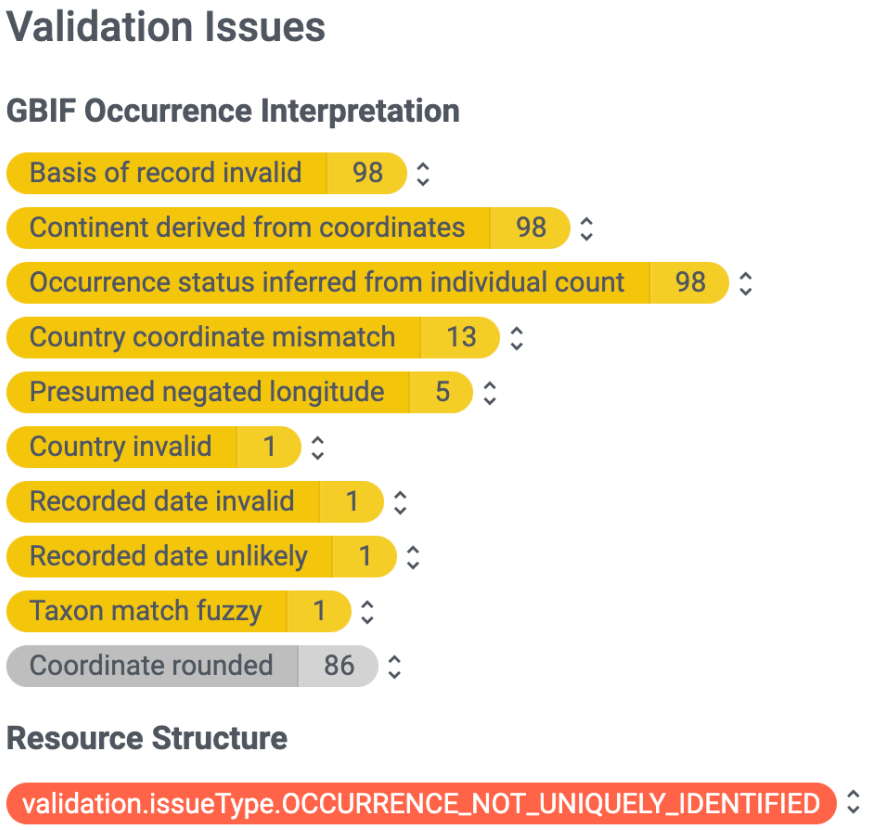

用 OpenRefine 清資料- 統一資料格式

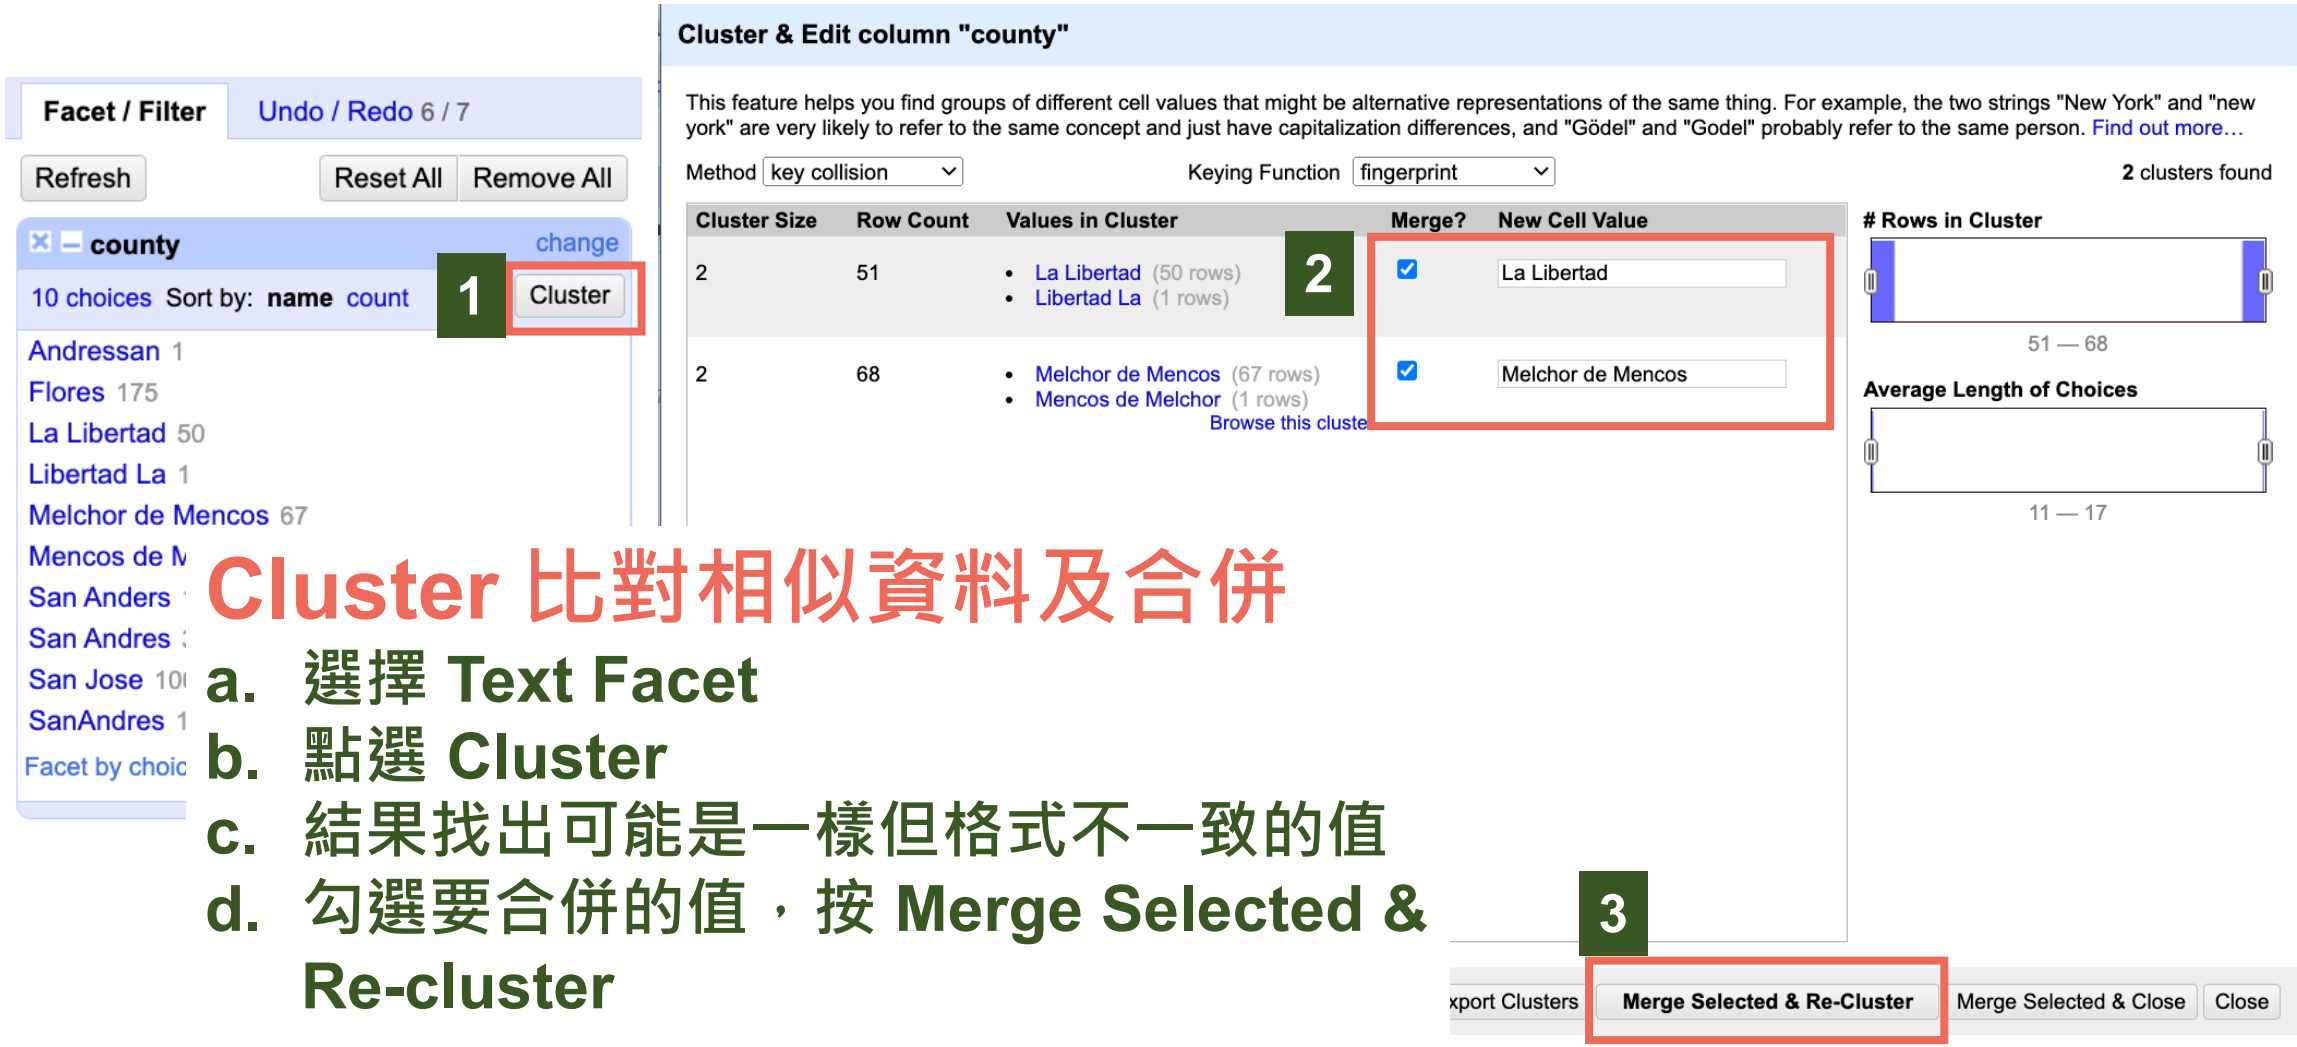

Cluster 比對相似資料及合併

a. 選擇 Text Facet
b. 點選 Cluster
c. 結果找出可能是一樣但格式不一致的值
d. 勾選要合併的值，按 Merge Selected & Re-cluster

進階題-自動匯入高階層分類欄位

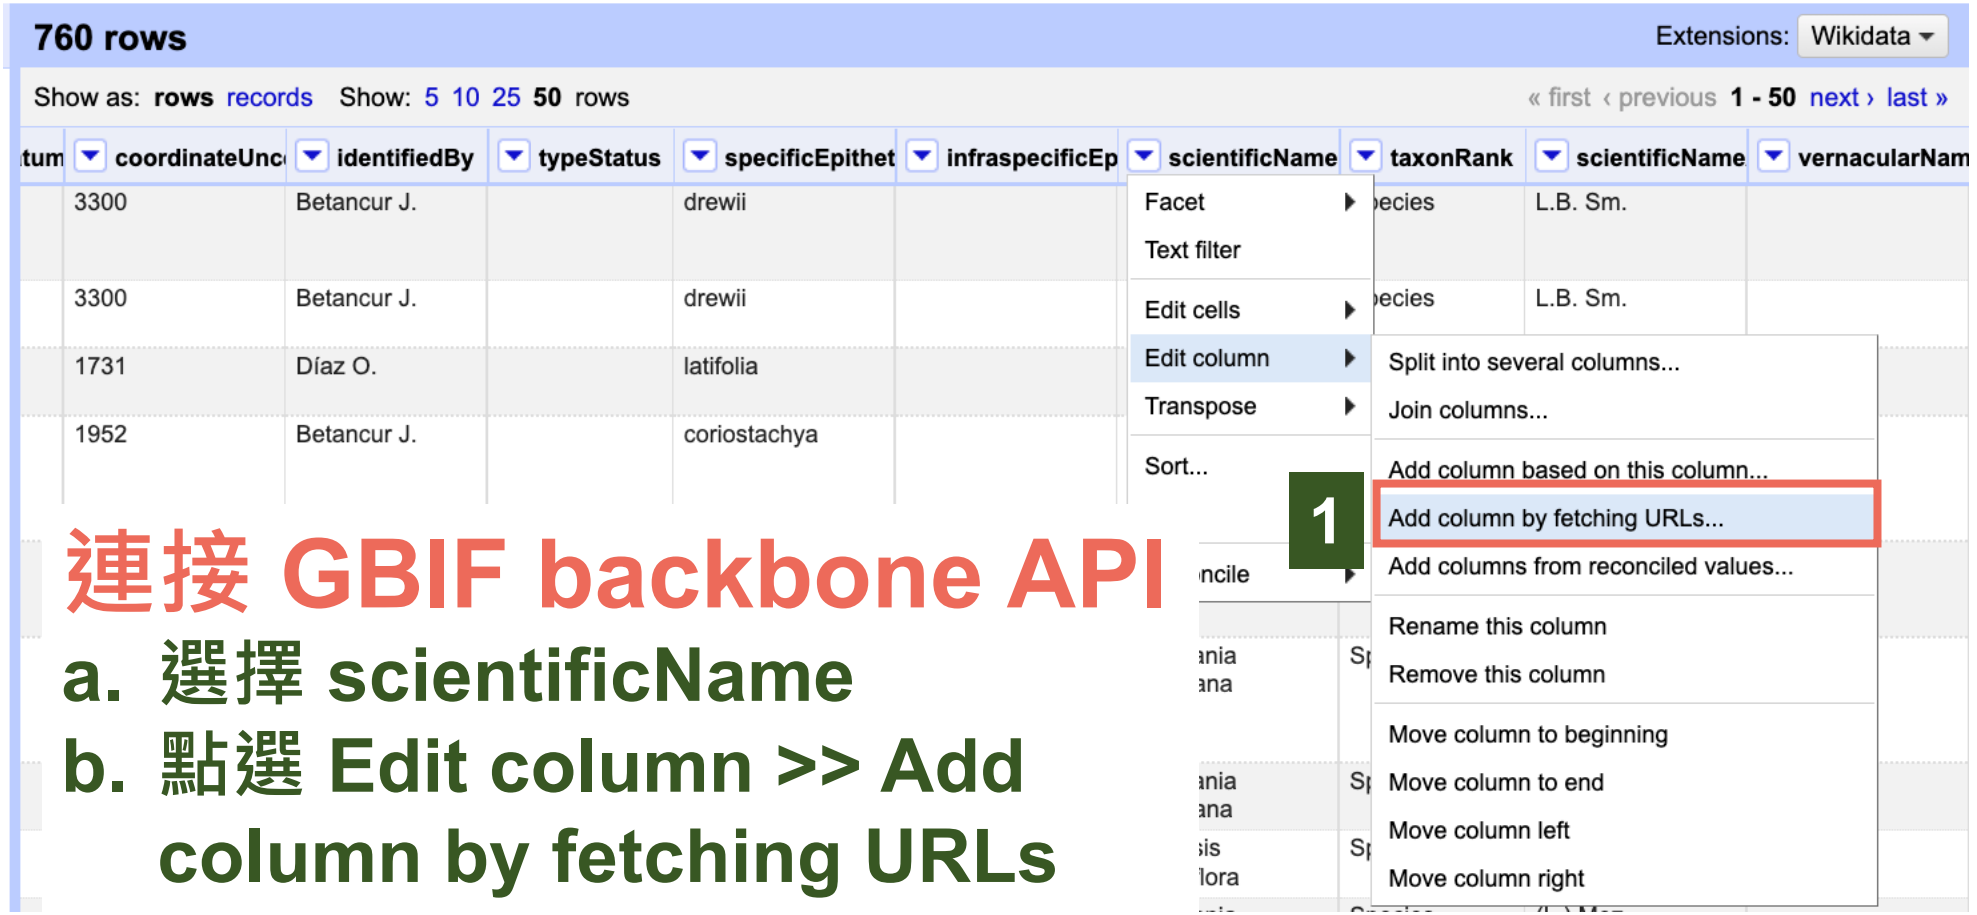

連接 GBIF backbone API

a. 選擇 scientificName
b. 點選 Edit column >> Add column by fetching URLs

進階題-自動匯入高階層分類欄位

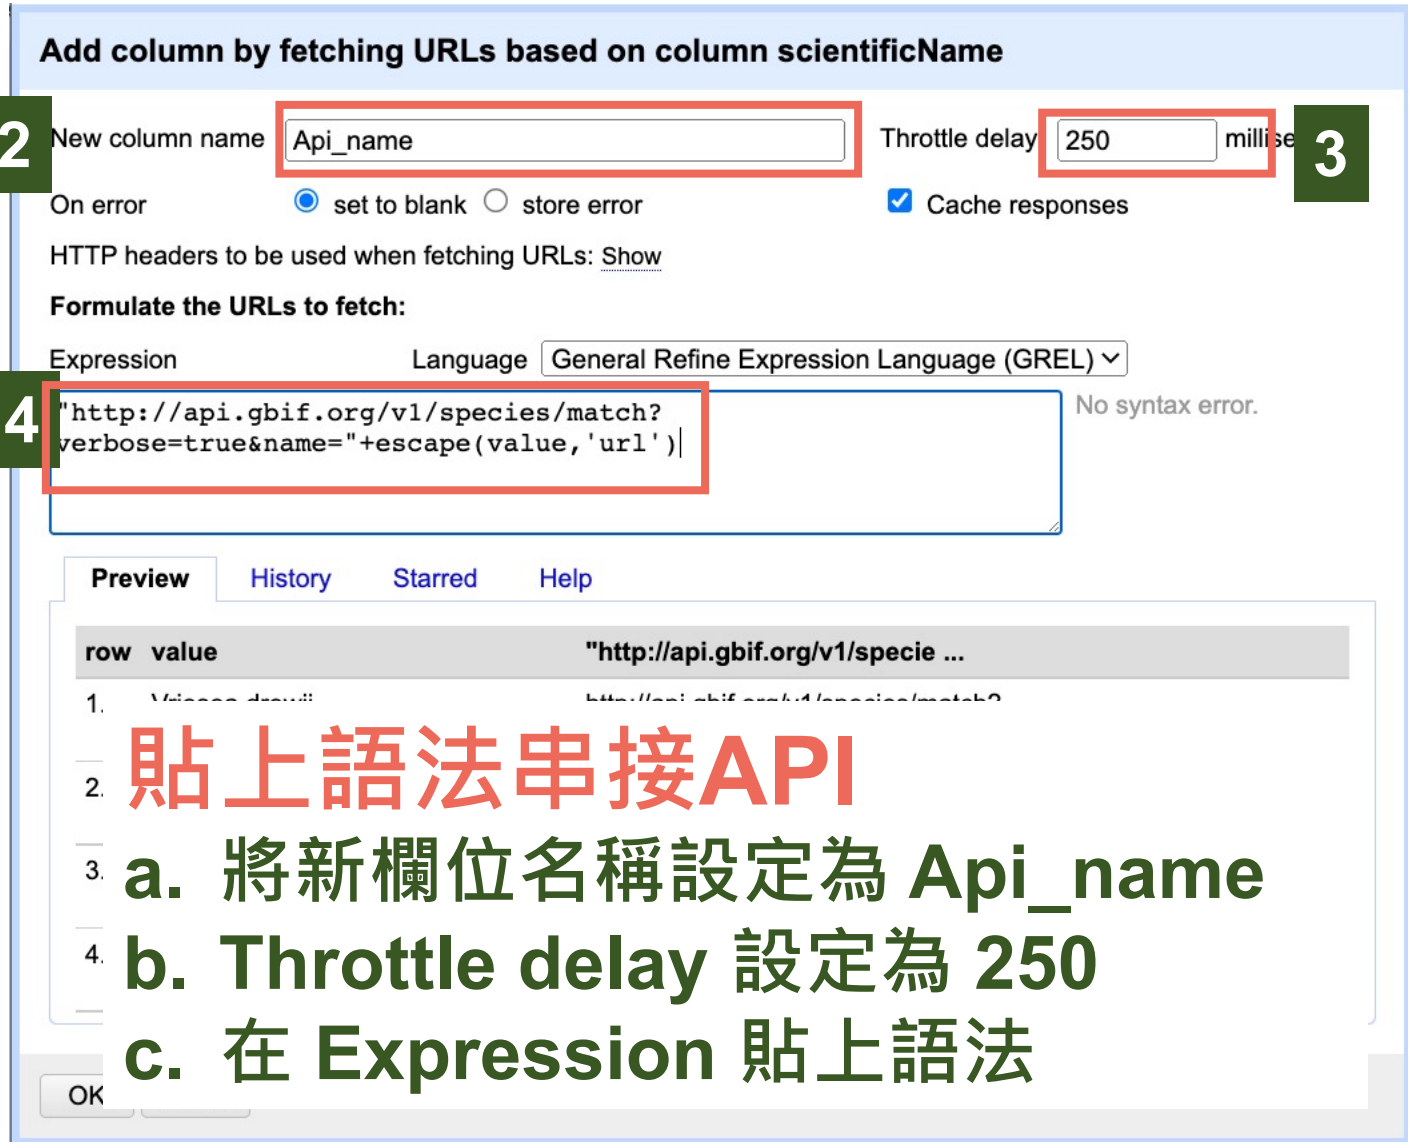

貼上語法串接API

a. 將新欄位名稱設定為 Api_name
b. Throttle delay 設定為 250
c. 在 Expression 貼上語法

語法在下一頁，
請整串複製貼上

進階題-自動匯入高階層分類欄位

語法在此，請整串複製貼上

"http://api.gbif.org/v1/species/match?verbose=true&name="+escape(value,'url')

進階題-自動匯入高階層分類欄位

呼叫各分類階層的值

a. 到 Api_name 欄位並選擇 Edit column >> Add column based on this column
b. 將新欄位名稱寫為 higherClassification
c. 貼上語法按 OK

語法在下一頁，請整串複製貼上

進階題-自動匯入高階層分類欄位

語法在此，請整串複製貼上

```
value.parseJson().get("kingdom")+", "+value.parseJson().get("phylum")+",
"+value.parseJson().get("class")+", "+value.parseJson().get("order")+", "+value.parseJson().get("family")
```

複製貼上請注意語法是否有空格和空行，請刪除

進階題-自動匯入高階層分類欄位

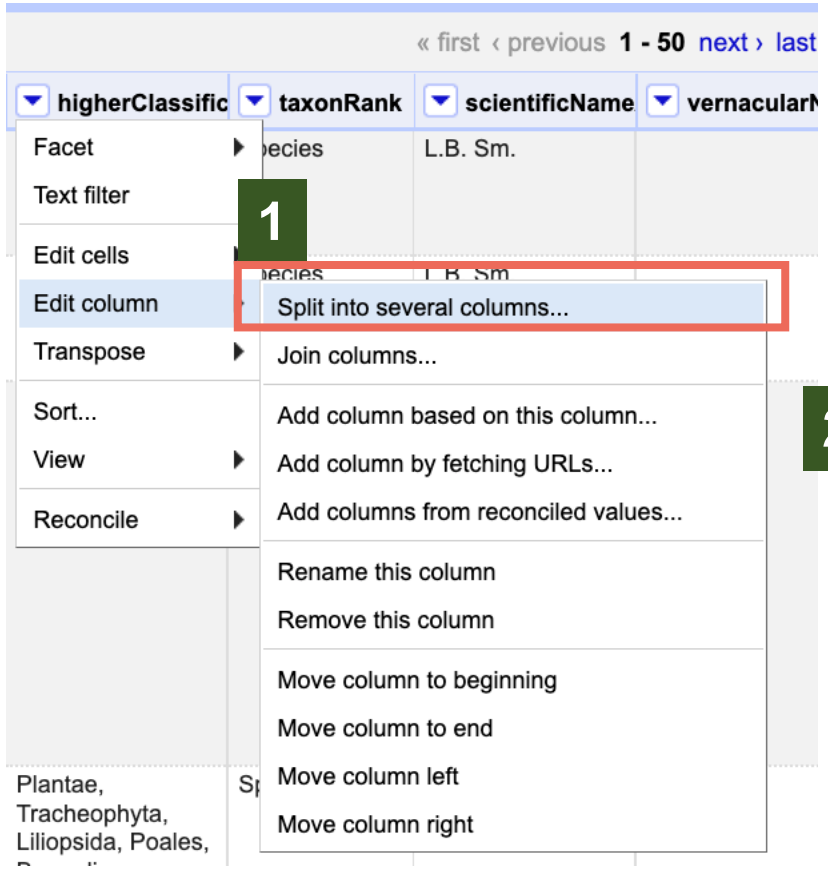

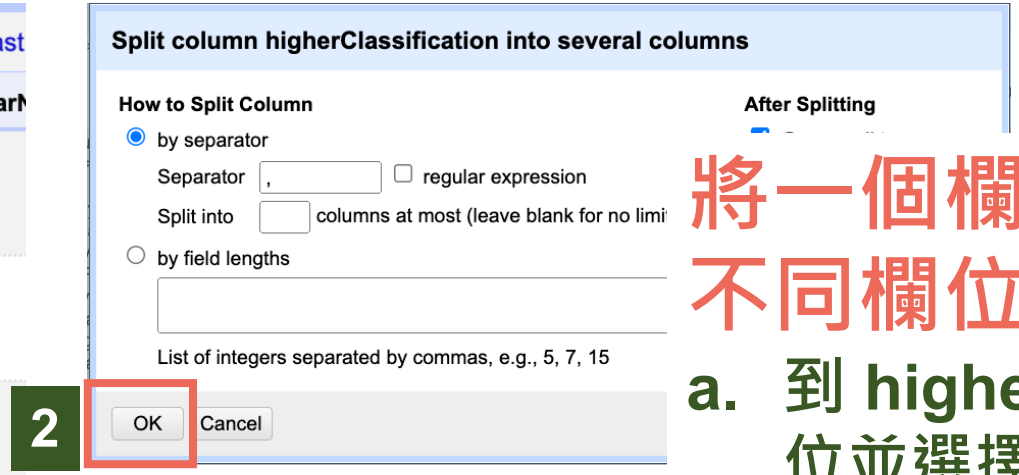

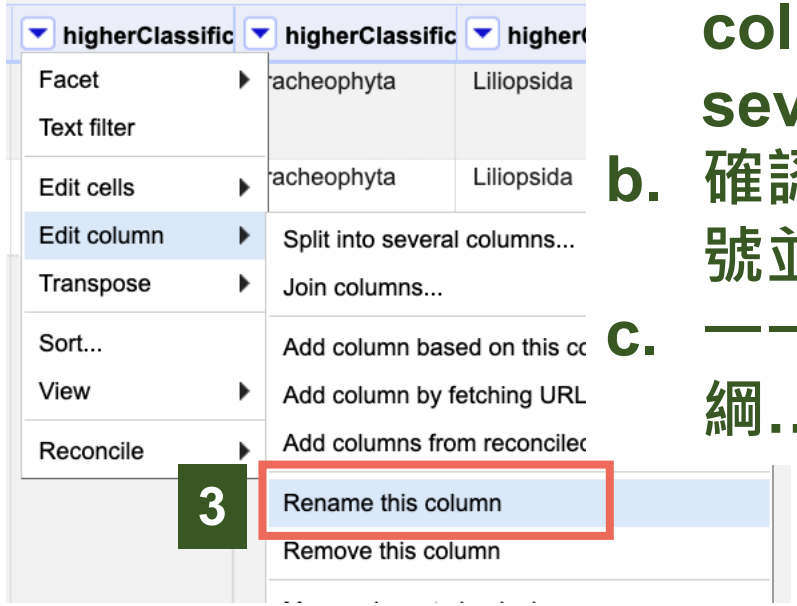

將一個欄位中的值分成不同欄位

a. 到 higherClassification 欄位並選擇 Edit column >> Split into several columns

b. 確認該欄位的分隔符號是逗號並按 OK

c. ——將欄位名稱改為界、門、綱…

進階題-自動匯入高階層分類欄位

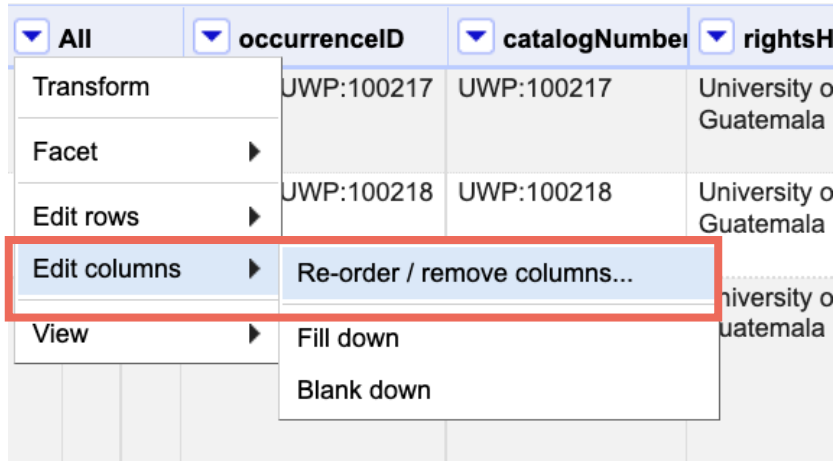

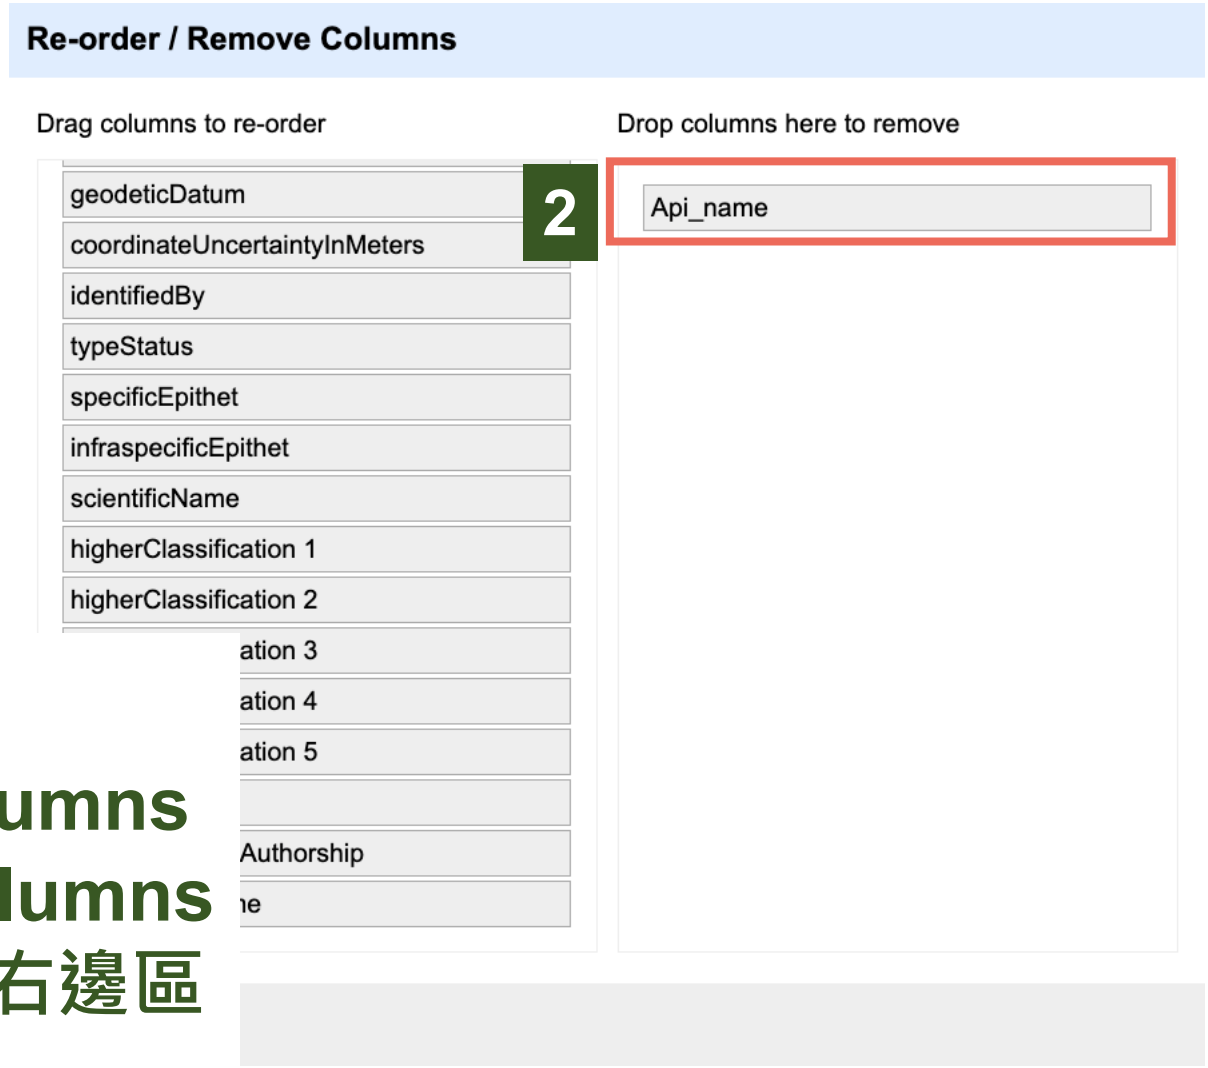

將不要的欄位刪除

a. 到 All欄位並選擇Edit columns >> Re-order/ remove columns

b. 拖曳左邊不想要的欄位到右邊區域並按 OK

TaiBIF Open Data Toolkit
開放資料整合工具

TaiBIF 內容經理 劉璟儀

開發緣由與背景

大家開放資料挫敗感太重

- DwC 那麼多要怎麼選
- 資料太多錯誤很難一次找到修正

很多工具可以用但尚未整合

- 如果有一個可以從資料欄位產生到編輯到清理都可以在同一個地方做完的工具就好了...

TaiBIF Open Data Toolkit
開放資料整合工具出爐！

位產生資料 → 編輯資料 → 驗證資料 → 清理資料 → 打包成資料檔

直接可以上傳IPT ~

第一步：建立資料模板


開放資料模板與驗證工具
資料模板 → 編輯資料 → 資料驗證 → 資料清理
STEP1. 選擇模板
STEP2. 選擇欄位
自訂模板
主題
生態調查
資料集類型*
Sampling Event 調查活動
延伸資料集
Darwin Core Occurrence
自訂欄位名稱
自訂欄位類型
新增自訂欄位
資料集類型欄位：Sampling Event
eventID
eventDate
samplingProtocol
sampleSizeValue
sampleSizeUnit
samplingEffort
countryCode
decimalLatitude
decimalLongitude
geodeticDatum
coordinateUncertaintyInMeters
coordinatePrecision
parentEventID
eventTime
year
month
day
verbatimEventDate
habitat
sampleSizeValue
所屬類別
Event
定義
採樣調查中單次採樣的大小數值(時間間隔、長度、範圍，或體積)。須搭配 dwc:sampleSizeUnit 欄位
常見對應名稱
採樣大小、採樣量、取樣大小
範例
5 (sampleSizeValue) with metre (sampleSizeUnit)
儲存模板
下一步

第二步：編輯資料


開放資料模板與驗證工具
資料模板 → 編輯資料 → 資料驗證 → 資料清理
STEP3. 切換頁籤
STEP4. 編輯資料
資料集類型
samplingevent
延伸資料集
darwin-core-occurrence
獲取行資料
匯入資料
匯出資料
新增列在表格底部
10
列數：15
eventID
eventDate
samplingProtocol
sampleSizeValue
sampleSizeUnit
samplingEffort
countryCode
decimalLatitude
decir
1 test-2024-001 2023-12-01 穿越線 1
2 test-2024-002 2023-12-02 穿越線 2
3 test-2024-003 2023-12-03 穿越線 5
4 test-2024-004 2023-12-04 徒步 10
5 test-2024-003 2023-12-05 徒步 4
6
7
8
9
10
11
12
13
14
15
上方插入列
下方插入列
移除該列
復原
取消復原
唯讀
複製
剪下
eventID
test-2024-001 1
test-2024-002 1
test-2024-003 2
test-2024-004 1
null 10
上一步
下一步

第三步：驗證資料


開放資料模板與驗證工具
資料模板 → 編輯資料 → 資料驗證 → 資料清理
STEP5. 檢視資料
資料集類型
samplingevent
延伸資料集
darwin-core-occurrence
欄位頻率
欄位名稱 正確率
eventID 66.7%
decimalLongitude 0%
decimalLatitude 0%
eventDate 86.7%
coordinateUncertaintyInMeters 100.0%
countryCode 100.0%
geodeticDatum 0%
sampleSizeUnit 0%
sampleSizeValue 100.0%
錯誤訊息
eventID 有重複 5
decimalLongitude 有空值 15
decimalLatitude 有空值 15
eventDate 無效 2
Index eventDate
7 2023-12-41
15 2023-16-04
countryCode 有空值 10
geodeticDatum 有空值 15
sampleSizeUnit 有空值 15
sampleSizeValue 有空值 10
上一步
下載錯誤訊息
下一步

第四步：清理資料與打包

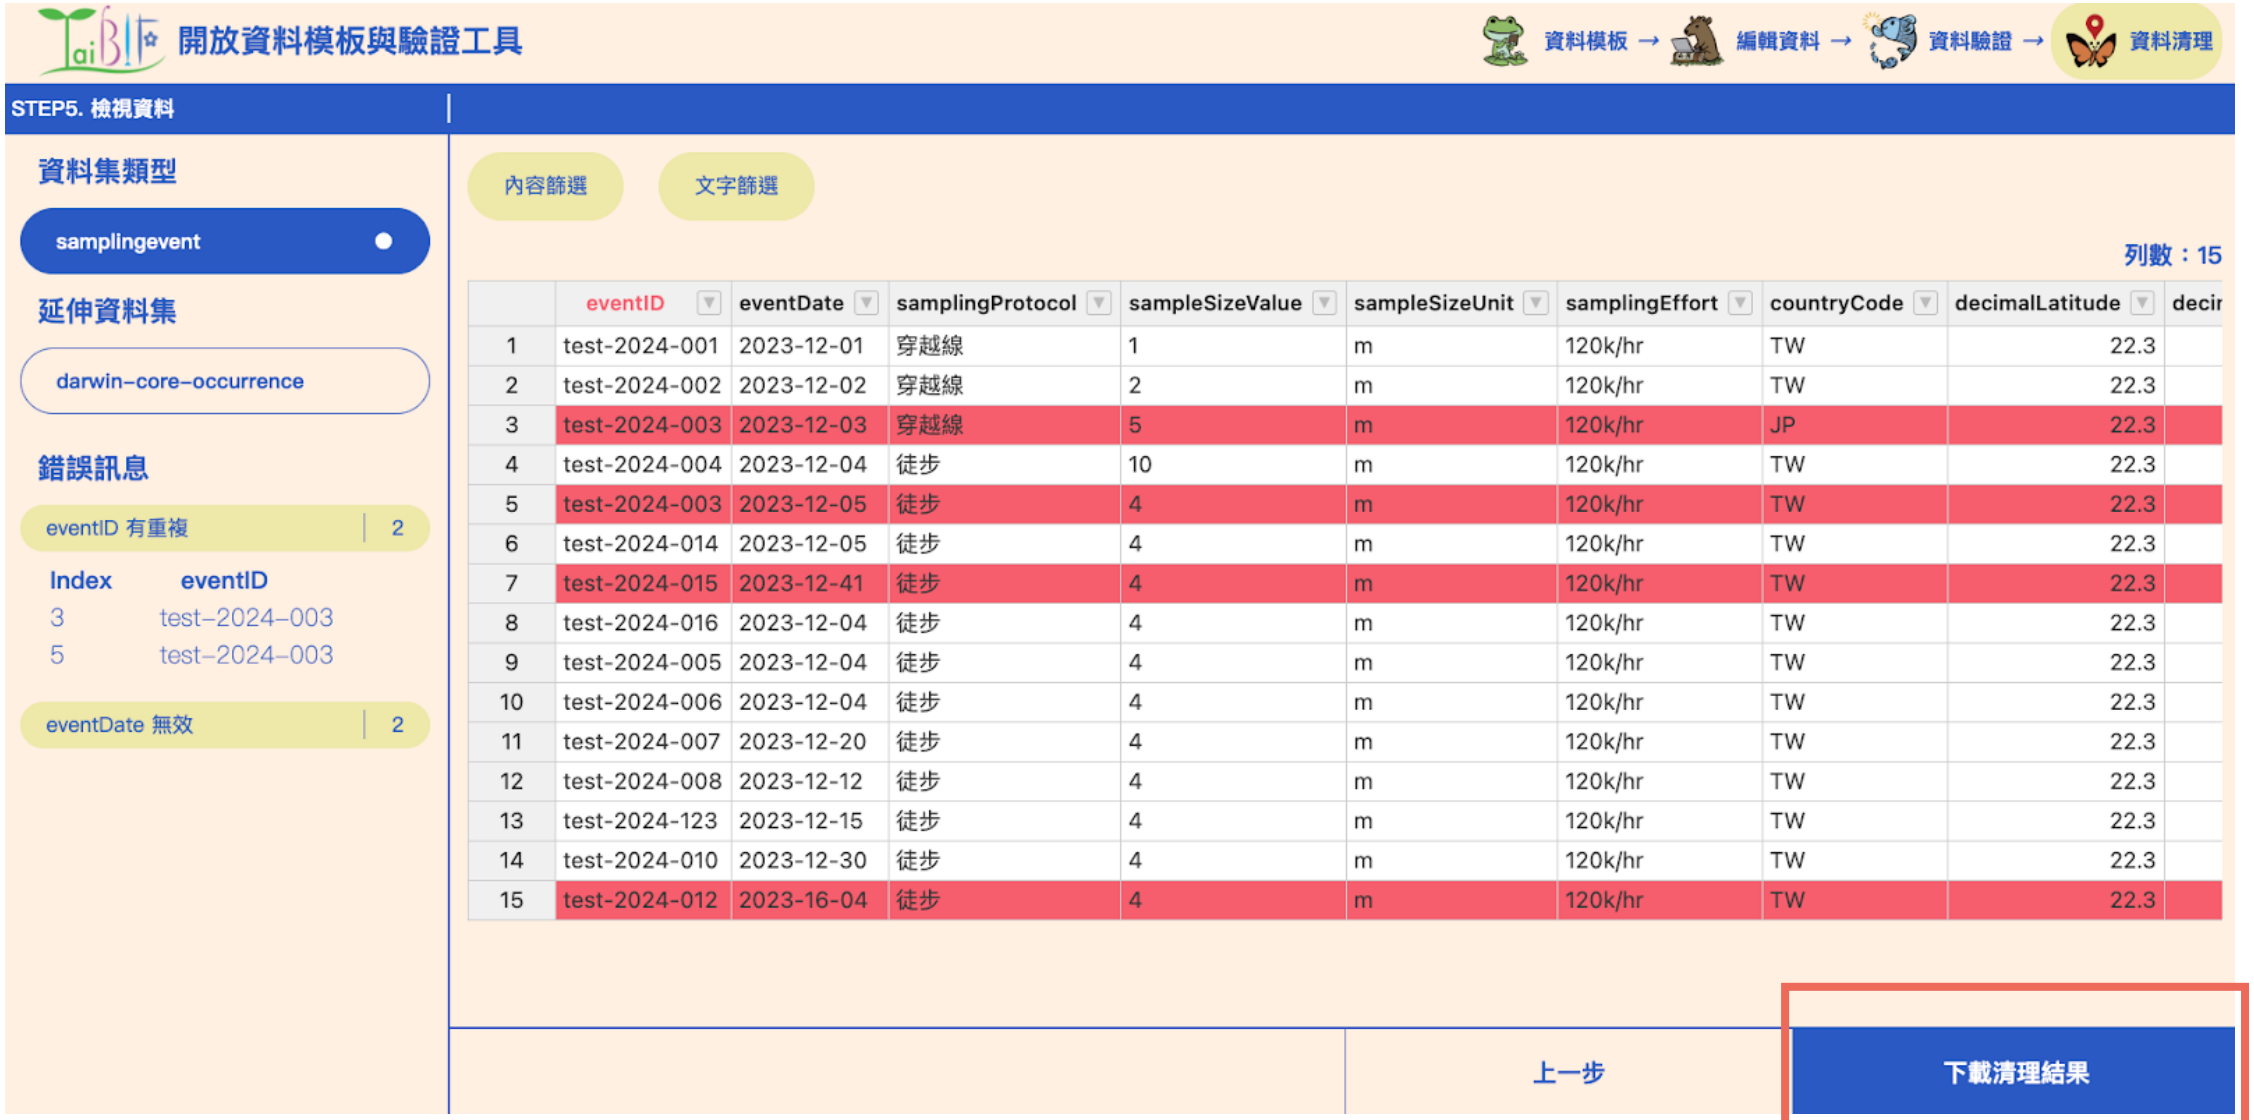
開放資料模板與驗證工具
資料模板 → 編輯資料 → 資料驗證 → 資料清理
STEP5. 檢視資料
資料集類型
samplingevent
延伸資料集
darwin-core-occurrence
錯誤訊息
eventID 有重複 2
Index eventID
3 test-2024-003
5 test-2024-003
eventDate 無效 2
內容篩選
文字篩選
列數：15
eventID eventDate samplingProtocol sampleSizeValue sampleSizeUnit samplingEffort countryCode decimalLatitude
1 test-2024-001 2023-12-01 穿越線 1 m 120k/hr TW 22.3
2 test-2024-002 2023-12-02 穿越線 2 m 120k/hr TW 22.3
3 test-2024-003 2023-12-03 穿越線 5 m 120k/hr JP 22.3
4 test-2024-004 2023-12-04 徒步 10 m 120k/hr TW 22.3
5 test-2024-003 2023-12-05 徒步 4 m 120k/hr TW 22.3
6 test-2024-014 2023-12-05 徒步 4 m 120k/hr TW 22.3
7 test-2024-015 2023-12-41 徒步 4 m 120k/hr TW 22.3
8 test-2024-016 2023-12-04 徒步 4 m 120k/hr TW 22.3
9 test-2024-005 2023-12-04 徒步 4 m 120k/hr TW 22.3
10 test-2024-006 2023-12-04 徒步 4 m 120k/hr TW 22.3
11 test-2024-007 2023-12-20 徒步 4 m 120k/hr TW 22.3
12 test-2024-008 2023-12-12 徒步 4 m 120k/hr TW 22.3
13 test-2024-123 2023-12-15 徒步 4 m 120k/hr TW 22.3
14 test-2024-010 2023-12-30 徒步 4 m 120k/hr TW 22.3
15 test-2024-012 2023-16-04 徒步 4 m 120k/hr TW 22.3
上一步
下載清理結果

TaiBIF Open Data Toolkit
開放資料整合工具出爐！

位產生資料 → 編輯資料 → 驗證資料 → 清理資料 → 打包成資料檔

預計今年優化完成後，年底上線

下個月記得交作業喔～

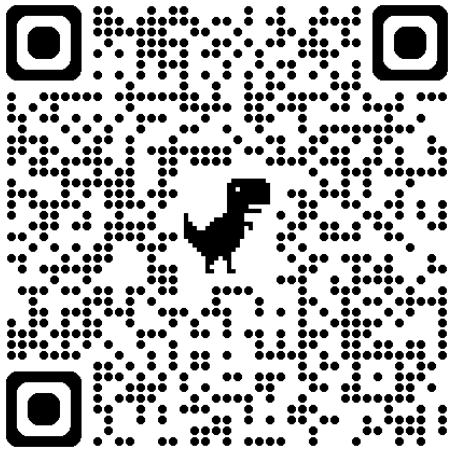

Open Refine / DwC 作業繳交 - https://forms.gle/zVCr1Ujeq3971TSs6

需要認證證書的人一定要交喔！

Thank you!

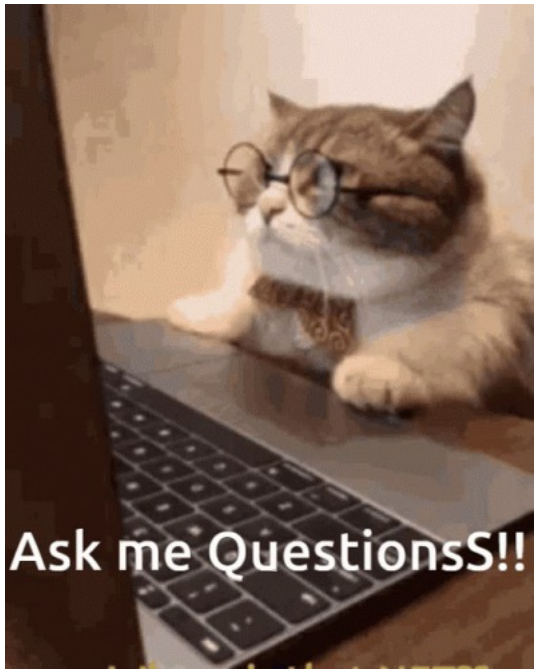

Q & A 時間