

Aineistojen muuntaminen ja jalostaminen linkitetyksi avoimeksi dataksi: 1,2 miljoona kirjettä ja 100 000 toimijaa

Suomalaisen Kirjallisuuden Seura
27.5.2025

Petri Leskinen, Aalto-yliopisto
Senka Drobac, Helsingin yliopisto

Sisältö

- Lähdemateriaali
- Datamuunnos
- Datat rikastaminen
- Tietomalli




Lähdemateriaali

Lähdemateriaali


- **Lukuisilta eri osapuolilta**
 - Datan määrä vaihtelee, 25 - 360.000 kirjettä
 - Ajallinen rajausta vuoteen 1917
- **Useissa eri formaateissa**
 - Word, Excel, CSV, JSON, RDF
- **Tiedon kattavuus vaihtelee**
 - Aika, kirjeiden määrä, lähetys- ja vastaanottopaikat
 - Henkilöiden biografiset yksityiskohdat

Datamuunnos

Process pipeline




Process pipeline



- **Data transformation**
- Harmonization
- Deduplication
- Data Linkage

Process pipeline



- **Data transformation**
 - **From various data formats:**
Word, Excel, CSV, JSON, RDF
- Harmonization
- Deduplication
- Data Linkage

Word files

- **Different document structure**
 - Categories not in the same order, different titles
 - Data for several people in one document
- **Inconsistent formatting**
 - Mixing tabs/spaces
 - Text in multi lines
 - Other correspondences
 - Numerous small inconsistencies

Multi lines

Number ↓ of letters

Suomen Eläinsuojeluyhdistys	1929	1
Suomen Evankelinen Seura	1918	1
Suomen ev.lut. Pyhäkouluyhdistys	1922	1
Suomen Historiallinen Seura	1912-1925	13
Suomen kenraalikuvernööri (:n toimisto), / # liitteinä suomennoksia	1900-1916 1900-1916	30 30
Suomen kielen sanakirjaosakeyhtiö	1916	2
Suomen Kirkkohistoriallinen Seura	1902	1
Suomen Kirkollisviraston leski- ja orpokassa	1900-1919	2
Suomen Kirkon Pappisliitto	1918-1926	6
Suomen Kirkon Seurakuntatyön Keskusliitto (liite)	1918-1934	23
Suomen Kirkon Sisälähetysseura (liite) / ## (ks. myös Aarnisalo, Otto ja Suomen Piipia-seurat)	1917 1917	1
Suomen Kotiseutututkimuksen keskusvaliokunta	1917	1

Multi lines

Detschy, Serafine	s.a.	1
Dillon, E.J.D.	1891, s.a.	6
liitt. Dillon, E.J.D. → Mr Dillon s.a., 1 kpl		
Dingeldey, Ludvig	s.a.	3
Dmitrieff, Hélène	1906, s.a.	4
Donner, Otto (kts. myös Donner, Minette)	1885-1904, s.a.	11
Donner (o.s. Munck), Wilhelmina Sofia	1899	1
Ch. (Minette) & Donner, O.		
Dühren, C.J. von	1904	1

Donner (o.s. Munck) ; Wilhelmina Sofia /
Ch. (Minette) ; Donner, O.

Gallen-Kallela Museum / FINNA

Results of a database query
using Finna API Service

```
▼ events:
  ▼ valmistus:
    ▼ 0:
      type: "valmistus"
      date: "valmistusaika 02.08.1907, valmistusaika 1907"
      methods: []
      methodsExtended: []
      materials: []
      materialsExtended: []
    ▼ places:
      ▼ 0:
        placeName: "Saksa, Warnemünde"
        type: "URI"
        id: "http://www.yso.fi/onto/yso/pl05087"
        ▼ ids:
          0: "http://www.yso.fi/onto/yso/pl05087"
        ▼ details:
          0: "place_id_type_URI"
      ▼ actors:
        ▼ 0:
          name: "Gallen-Kallela, Akseli"
          role: "vastaanottaja"
        ▼ 1:
          name: "Öhquist, Johannes"
          role: "lähettäjä"
```

Albert Edelfelts brev API

```
{
  "url": "http://edelfelt.sls.fi/api/letters/1/",
  "id": 1,
  "title": "Kiala den 16 Juni 67.",
  "events": [ "http://edelfelt.sls.fi/api/events/1983/", ... ],
  "web_url": "http://edelfelt.sls.fi/brev/1/kiala-den-16-juni-67/",
  "date": "1867-06-16",
  "urn": "URN:NBN:fi:sls-537-1403107521400",
  "locations": [ "http://edelfelt.sls.fi/api/locations/273/" ]
}
...
{
  "url": "http://edelfelt.sls.fi/api/events/1995/",
  "id": 1995,
  "title": "Alexandra Edelfelt och Carl Albert Edelfelt har varit på resa; de har besökt Åbo och Stockholm.",
  "letter": "http://edelfelt.sls.fi/api/letters/2/",
  "persons": [ "http://edelfelt.sls.fi/api/persons/466/",
               "http://edelfelt.sls.fi/api/persons/786/"
            ],
  "mentioned_locations": [ "http://edelfelt.sls.fi/api/locations/71/",
                           "http://edelfelt.sls.fi/api/locations/78/"
                        ]
}
```

Simple RDF

```
records:NL__00009996 a :MetadataRecord ;
```

```
  sender "Borg, Einar",
```

```
    "Heikel, O. J.",
```

```
    "Järventaus, H. A.",
```

```
    "Kauppinen, K.",
```

```
    "ym." ;
```

```
  :sender_as_recorded "Borg, Einar ; Heikel, O. J. ; Järventaus, H.A. ; Kauppinen, K. ; ym." ;
```

```
  :recipient "Juho Rudolf Koskimies (Forsman)" ;
```

```
  :recipient_as_recorded "Juho Rudolf Koskimies (Forsman)" ;
```

```
  :sending_date "1916" ;
```

```
  :number_of_letters "5" ;
```

```
  :archival_organization_as_recorded "National Library of Finland" ;
```

```
  :fonds_as_recorded "Coll. 108 Koskimies, Juho R." ;
```

```
  :source_filename "COLL108.docx" ;
```

```
  :note "# KK" ;
```

```
  :archival_location "COLL.108.27" ;
```

```
  dct:source <http://ldf.fi/coco/source/nationallibrary> .
```

← **Actors**


← **Timespan**

← **Letters**

← **Contributor**


← **Fonds**

← **Additional archival metadata**



Datan rikastaminen

Process pipeline



- Data transformation
- **Harmonization**
 - **Into one uniform data schema**
- Deduplication
 - Merge same actor mentioned in different datasets
- Data Linkage
 - To external data sources
 - Enrich with e.g. biographical details and family relations

Esimerkkejä

- **Henkilönimet**

- "Haartman, Axel o. Hedvig f. Stolpe"
 - *Haartman, Axel*
 - *Haartman (Stople), Hedvig*


- **Elin- tai toiminta-aika**

- Forsström, Petter (1877-1967)
- Kekoni, Agnes (*fl.* 1876-1944)
- Förlags Ab Söderström & Co (*fl.* 1800-1949)

- **Arkistokoelmat**

- “Hilja Haahden arkisto”
 - *Haahti, Hilja*
- “SLSA 1319 Släkten Munsterhjelm's arkiv”
 - *Munsterhjelm, Hjalmar; Munsterhjelm, Anders Lorentz; Munsterhjelm, Anders Gustaf; Munsterhjelm, Sofie Johanna; ...*
(linked to [Finna](#))

Process pipeline




- Data transformation
- Harmonization
- **Deduplication**
 - **Merge same actor mentioned in different datasets**
- Data Linkage
 - To external data sources
 - Enrich with e.g. biographical details and family relations

Toimija- ja paikkaontologiat

- **Henkilö, Organisaatio, Perhe/Suku, tuntematon**
 - Ulkopuoleiset tietolähteet
 - *SampoSampo*
 - *Biografiset tiedot, perhe- ja ihmissuhteet*
- **Paikat**
 - Ulkopuoleiset tietolähteet
 - *Koordinaatit, hiearkia*

Actor deduplication



Actor deduplication

**Eva Maria
Acke**



Eva Topelius




**E. M.
Topelius**



Alternative names:

Eva Maria Acke, Eva Maria Topelius, Eva Topelius Acke, Eja Topelius, Eva Maria

Process pipeline



- Data transformation
- Harmonization
- Deduplication
- **Data Linkage**
 - To external data sources
 - Enrich with e.g. biographical details and family relations

Vocabulary of Finnish Actors

- SampoSampo

Historical Finnish People, Organizations, and Places

Biographical information about 230000 historical people related to Finland

Name variations, gender, years and places of birth and death ...

- Collected from multiple datasources:

1. AcademySampo (23000 entries)
2. BiographySampo (22500)
3. Wikidata (84000)
4. Kanto (29000)
5. BookSampo (9800)
6. ParliamentSampo (2100)
7. Norssi Highschool Alumni (2600)
8. Union List of Artist Names (1500)
9. Wikitree (12000)
10. Geneanet (144000)

Parts of CoCo data providing biographical details

11. Edelfelt Letters (3300)
12. Snellman Letters (3300)
13. Åbo Akademi University Library letters (1570)

Vocabulary of Finnish Actors

Eva Topelius (Q4455334)

Finnish painter

Eva Maria Topelius | E. M. Topelius | E. Topelius | Eva Maria Acke

[In more languages](#)

[Configure](#)

Language	Label	Description	Also known as
English	Eva Topelius	Finnish painter	Eva Maria Topelius E. M. Topelius E. Topelius Eva Maria Acke
Finnish	Eva Topelius	suomalainen taidemaalari	E. Topelius E. M. Topelius Eva Maria Topelius Eva Maria Andersson Eva Maria Acke Eva Topelius-Acke Eva Topelius-Acke
Swedish	Eva Topelius	finlandssvensk målare	E. Topelius E. M. Topelius Eva Maria Topelius Eva Maria Acke



♀ Eva Maria Topelius

- Born in 1855 - Nykarleby
- Deceased March 23, 1929 - Vaxholm, Sverige, aged 74 years old

1 file available

Parents

- Zacharias Topelius, *Verkligt statsråd* 1818-1898
- Maria Emille Lindqvist 1821-1885

KÄYTETTÄVÄ NIMENMUOTO

Topelius, Eva, 1855-1929

TYYPPI

henkilö

HENKILÖN TUNNISTE

Asteri ID: 000122880

SYNTYMÄAIKA

1855

KUOLINAIKA

1929

SYNTYMÄPAIKKA

[Uusikaarlepyy](#) (yso-paikat)

KUOLINPAIKKA

Vaxholm, Ruotsi

HENKILÖN AMMATTI TAI
TEHTÄVÄ

[taidemaalari](#) (Metatietosanasto)

HENKILÖN TOIMINTA-ALA

[maalaustaide](#) (YSO)

HENKILÖN LIITTYVÄ

[Topelius-Acke, Eva, 1855-1929](#)

HENKILÖ

Eva Topelius-Andersson



[Uusikaarlepyy](#) 4.9.1855 † [Vaxholm](#) 1929

taidemaalari

Lähteet: Kansallisbiografia, Kansallisbiografian sisällysluettelo

[ISNI](#)

[VIAF](#)

[Wikipedia](#)

[Wikidata](#)

Challenges

- General issues of record linkage, e.g., namesakes, name variations
- Errors in source data
 - Typos
 - Uncertainty in letter dates
 - Erroneous dates
- No (machine readable) data available about some actors

Record Linkage, Current Implementation

- Linkage to external databases
- Deduplication between datasets based on external matches
- Data Enrichment from external sources
 - Biographical details
 - Occupations
 - Personal relations
 - Images


Record Linkage, Current Implementation

- Using Python package [SPLink](#):
 - Unsupervised learning
 - Term Frequency learning
 - Alternative Python packages: [Dedupe](#), [Record Linkage](#)
- Similarity based on:
 - Three different name variations considering
 - *Family Names*
 - *Given Names*
 - *Middle Names*
 - *Initials*
 - Quantiles of letter activity period
 - *Compared to lifespans of external actors*
 - Existing linkage
 - *Cases of Snellman and Edelfelt*




Tietomalli

Tietomalli



Tietomalli

- Metadata Records
- Letters
- Actors
- Fonds
- Places
- Contributors
- Occupations
- Lettertypes
- Times
- ... supporting ontologies



Tietomalli

letters:NL__00009996_0000001 a :Letter ;
:estimated_year 1916 ;
:fonds fonds:f2169107577047552292 ;
:has_time-span <http://ldf.fi/coco/times/time_1916-01-01T00:00:00-1916-12-31T23:59:59-1916-01-01T00:00:00-1916-12-31T23:59:59> ;
:metadata records:NL__00009996 ;
:original_data_provider sources:nationallibrary ;
:type :missing_value ;
:was_addressed_to actors:p2733526637996731453 ;
:was_authored_by actors:p1641415298093300589,
actors:p1687294493541452016,
actors:p1886281086476616465,
actors:p4082113826364268026,
actors:p5971669413030914771 ;
dct:source sources:nationallibrary ;
skos:prefLabel "1916: Borg, Einar; Heikel, O. J.; Järventaus, H. A.; Kauppinen, K.; ym. ->
Juho Rudolf Koskimies (Forsman) [NL__00009996]" .



Kiitos!