



NETWERK

KENNISCENTRUM GEFACILITEERD DOOR HET **NIOD**

**OORLOGS
BRONNEN**

OpenRefine

17 oktober 2017

Inge van Stokkom | Netwerk oorlogsbronnen

OpenRefine

- Open Refine is een gratis open-source tool waarmee je data kan:
 - Analyseren
 - Schonen & standaardiseren
 - Koppelen van eigen thesaurus aan externe bron
 - Verrijken: aanvullen van eigen data met data uit externe bron
- “a powerful tool for working with messy data”
- “Excel voor gestructureerde tekst”
- stand alone desktop application, geen internet nodig
- data schonen, normaliseren, transformeren naar verschillende formaten

Zoekresultaat

13 termen gevonden in 0.17

op ruiten gebracht

- op ruiten gebracht door insnijdingen
- op ruiten gebracht in grafiet
- op ruiten gebracht in grafiet of zwart krijt
- op ruiten gebracht in houtschool
- op ruiten gebracht in potlood
- op ruiten gebracht in rood en zwart krijt
- op ruiten gebracht in rood krijt
- op ruiten gebracht in roze krijt
- op ruiten gebracht in wit krijt
- op ruiten gebracht in zwart krijt
- op ruiten gebracht met pen en potlood
- op ruiten gebracht met pen in bruin

 Alle sleutels Inclusief nauwere termen Term uitslappen

thesaurusterm

beheergegevens

Term

Term

23D41

Engelse term

winter, 'Hyems'; 'Inverno' (Ripa)

Aziatische term

Relaties

Use

Used for

Broader Term

Narrower Term

Related Term

Equivalent Term

Bron en definitie

Bron

Iconclass

URI

<http://iconclass.org/23D41>

Scope Note

Bijzonderheden

plaats:"Amsterdam"

plaats:"AMSTERDAM"

plaats:"A-dam"

plaats:"Adam"

plaats:"A'dam"

plaats:"Amsterdam"

plaats:"Amsterdam"

plaats:"Amsterdam."

plaats:"Amsterdam."

plaats:"AmsterdamM"

plaats:"Amsterdam-N"

plaats:"Amsterdam-oost"

plaats:"Amsterdam-Oost"

plaats:"Amsterdam-Sloten"

plaats:"Amsterdam-Sloten"

plaats:"Amsterdam-zuid"

plaats:"Amsterdam-Zuid"

plaats:"AMSTERDAN"

plaats:"Amsterdm"

plaats:"Amsterfoort"

plaats:"Amstgerdam"

plaats:"Amstrerdam"

plaats:"Amterdam"

plaats:"Amterdam"

plaats:"Amsterdam"

plaats:"Amstelredam"

plaats:"Amstelledamme"

plaats:"Amst."

plaats:"Andenne"

penseel in bru

penseel in bru

penseel in bruinzwart

penseel in dekverf

penseel in dekverf en zilververf

penseel in dekverf in blauw en

penseel in dekverf in grijs en

penseel in dekverf in grijs en

penseel in dekverf in kleuren

penseel in dekverf in zwart en

penseel in dekverf in zwart en

penseel in dekverf in zwart, re

penseel in donkerblauw

penseel in donkerbruin

penseel in donkerbruin en lic

penseel in donkergris

penseel in donkerrode water

penseel in enig goud

penseel in enig rood

penseel in enig wit

penseel in enige kleuren

penseel in felgeel

penseel in geel

penseel in geelbruin

penseel in gewassen inkt

penseel in goud

penseel in goudverf

penseel in grijs

penseel in grijs en bister

penseel in grijs en blauw

OpenRefine

2014 11 21 penseel in grijs ... 2014 12 15 penseel in grijs ... +

127.0.0.1:3333/project?project=1730409142656 Wikipedia (nl)

Google refine 2014 12 15 penseel in grijs csv Permalink Open... Export Help

Facet / Filter Undo / Redo 14

1476 rows

Show as: rows records Show: 5 10 25 50 rows « first < previous 1 - 50 next > last »

Extensions: Named-entity recognition ▾ Freebase ▾ RDF ▾

Using facets and filters 

Use facets and filters to select subsets of your data to act on. Choose facet and filter methods from the menus at the top of each data column.

Not sure how to get started?
[Watch these screencasts](#)

All	recordnr	TK	MA	ME
1.	352166	etsen, pen in bruin, pen in zwart, penseel in grijs	papier, inkt	ets, bewerkt met pen en penseel, proefdruk
2.	154120	etsen, penseel in grijs	papier	ets
3.	231448	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
4.	145186	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
5.	230784	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
6.	205200	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
7.	319405	potlood, pen in grijs, penseel in grijs	papier, inkt	pen in grijs
8.	174257	penseel in grijs, pen	papier, inkt	pen in grijs en zwart
9.	247205	pen in grijs, penseel in grijs, doorgriffelen	papier, inkt	pen in grijs
10.	225450	zwart krijt, pen in grijs, penseel in grijs	papier, inkt	pen in grijs
11.	236029	potlood, pen in grijs, penseel in grijs	papier, inkt	pen in grijs
12.	209917	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
13.	145230	pen in grijs, penseel in grijs	papier, inkt, potlood	op ruiten gebracht in potlood
14.	231542	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
15.	26529	potlood, pen in grijs, penseel in grijs	papier, inkt	pen in grijs
16.	444552	loodstift, pen in bruin, penseel in grijs	papier	tekening
17.	145242	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
18.	323742	potlood, pen in grijs, penseel in grijs	papier, inkt	pen in grijs
19.	214538	pen in grijs, penseel in grijs, doorgriffelen	papier, inkt	pen in grijs
20.	241551	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
21.	226813	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
22.	241679	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
23.	236619	potlood, pen in grijs, penseel in grijs	papier, inkt	pen in grijs
24.	232042	penseel in grijs, pen in grijs	papier, inkt	pen in grijs
25.	311902	potlood, pen in grijs, penseel in grijs	papier, inkt	pen in grijs
26.	230629	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
27.	232390	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
28.	54182	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
29.	227066	pen in grijs, penseel in grijs	papier, inkt	pen in grijs
30.	225835	zwart krijt, pen in grijs, penseel in grijs	papier, inkt	pen in grijs

Features

SMM_objectName.cs

127.0.0.1:3333/project?project=1951978072313

Google refine SMM_objectName.csv Permalink

Facet / Filter Undo / Redo 0 16 matching records (742 total) Extensions: Freebase ▾

Refresh Reset All Remove All Show as: rows records Show: 5 10 25 50 records « first < previous 1 - 10 next > last »

record - term

stoe

case sensitive

record - term

16 choices Sort by: name count

1 armstoel 1
1 armstoel met fronton 1
19 zetels en stoelen 1
2 armstoelen 1
2 stoelen 1
35 stoelen 1
6 stoelen 1
achterstijl van stoel 1
bureau-leunstoel 1
ceremoniële stoelen 1
draagstoelen 1
gestoelte 1
spaanse stoel 1
stoelen 1
stoelpoot 1
stoelzitting 1
(blank) 16

Facets and filters

	main	record - domain	record - term	record - priefer	record - date_in	reco
0	1 armstoel			1286	2005-04-01	domini
1						
0	1 armstoel met fronton			1295	2005-04-01	domini
1						
0	19 zetels en stoelen			1290	2005-04-01	domini
1						
0	2 armstoelen			1294	2005-04-01	domini
1						
0	2 stoelen			1306	2005-04-05	domini
1						
0	35 stoelen			1297	2005-04-01	domini
1						
0	6 stoelen			1285	2005-04-01	domini
1						
0	echterstijl van stoel			1240	2005-03-18	domini
1						
0	bureau-leunstoel			1235	2005-03-17	domini
1						
0	ceremoniële stoelen			1220	2005-03-18	domini
1						

FACET/FILTER

127.0.0.1:3333/project?project=1822407736442 — Adlibgebruikersgroep_workshop 3 csv – OpenRefine

Reader Open... Export Help

Refine Adlibgebruikersgroep_workshop 3 csv Permalink

Facet / Filter Undo / Redo 0 Extensions: undefined

Refresh Reset All Remove All

16 records Show as: rows records Show: 5 10 25 50 records « first < previous 1 - 10 next > last »

	Straat	Postcode	Postcode letters	Gemeente	Land	Datum ontwerp	Datum opleverin	Ontwerpers	Architect	Studie...
1	Meulesteenweg	9 000		Facet	Text facet					noArchitecten
				Text filter	Numeric facet					
				Edit cells	Timeline facet					
				Edit column	Scatterplot facet					
				Transpose	Custom text facet...					
				Sort...	Custom Numeric Facet...					
				View	Customized facets					
				Reconcile						
2	Dieudonné Lefèvrestraat	1 020								
3	Europalaan	3 600								
4	Rue Grandrieux	7 910								
5	Leuvensesteenweg	2 800		Mechelen	België	2006	2008	Van Severen, Maarten	PCP Architects	
6	Oudeleeuwenrij	2 000		Antwerp	België	1997	2006	Brusselmans, Jean	Robbrecht en Daem architecten	Structor Engineering Mechelen
7								Goossens, Willy		
8								Daem, Hilde		Grontmij Vlaanderen
(blank)										
9 choices	Sort by: name count	Cluster								
Facet by choice counts										

UNDO/REDO

127.0.0.1:3333/project?project=1822407736442 — Adlibgebruikersgroep_workshop 3 csv – OpenRefine

Edit single cell on row 2, column Gemeente Undo

Refine OPEN Adlibgebruikersgroep_workshop 3 csv Permalink

Facet / Filter Undo / Redo 2 Extract... Apply... Extensions: undefined

Filter:

16 records

Show as: rows records Show: 5 10 25 50 records « first < previous 1 - 10 next > last »

	Straat	Postcode	Postcode letters	Gemeente	Land	Datum ontwerp	Datum opleverin	Ontwerpers	Architect	Student
1	Meulesteenesteenweg	9 000			België				noArchitecten	
2	Sint-Dieudonné Lefèvrestraat	1 020			België	2003	edit	2009	Ambrosius Francken I	Architecten Tom Thys en Adinda Van Geystelen
3	Europalaan	3 600		Genk	België				PCP Architects	
4	Rue Grandrieux	7 910		Frasnes-Lez-anvaing	België	2006		2008	Van Severen, Maarten	GWM architecten
5	Leuvenesteenweg	2 800		Mechelen	België	2006		2007	Ambrosius I Francken	DG architecten
6	Oudeleeuwenrij	2 000		Antwerp	België	1997		2006	Brusselmans, Jean	Robbrecht en Daem architecten
7									Goossens, Willy	
8									Daem, Hilde	

Features

SMM_material - Goo x

127.0.0.1:3333/project?project=2217220435084

Cluster & Edit column "record - term"

This feature helps you find groups of different cell values. For example, the two strings "New York" and "new York" are very likely to refer to the same concept and can be merged.

Method key collision

Cluster Size	Row Count	Values in Cluster	Merge?	New Cell Value
3	3	• (roze) hout (1 rows) • (roze?) hout (1 rows) • roze hout (1 rows)	<input checked="" type="checkbox"/>	rozenhout
2	2	• ivoor (1 rows) • ivoor? (1 rows)	<input type="checkbox"/>	ivoor
2	2	• marmer (1 rows) • marmer? (1 rows)	<input type="checkbox"/>	marmer
2	2	• rode was (1 rows) • was (rode) (1 rows)	<input type="checkbox"/>	rode was
2	2	• metaal (1 rows) • metaal? (1 rows)	<input type="checkbox"/>	metaal
2	2	• keramiek (1 rows) • keramiek? (1 rows)	<input type="checkbox"/>	keramiek
2	2	• was (1 rows)	<input type="checkbox"/>	was

10 clusters found

Choices in Cluster

Rows in Cluster

Average Length of Choices

Length Variance of Choices

google-refine-2....zip

Show all downloads...



Cluster & Edit column "antwoord_bewerkt14"

This feature helps you find groups of different cell values that might be alternative representations of the same thing. For example, the two strings "New York" and "new york" are very likely to refer to the same concept and just have capitalization differences, and "Gödel" and "Godel" probably refer to the same person. [Find out more ...](#)

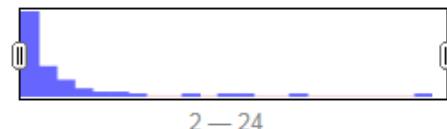
Method **key collision**

Keying Function **metaphone3**

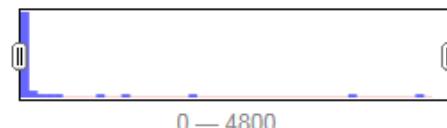
516 clusters found

13	1987	<ul style="list-style-type: none">• plaats:"Rotterdam " (1961 rows)• plaats:"Rotterdam Z" (5 rows)• plaats:"Rotterdam (N)" (4 rows)• plaats:"Rotterda (3 rows)• plaats:"Rotterdam" (2 rows)• plaats:"Rotterdam (Hillgersberg)" (2 rows)• plaats:"Rotterdam (Schiebroek)" (2 rows)• plaats:"Rotterdam IJsselmonde" (2 rows)• plaats:"Rotterddam" (2 rows)• plaats:"Rotterdam " (1 rows)• plaats:"Rotterdam (Pernis)" (1 rows)• plaats:"Rotterdan" (1 rows)• plaats:"Rotterdm" (1 rows)	<input type="checkbox"/>	plaats:"Rotterdam "
11	28	<ul style="list-style-type: none">• plaats:"Villers le Temple" (11 rows)• plaats:"Flers en Escrebieux" (4 rows)• plaats:"Flers Borcelrieux" (2 rows)• plaats:"Flers Lille" (2 rows)• plaats:"Flers-en Escrelieux" (2 rows)• plaats:"Flers-en Escrelrieux" (2 rows)	<input type="checkbox"/>	plaats:"Villers le Temple"

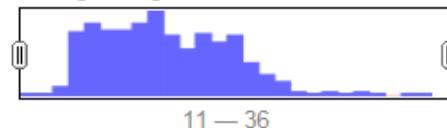
Choices in Cluster



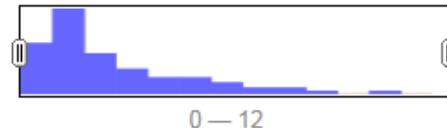
Rows in Cluster



Average Length of Choices



Length Variance of Choices



Select All Unselect All

Merge Selected & Re-Cluster

Merge Selected & Close

Close

Features

The screenshot shows the Google Refine interface with a modal dialog open. The dialog title is "Add column based on column term_clean". It asks for a "New column name" (AAT identifier) and has an "On error" option set to "set to blank". The "Expression" field contains the following GREQL code:

```
cell_cross("AAT_ENG_NED", "skos:prefLabel@nl").cells["actidentificer"].value[0]
```

The "Language" dropdown is set to "Google Refine Language (GREQL)". Below the expression, it says "No syntax error." A blue callout bubble points to the word "identifier" in the expression.

The main interface shows a table with 683 rows. The first few rows are:

22.	achtergrond van stof	300181918
23.	acrylverfschilderingen	300181918
24.	afdrukken	300178549
25.	affiches	300027221
26.	afgezaagde menselijke schedelkap	Error: Cannot retrieve field from null
27.	afgietsels	300047806

At the bottom of the dialog, there are "OK" and "Cancel" buttons.

A large blue callout bubble points to the text "Google Refine Expression language" in the upper right area of the interface.

waardes aanpassen (*GREL expressions*)

Screenshot of the OpenRefine interface showing a custom text transform dialog.

The dialog title is "Custom text transform on column Materiaal".

The expression is set to `value.replace('potlood en inkt','potlood, inkt')`. A note says "No syntax error."

The preview table shows the transformation of six rows:

row	value	value.replace('potlood en inkt','potlood, inkt')
1.	potlood en inkt	potlood, inkt
2.	potlood en inkt	potlood, inkt
3.	potlood en inkt	potlood, inkt
4.	potlood en inkt	potlood, inkt
5.	potlood en inkt	potlood, inkt
6.	potlood en inkt	potlood, inkt

On error options: keep original, set to blank, store error.

OK and Cancel buttons are at the bottom.

In the background, the main OpenRefine interface shows a dataset with one row:

irnemingen traete en iecke, Van e Bouwgroep							
------------------------------------------------------	--	--	--	--	--	--	--

Navigation and other controls are visible at the top and right of the interface.

Features

SMM_material - Goo x

127.0.0.1:3333/project?project=1923031089630

Google refine SMM_material Permalink

Facet / Filter Undo / Redo 1

Refresh Reset All Remove All

term_clean: judgment change

2 choices Sort by: name count

matched 30

none 1

Facet by choice counts

term_clean: best candidate's score change reset

92.00 — 100.02

31 rows

Show as: rows reconciliation services

All term_clean

1.	beukenhout Choose new match	2572		30
2.	Congohout Choose new match	802		30
3.	dennenhout Choose new match	1445		30
4.	dennenhout Choose new match	2333		30
5.	divuiti-hout Choose new match	2088		30
6.	ebbehout Choose new match	1281		30
7.	ebbenhout Choose new match	1190		30
8.	eikenhout Choose new match	113		30
9.	eikenhouten paneel Choose new match	298		30
10.	gezwarthout Choose new match	2167		30

Reconciliation Services



Eigen thesaurus
Materiaal = olieverf

AAT
Term = oil paint (paint)
NL term = olieverf

<http://vocab.getty.edu/aat/300015050>

Eigen thesaurus
Materiaal = **olieverf**

AAT
Term = oil paint (paint)
olieverf

<http://vocab.getty.edu/aat/300015050>

Oil paint (paint)
Eigen thesaurus
Materiaal = **olieverf**

<http://vocab.getty.edu/aat/300015050>

AAT
Term = oil paint (paint)
olieverf

<http://vocab.getty.edu/aat/300015050>

Export maken

Open...

Export ▾

Export project

Tab-separated value

Comma-separated value

HTML table

Excel

ODF spreadsheet

Triple loader

MQLWrite

Custom tabular exporter...

Templating...

- Handleidingen:

- http://www.adlibug.nl/wp-content/uploads/2015/05/20150430_Handout_Open_Refine_workshop.pdf
- https://www.dropbox.com/s/4jcve4m7ecjmf2/Handleiding_OpenRefine.pdf?dl=0#
- Geo-info: <http://erfgeo.nl/wat-hoe/openrefine.html>

Gloednieuwe handleiding data opschonen & koppelen:

- https://www.projectcest.be/wiki/Bestand:MoMu_VerbindJeTermenOkt2017.pdf

✓ Met dank aan Alina Saenko van Packed vzw

Inge van Stokkom
l.van.stokkom@niod.knaw.nl

NETWERK

KENNISCENTRUM GEFACILITEERD DOOR HET NIOD

OORLOGS BRONNEN

www.oorlogsbronnen.nl

@Oorlogsbronnen

info@oorlogsbronnen.nl



Ministerie van Volksgezondheid,
Welzijn en Sport

VSBfonds,
iedereen doet mee