



Kielipankki – The Language Bank of Finland

Resources and services provided by FIN-CLARIN

Mietta Lennes, University of Helsinki



LANGUAGE BANK [ACCESS](#) [CORPORA](#) [TOOLS](#) [ORGANIZATION](#) [SUPPORT](#)

SUOMEKSI [PÅ SVENSKA](#)

Access



Apply for rights to use our language resources.

Corpora



Browse our corpora.

Tools



Try our tools.



Researcher of the Month: Eero Voutilainen

Organization



Who are the Language Bank?

Support



Help and instructions.

News

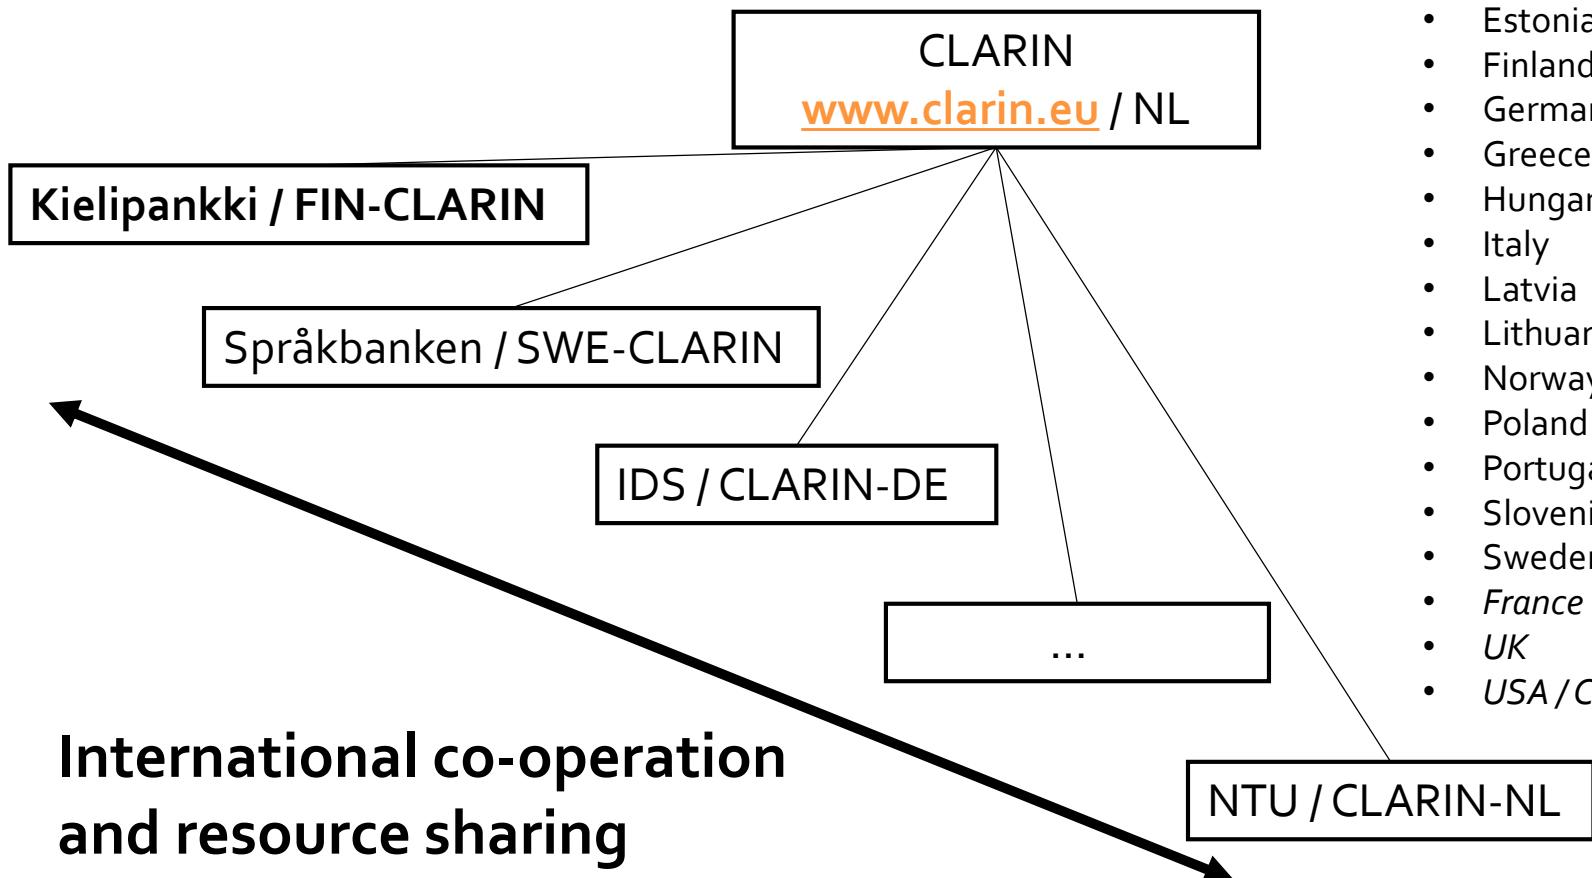
- Researcher of the Month: Eero Voutilainen (10.11.2017)
- FIN-CLARIN is looking for a project planning officer (23.10.2017)
- Researcher of the Month: Markus Juutinen (10.10.2017)
- Network maintenance 10.10.2017

CLARIN ERIC

European Research Infrastructure Consortium
founded 29. February 2012

www.kielipankki.fi

- The Netherlands
- Austria
- Bulgaria
- Czech Republic
- Denmark
- DLU
- Estonia
- Finland
- Germany
- Greece
- Hungary
- Italy
- Latvia
- Lithuania
- Norway
- Poland
- Portugal
- Slovenia
- Sweden
- France
- UK
- USA / CMU



FIN-CLARIN partners

- University of Helsinki
- CSC – IT Center for Science
- KOTUS – Institute for the Languages of Finland
- Aalto University
- University of Eastern Finland
- University of Jyväskylä
- University of Oulu
- University of Tampere
- University of Turku
- University of Vaasa



Coordinates and provides access
to **centralized corpora and tools**



Provides access to
locally developed corpora and tools

Users of the Language Bank

- Researchers from all fields welcome!
- Many corpora are available even without signing in.
- FIN-CLARIN can help you publish your own corpus.



Corpora

Gw = billion words, Mw = million words, h = hours

Resources	2017	2022
Text		
Magazines and newspapers 1770- (NLF and Web publ.)	12 Gw	20 Gw
Social media and similar sources 2000- (Suomi24, Ylilauta, ...)	4 Gw	10 Gw
Literature and manuscripts (Gutenberg, Fennica, archives)	60 Mw	70 Mw
Speech		
News broadcasts (YLE)		10000 h
Video sessions from the Finnish Parliament 2008-2016	500 h	1000 h
Dialect and everyday speech (Kotus, Turku)	500 h	1000 h
Sign language resources (Aalto, Kuurojen liitto)	20 h	500 h
Multilingual and Other Resources		
Multilingual Resources (EuroParl, laws, Bible, subtitles, ...)	3 Gw	10 Gw
Learner's resources (Oulu, Jyväskylä, Kotus, Aalto)	2 Mw	5 Mw
Open source lexicons and terminologies (Helsinki, Tromssa)	300 Kw	400 Kw

Corpora

Gw = billion words, Mw = million words, h = hours

Resources	2017	2022
Text		
Magazines and newspapers 1770- (NLF and other databases, publ.)	12 Gw	20 Gw
Social media and similar sources 2000- (Facebook, Twitter, Ylilauta, ...)	4 Gw	10 Gw
Literature and manuscripts (Gutenberg, National Archives)	60 Mw	70 Mw
Speech		
News broadcasts (YLE)		10000 h
Video sessions from the Finnish Parliament	500 h	1000 h
Dialect and everyday speech (Kotus, Suomi, Mitto, ...)	500 h	1000 h
Sign language resources (Aalto, Kotus, Mitto, ...)	20 h	500 h
Multilingual and Other Resources		
Multilingual Resources (Europarl, laws, Bible, subtitles, ...)	3 Gw	10 Gw
Learner's resources (Oulu, Jyväskylä, Kotus, Aalto)	2 Mw	5 Mw
Open source lexicons and terminologies (Helsinki, Tromsø, ...)	300 Kw	400 Kw



Korp: Corpus of Contemporary American English (COCA)

KORP SEARCH: 'TERRORIST'

Korp search interface: Suomi24 corpus

[Finnish](#) | [Swedish](#) | [Other languages](#) | [Parallel](#)
[Cite Korp](#) [Suomi](#) | [Svenska](#) | [English](#)  


10 of 657 corpora selected — 2.66G of 8.58G tokens

terroristi..nn.1

[Simple](#)
[Extended](#)
[Advanced](#)
[Compare](#)

terroristi (noun)


 also as initial part final part and case-insensitive

 in  which contain

KWIC: hits per page: 25

sort within corpora: not sorted

Statistics: compile based on: word

 Show word picture

 Show map

[KWIC](#)
[Statistics](#)
[Word picture](#)
[Map](#)
[Name classification](#)

Results: 68,735

... Go to page of 2750

[Show context](#)

SUOMI24 (1/10)

naapurimaan aluetta tykein ja ohjuksin ja **vie** jopa aseita naapurin **terroristeille**.
Alla joku väitti, että muslimeista 3 promillea muslimeista on **terroristeja**.
Jos siis otetaan kaikki muslimit mukaan **terroristeja** on $5\,500\,000 * 1.1/100 * 3/1000 = 180$. Eikö 180 ter-
t mukaan terroristeja on $5\,500\,000 * 1.1/100 * 3/1000 = 180$. Eikö 180 ter-
Tottakai JOS Kaikki olisivat **terroristeja**.
Alla joku väitti, että muslimeista 3 promillea muslimeista on **terroristeja**.
Jos siis otetaan kaikki muslimit mukaan **terroristeja** on $5\,500\,000 * 1.1/100 * 3/1000 = 180$. Eikö 180 ter-
t mukaan terroristeja on $5\,500\,000 * 1.1/100 * 3/1000 = 180$. Eikö 180 ter-
Ja sinähän tiedät että muslimeista **terroristeja** on jotain 3 promillea?
Aka **terroristien** kanssa ei neuvotella.
Kiovan rikollisen junan **terroristit** aloittivat yöllä 02.00 ensin tulituksen vapausarm-
vällä 02.00 ensin tulituksen vapausarm-**ijalkavöki läivi hyökkäykseen**.

Corpus

Suomi24 (1/10)

Metadata

Licence: CC BY-NC (CLARIN PUB)

[Cite corpus](#)

Link to corpus in Korp: urn:nbn:fi:lb-2015120401

Text attributes

title: Nato uhittelee Venäjän rajoilla lukuissa...

title word lemmas: nato uhitella Venäjä raja lukuisa ...

date: 10.06.2015

text_time: 10:09

discussion_thread_id: 13631623

Corpora in other languages

[Finnish](#) | [Swedish](#) | [Other languages](#) | [Parallel](#)
[Cite Korp](#) [Suomi](#) | [Svenska](#) | [English](#)


0

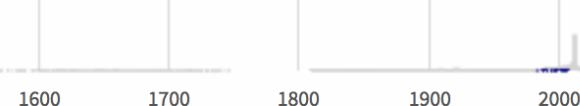

 Simple Extended

 also as initial part final

 in sentences which co

KWIC: hits per page: 25

MULCOLD englanti selected — 359.87K of 3.45G tokens


 Select all

 Select none

- ▶ ORACC (6)
- ▶ ERME (2)
- ▶ Fennno-Ugrica (10)
- ▶ English / Englanti (157)
 - ▶ E-thesis (25)
 - ▶ COCA: Corpus of Contemporary American English (beta) (5)
 - ▶ COHA: Corpus of Historical American English (beta) (75)
 - ▶ GloWbE: Global Web-based English (beta) (40)
 - ▶ ScotsCorr (beta) (9)
 - MULCOLD englanti
 - ELFA
 - Topling (English) [RES]
- ▶ Deutsch / Saksa / German (2)
- ▶ Français / Ranska / French (1)
- ▶ Español / Espanja / Spanish (1)
- ▶ Русский / Venäjä / Russian (7)
- ▶ Helsinki Corpus of Swahili 2.0 (HCS 2.0) (4)
- ▶ SUS-kenttätyö (näyte) (3)

terroristi..nn.1

Show map

COCA: Corpus of Contemporary American English (beta)

COCA: Corpus of Contemporary American English – Kielipankki Korp version 2017H1 (beta)

The COCA corpus contains about 520 million words in 220,000 texts of US English from the years 1990–2015. The corpus is evenly divided into spoken, fiction, magazine, newspaper and academic genres.

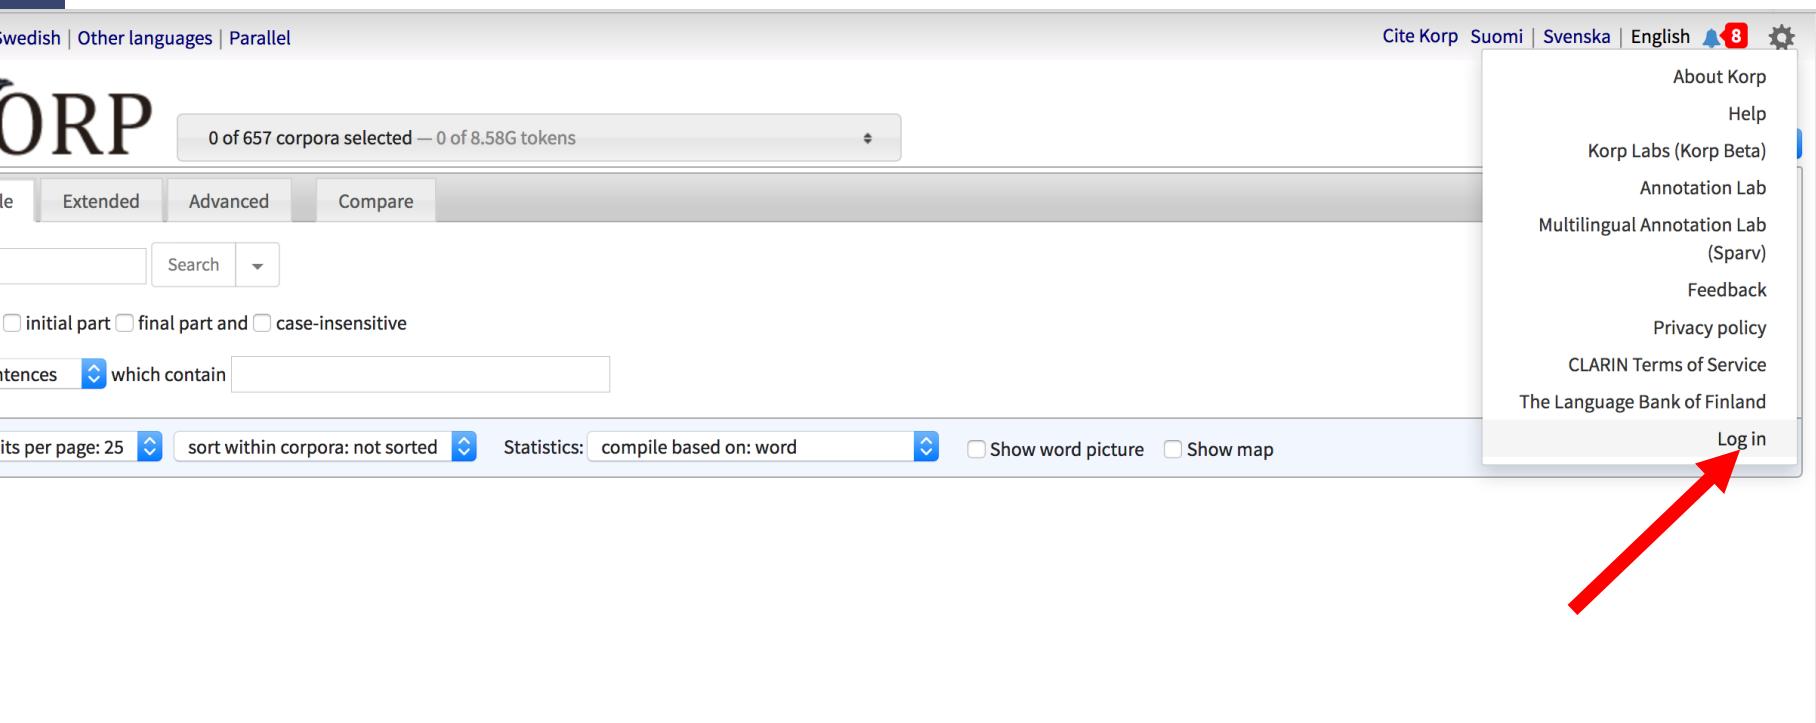
Note: To follow the US Fair Use Law, every 200 words, ten words have been removed and replaced with “@” ([more information](#)).

Metadata

Licence: ACA-Fi (Academic users in Finland)

[Cite corpus](#)

Log in to use an ACA-licensed corpus



The screenshot shows the Kielipankki search interface. At the top, there are links for "Swedish | Other languages | Parallel" and "Cite Korp Suomi | Svenska | English" with a notification badge showing '8'. The main search area displays "0 of 657 corpora selected — 0 of 8.58G tokens". Below this are tabs for "Extended", "Advanced", and "Compare", followed by a search bar with a dropdown menu. Underneath the search bar are checkboxes for "initial part", "final part and", and "case-insensitive". A search input field contains the placeholder "which contain". At the bottom of the search area are buttons for "items per page: 25", "sort within corpora: not sorted", "Statistics: compile based on: word", and checkboxes for "Show word picture" and "Show map". To the right of the search area is a sidebar with links: "About Korp", "Help", "Korp Labs (Korp Beta)", "Annotation Lab", "Multilingual Annotation Lab (Sparv)", "Feedback", "Privacy policy", "CLARIN Terms of Service", and "The Language Bank of Finland". The "Log in" button is highlighted with a red arrow.

Now select the COCA corpus in the corpus menu

Finnish | Swedish | Other languages | Parallel Cite Korp Suomi | Svenska | English Log out lennes@helsinki.fi 0 ⚙

KORP

Simple Extended S
also as initial part final
in sentences which co
KWIC: hits per page: 25

5 of 195 corpora selected — 624.40M of 3.45G tokens

1600 1700 1800 1900 2000

Select all Select none

- ▶ ORACC (6)
- ▶ ERME (2)
- ▶ Fenno-Ugrica (10)
- ▶ English / Englanti (157)
 - ▶ E-thesis (25)
 - ▶ COCA: Corpus of Contemporary American English (beta) (5)
 - COHA: Corpus of Historical American English (beta) (75)
 - ▶ GloWbE: Global Web-based English (beta) (40)
 - ▶ ScotsCorr (beta) (9)
 - MULCOLD englanti
 - ELFA
 - Topling (English) [RES]
- ▶ Deutsch / Saksa / German (2)
- ▶ Français / Ranska / French (1)
- ▶ Español / Espanja / Spanish (1)
- ▶ Русский / Venäjä / Russian (7)
- ▶ Helsinki Corpus of Swahili 2.0 (HCS 2.0) (4)
- ▶ SUS-kenttätyö (näytte) (3)

Show map

COCA: Corpus of Contemporary American English (beta)

COCA: Corpus of Contemporary American English – Kielipankki Korp version 2017H1 (beta)

The COCA corpus contains about 520 million words in 220,000 texts of US English from the years 1990–2015. The corpus is evenly divided into spoken, fiction, magazine, newspaper and academic genres.

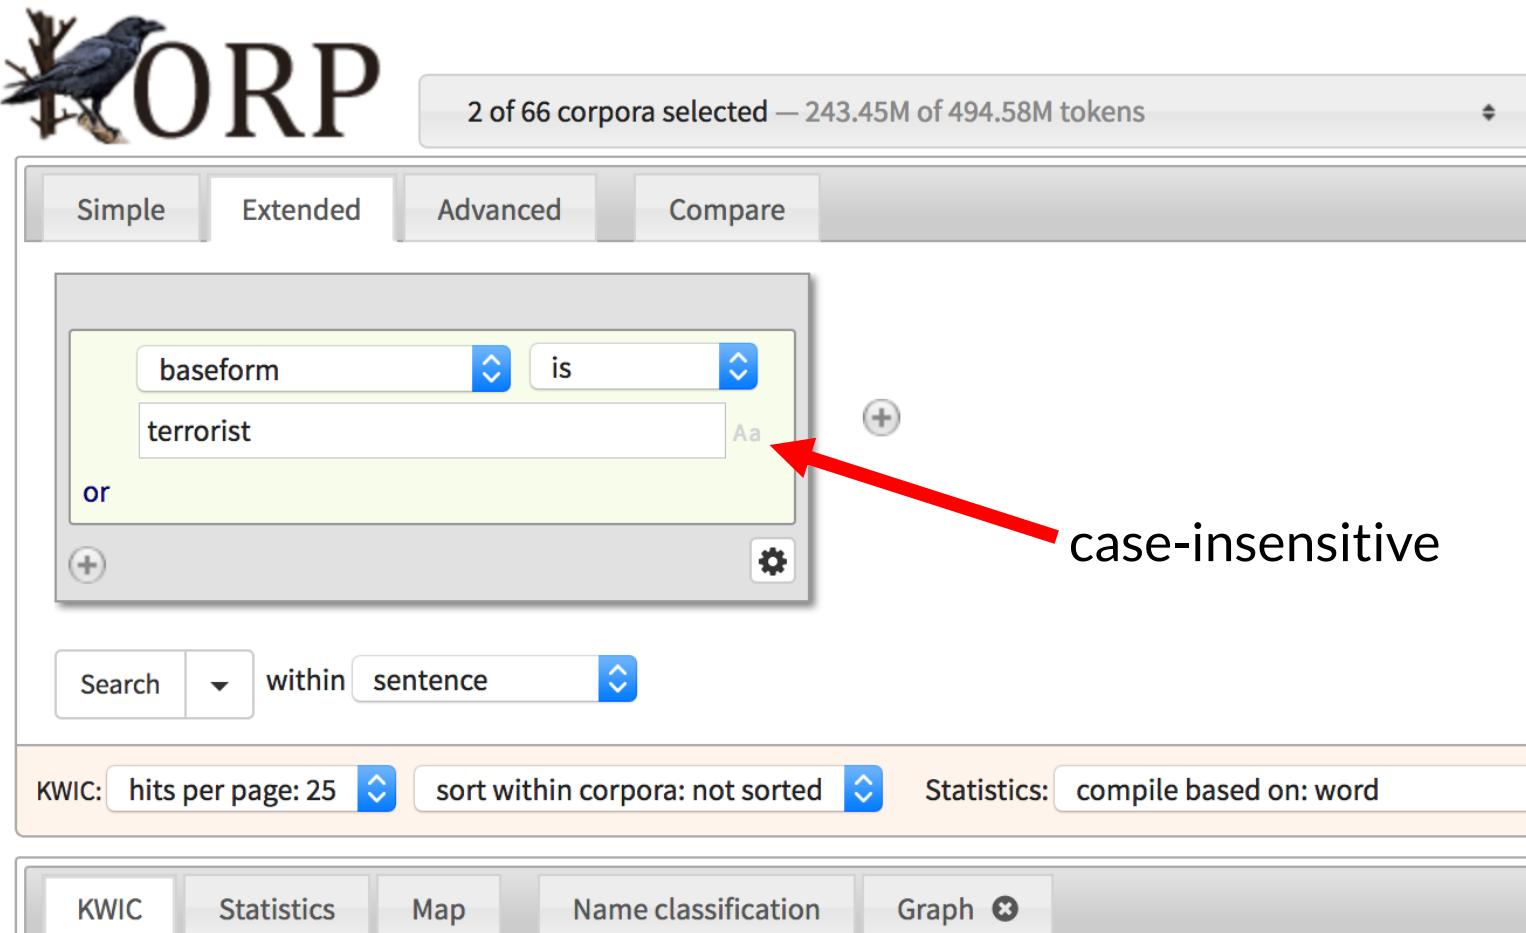
Note: To follow the US Fair Use Law, every 200 words, ten words have been removed and replaced with "@" ([more information](#)).

Metadata
Licence: ACA-Fi (Academic users in Finland)
[Cite corpus](#)

terroristi..nn.1

Search for any form of the word 'terrorist' ("Extended" tab)

Finnish | Swedish | Other languages | Parallel



2 of 66 corpora selected — 243.45M of 494.58M tokens

Simple Extended Advanced Compare

baseform is terrorist

or

Search within sentence

KWIC: hits per page: 25 sort within corpora: not sorted Statistics: compile based on: word

KWIC Statistics Map Name classification Graph

'terrorist'

baseform is terrorist
or

Search within sentence

KWIC: hits per page: 25 sort within corpora: not sorted Statistics: compile based on: word Show map

KWIC Statistics Map Name classification Graph

Results: 5,392

« ‹ 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 ... › » Go to page of 216 Show context

COCA: ACADEMIC (BETA)

carrying the ANC delegation swept by (the irony of the police escort for these former " terrorists " was not missed), as both parties expressed a sincere desire to move away from the rights of @ @ @ @ @ @ @ kind of regional, racial and religious conflicts, terrorist tactics and conventional, chemical or nuclear arms buildups that threaten the potential deterrent forces to other parts of the world, toward local low-intensity conflicts and terrorist activities, toward hostile acts by undemocratic and unpredictable governments Israel forced Egypt, Syria and Jordan to proscribe direct cross-border terrorist attacks.

In addition new East European governments are inhospitable to international terrorists, denying them indispensable training bases and logistical backing, which were designed for tactical use against helicopters but can also easily be used by terrorists against passenger-carrying commercial aircraft. As the possibility, let alone like

Only humans, @ @ @ @ @ @ @ as the composition and action plans of terrorist groups or of narcotics traffickers.

uickly transferring large sums of money in ways that draw @ @ @ @ @ @ @ by terrorists, narcotics traffickers and others who need to move or launder money discreetly. nly welcome special operations that rescued hostages and punished hostage-takers or terrorists for their actions, particularly if their depredations were then curtailed -- as Muar n being informed of the plans that the Minister of Defence had made to eliminate the " terrorist leaders " before he would agree to vote in favour of additional appropriations to ciations if they had cause to believe that the aid was derived @ @ @ @ @ @ @ terrorists " in the West Bank and Gaza Strip.

the plan drawn @ @ @ @ @ @ his assassination by Menachem Begin's/Irgun terrorists), calling for a division of the old state of Palestine into Arab and Jewish sectors.

The Terrorism Act of 1967 allows indefinite detention of those suspected of terrorist crimes, which would include belonging to any banned organization.

own propaganda as right-wing support erodes for a government that negotiates with " terrorists " and " communists. "

uierda Revolucionario) and was an active proponent of the human rights of suspected terrorists.

The value of the Mothers is their refusal to accept the terms of the terrorist state, to articulate the existence of a responsible party which has disappeared th

Corpus

COCA: Academic

URN: [to be a
Metadata

Licence: ACA-

Text attribut

genre: ACAD

subgenre: 20C

year: 1990

source: Africa

title: Aparthe

Africa.

publication in

Vol. 37 Issu

text id: 195

file name: wlp

paragraph_ty

part of the se

Show Trend Diagram

terrorist Aa
or + 

Search within sentence 

KWIC: hits per page: 25  sort within corpora: not sorted  Statistics: compile based on: word  Show

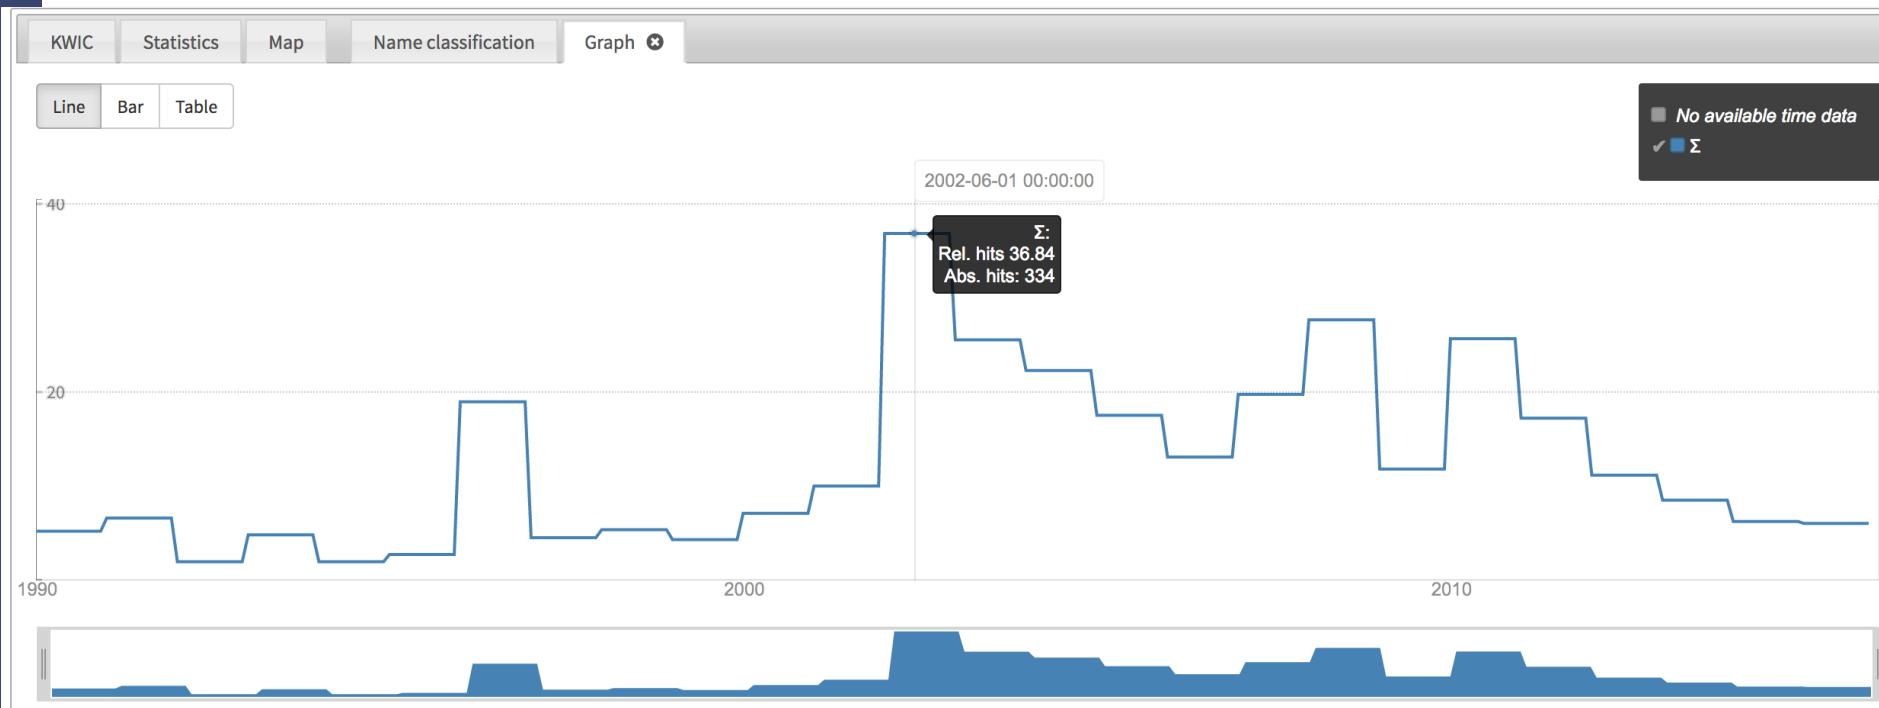
KWIC **Statistics** **Map** **Name classification**

Values: 1

 [Show Trend Diagram](#)

	word	Total	COCA: Acad...	COCA: Fictio...	
<input checked="" type="checkbox"/>	Σ	 12,4 (3 029)	19,7 (2 353)	5,5 (676)	
<input type="checkbox"/>	terrorist	 12,4 (3 029)	19,7 (2 353)	5,5 (676)	

Trend Diagram





Korp and LAT, speech corpora

DIALECT VARIANTS OF THE WORD *METSÄ* 'FOREST'

Samples of Spoken Finnish (dialects)

ELAN 4.9.4 - SKN17a_Liperi.eaf

File Edit Annotation Tier Type Search View Options Window Help

Grid Text Subtitles Lexicon Comments Recognizers Metadata Controls

AL-sentence

> Nr	Annotation
1	-- 'kiirettä 'maltto , 'maltto , "huasteelian 'nythän se "kuul , 'samassa .
2	mittees 'sit _ossois su- , "mittees sitä 'ossois vielä , 'vielä , 'huasteela ?
3	Karhusua'r _on , 'nyttiiv vie[lä].
4	'kyllä se tuo "käuppias 'tietää 'onha se 'käön[yt].
5	's _on tuossa 'yl s- , 'yl 'selän 'tuosta .
6	'tuossa on , 'tä kun _on 'semmonnen , "niemimua koko , tä 'Ruokolahti 'kahem puolen _oj "järvet 'tuossa .

00:00:24.765 Selection: 00:00:24.765 - 00:00:27.011 2246

00:00:22.000 00:00:23.000 00:00:24.000 00:00:25.000 00:00:26.000 00:00:27.000 00:00:28.000 00:00:29.000 00:00:30.000

SKN17a_Lip... 000

AL-sentence [699] 000 00:00:22.000 00:00:23.000 00:00:24.000 00:00:25.000 00:00:26.000 00:00:27.000 00:00:28.000 00:00:29.000 00:00:30.000

AL-sentence-norm [699] Karhusua'r _on , 'nyttiiv vie[lä].

MP-sentence [29] Karhusaari on nytkin vielä

MP-sentence-norm [29] 'kyllä se tuo kauppias tietää onhan se käynyt

N-sentence [1] 's _c se or

M-sentence [111]

00:00:22.000 00:00:23.000 00:00:24.000 00:00:25.000 00:00:26.000 00:00:27.000 00:00:28.000 00:00:29.000 00:00:30.000

SKN corpus: words that begin with *metsä*

[Suomi](#) | [Ruotsi](#) | [Muut kielet](#) | [Rinnakkaistekstit](#)
[Viittaa Korpiaan](#) [Suomi](#) | [Svenska](#) | [English](#)  

KORP SKN – Suomen kielen näytteitä valittu — 841,75K / 8,00G sanetta

Yksinkertainen Laajennettu Edistynyt Vertailu

Aa

Etsi virkkeen sisältä

Konkordanssi: osumia sivulla: 25 järjestää korpuksen sisällä: järjestämätön Tilastoja: laske tilastot tämän perusteella: tarkkeeton sananmuoto Näytä sanakuva Näytä kartta

Compile statistics according to
original transcribed word form
without diacritics



Konkordanssi Tilastoja Sanakuva Kartta Nimiluokittelu

Tuloksia: 928 Siirry sivulle / 38 Näytä konteksti

SKN – SUOMEN KIELEN NÄYTTEITÄ

Siellä kuin yhden -, Kuittijärvillä kyllä paljon olen käynyt lesnoin, **metsänhoitajalla** luona silloin kun Venäjän puolelta hakattiin niin, piiripäällikö kun, **metsänhoitaja**, tuo, metsävartijat oli niin viisaita sitten olisi ollut niin hirmuui oli niin viisaita sitten olisi ollut niin hirmuinen maksu niin ne - mennyt ja silloin sitä lähdettiin itse kukin kotiin.

kun, metsänhoitaja, tuo, metsävartijat metsäsynnyin Ouluyhtiössä niin se, se se kävi sen kaupan tekemässä Venäjä aamulla sanoo lesnoi nyt se on metsänhoitajana metsään tehtiin kämpä, Pölhönpuron varteen siellä ja, ruvettiin ja siir - , Ouluyhtiön puita, oululainen sen - vanhan, Viikmannin, joka oli, metsässä .

-, Jumalissäkkistä hakattiin siinä oli kuusi hevosta porukassa ja metsän metsääjoa puoleiseen päähän tehdä ja alkupäähän sen puomipuu, -, puun niin myöhään meni kevääksi aina se ajo niin, eivät saane

Korpus

SKN – Suomen kielen näytteitä

URN: urn:nbn:fi:lb-201407141
Kuvailutiedot
Lisenssi: CC BY 4.0 (CLARIN PUB)

Tekstin ominaisuudet

otsikko: Suomussalmen murretta (vihko 1)
päiväys: 1978
kirjoittaja: Alpo Räsänen
paikkakunta: Suomussalmi

Statistics: transcribed forms of *metsä*

Konkordanssi Tilastoja Sanakuva Kartta Nimiluokittelu

Arvoja: 372

Näytä trendidiagrammi

<input type="checkbox"/> tarkkeeton sananmuoto	Yhteensä	SKN – Suomen kielen näytteitä
<input checked="" type="checkbox"/> Σ	1 102,5 (928)	1 102,5 (928)
<input type="checkbox"/> mettäs	72,5 (61)	72,5 (61)
<input type="checkbox"/> mettää	61,8 (52)	61,8 (52)
<input type="checkbox"/> metässä	42,8 (36)	42,8 (36)
<input type="checkbox"/> mettä	41,6 (35)	41,6 (35)
<input type="checkbox"/> metsää	27,3 (23)	27,3 (23)
<input type="checkbox"/> mettästä	24,9 (21)	24,9 (21)
<input type="checkbox"/> mettät	21,4 (18)	21,4 (18)
<input type="checkbox"/> metästä	21,4 (18)	21,4 (18)
<input type="checkbox"/> mettäst	20,2 (17)	20,2 (17)
<input type="checkbox"/> mettäh	19 (16)	19 (16)
<input type="checkbox"/> mettän	19 (16)	19 (16)
<input type="checkbox"/> metsäs	19 (16)	19 (16)
<input type="checkbox"/> mettässä	17,8 (15)	17,8 (15)
<input type="checkbox"/> mehtää	16,6 (14)	16,6 (14)
<input type="checkbox"/> mehtä	14,3 (12)	14,3 (12)
<input type="checkbox"/> mettaan	13,1 (11)	13,1 (11)
<input type="checkbox"/> mehtään	13,1 (11)	13,1 (11)
<input type="checkbox"/> messää	11,9 (10)	11,9 (10)

Click on “Listen in Annex”

Konkordanssi: osumia sivulla: 25 järjestä korpuksen sisällä: järjestämätön Tilastoja: laske tilastot tämän perusteella: tarkkeeton sananmuoto Näytä sanakuva
 Näytä kartta

Konkordanssi Tilastoja Sanakuva Kartta Nimiluokittelu Konkordanssi

Tuloksia: 12

« < **1** > » Siirry sivulle / 1 Näytä konteksti

SKN – SUOMEN KIELEN NÄYTTEITÄ

täjä ja siellä olisi kaunis paikka mutta kun on raja niin likellä niin, kun nyt metsä hakattiin ja siitä tulee kolmisenkymmentä kilometriäkö täältä vaan · enkymmentä kilometriäkö täältä vaan -, vieläkö enempä matkaa niin kun metsä hakattiin niin tämä kirkon torni selvästi näkyy.
käymään sitten jossakin tietäjässä ja se oli tiennyt sanoa että ne on niitä, metsä pitää.
ti että ne tänä päivänä pääsee sieltä lähtemään että ne on ollut niin kuin, metsä pitänyt.
onko heitä sitten, semmoisiakin tapauksia minä en tiedä pitääkö metsä, mutta niin se, kertoi.
no kertoikos ne sellaista että olisi ihmistäkin pitänyt metsä joskus?
nyt niin paikan päällä, tuosta vähän -, tuonne noin tuo -, kun tuo matala metsä, -, alkaa ja tuossa pitkin niin, se oli Venäjänkorpi.
ei hän sitä nyt, kenenkään metsään niin se piti olla, semmoinen luvattu metsä mistä, meni ympäri, .
minähän lähdin sitten ja joka oli se -, metsä sõi siltä ne vaattetkin että ne hetuleet meni vain jäljissä niin.
e kun se oli se metsänpeitto kun sanottiin että karja, karja, karjan peittää metsä.
jos oli äijä oksia niin se paloi - mutta jos ei ollut, oikein, sankka metsä ja petäjiä seassa niin tuota, sitä sitten, -, rovio kun se oli pitkä rovio,
sanoin jotta en minä kehtaa kiusata kun, petäjää on kuitenkin ja, valtion metsä on vielä meillä tässä syötävänä niin.

« < **1** > » Siirry sivulle / 1

Lataa tiedostona muodossa:

alkuperäinen sana: 'mehtä
tarkkeeton sananmuoto: mehtä
kommentti: [tyhjä]

Lataa FAF-tiedosto

Listen to the utterance

Annex 1.6.42702 [manual](#) [?](#) [embed](#) Show tooltips [Compact](#)  Spacious [user: anonymous](#) [login](#)

Text **Video display** **Information** **Mini Data Frame**

Grid

Subtitle

Waveform

Timeline

Combined

No video, only audio

Resource: SKN19b_Kalajoki.eaf
Media file: SKN19b_Kalajoki.m4a
Elapsed time: 00:33:43:765

Selected chunk:
Begin time: 00:33:43:765
End time: 00:33:51:482
Text: -

Tier: **none**

Font size: **14**

Play selection

Clear selection

Create bookmark

I < **> I**

<< **>>**

< **>**

+ **-**

Play screen by screen
 Play continually

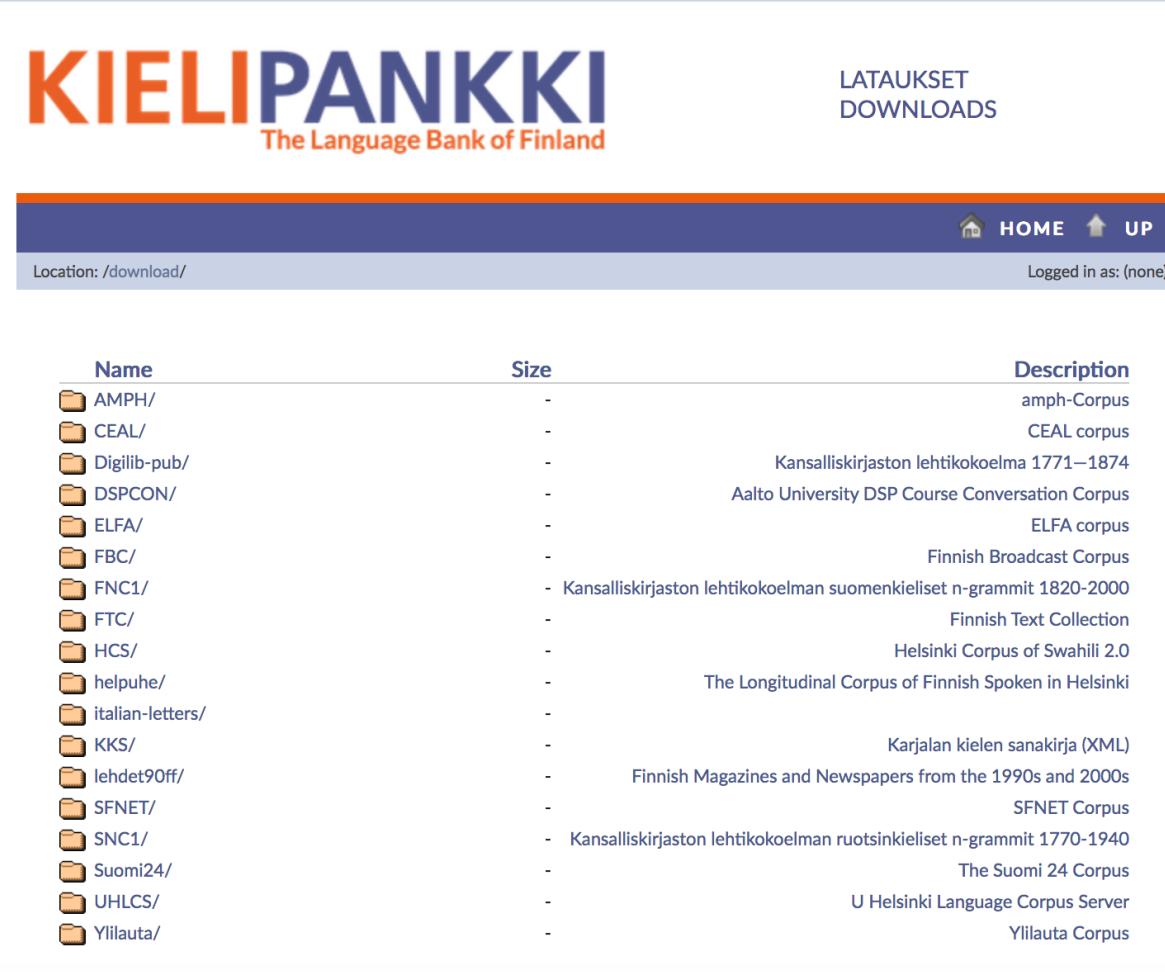
Tier text font: **Select a font**

Timeline

	00:33:40:000	00:33:42:000	00:33:44:000	00:33:46:000	00:33:48:000	00:33:50:000	00:33:52:000
TT-sentence							
ES-sentence	en ny 'hänej "jäläkiin että "hää 'c nc		'määhäl "lähin 'sitte 'a joka 'oli se pit- , 'mehtä "söi 'siltä ne 'vaatteeksi että ne "hetuleet 'meni väj "jälisä r				
TT-sentence-no:							
ES-sentence-no:	ten nyt hänen jälkiin että hän op nc		minähän lähdin sitten ja joka oli se - metsä söi siltä ne vaattetkin että ne hetuleet meni vain jälissä niin				

Download service:

www.kielipankki.fi/download



The screenshot shows the 'LATAUKSET DOWNLOADS' (Downloads) section of the Kielipankki website. The page header includes the Kielipankki logo and the text 'LATAUKSET DOWNLOADS'. The navigation bar at the top right includes links for 'HOME' and 'UP', and a status message 'Logged in as: (none)'. The main content area displays a table of downloadable corpus entries, each with a folder icon, name, size, and description.

Name	Size	Description
AMPH/	-	amph-Corpus
CEAL/	-	CEAL corpus
Digilib-pub/	-	Kansalliskirjaston lehtikokoelma 1771–1874
DSPCON/	-	Aalto University DSP Course Conversation Corpus
ELFA/	-	ELFA corpus
FBC/	-	Finnish Broadcast Corpus
FNC1/	-	Kansalliskirjaston lehtikokoelman suomenkiiset n-grammit 1820-2000
FTC/	-	Finnish Text Collection
HCS/	-	Helsinki Corpus of Swahili 2.0
helpuhe/	-	The Longitudinal Corpus of Finnish Spoken in Helsinki
italian-letters/	-	
KKS/	-	Karjalan kielen sanakirja (XML)
lehdet90ff/	-	Finnish Magazines and Newspapers from the 1990s and 2000s
SFNET/	-	SFNET Corpus
SNC1/	-	Kansalliskirjaston lehtikokoelman ruotsinkieliset n-grammit 1770-1940
Suomi24/	-	The Suomi 24 Corpus
UHLCS/	-	U Helsinki Language Corpus Server
Ylilauta/	-	Ylilauta Corpus

Edit / search annotations in ELAN

ELAN 4.9.1-b

ELAN - SKN19b_Kalajoki_full.eaf

File Edit Annotation Tier Type Search View Options Window Help

Text Grid Subtitles Lexicon Metadata Recognizers Comments **Controls**

Volume: 100

SKN19b_Kalajoki.wav

Mute Solo

Rate: 100

Selection: 00:00:00.000 - 00:00:00.000 0

00:00:00.000 00:03:42.000 00:03:43.000 00:03:44.000 00:03:45.000 00:03:46.000 00:03:47.000 00:03:48.000 00:03:49.000 00:03:50.000 00:03:51.000 00:03:52.000 00

SKN19b_Kal... 00:03:42.000 00:03:43.000 00:03:44.000 00:03:45.000 00:03:46.000 00:03:47.000 00:03:48.000 00:03:49.000 00:03:50.000 00:03:51.000 00:03:52.000 00

TT-sentence [24] noh määhäl lähin sitte a joka oli se pit-, mehtä söi siltä ne vaatteekki että ne hetuleet meni väh jälisä ni.

ES-sentence [367]

TT-sentence-norm [24]

TT-word-original [200]

TT-word-norm [167]

ES-sentence-norm [367] noh minähän lähdin sitten ja joka oli se - metsä söi siltä ne vaattetkin että ne hetuleet meni vain jäljissä niin

ES-word-original [6807] noh määhäl lähin sitte a joka oli s pit-, mehtä söi siltä n vaatteekki että n hetuleet meni väh jälisä nil.

noh minähän lähdin sitten ja joka oli s - metsä söi siltä n vaattelkin että n hetuleet meni vain jälisä nil.

KIELIPANKKI

The Language Bank of Finland

LANGUAGE BANK ACCESS CORPORA TOOLS ORGANIZATION SUPPORT

SUOMEKSI PÅ SVENSKA

Corpora deposited in the Language Bank

Location

The corpora in the Language Bank may be accessible via a web interface ([Korp](#) and [LAT](#)) or by using command line tools on the Language Bank's software server. Some corpora can also be downloaded ([Download](#)).

License

Some corpora are directly available [PUB](#), some may be accessed by signing in [ACA](#) or by applying for individual access rights [RES](#). Protected corpora can be accessed following the link [●](#) in the [Apply](#) column. Access instructions.

Cite

Corpora-specific reference instructions are available by clicking the quote [»](#) link.

Abbreviation	Name and metadata	License	Apply	Location	Help	Cite
acquis-ftb3	The Finnish Sub-corpus of the JRC-Acquis Multilingual Parallel Corpus	PUB		Korp		»
aku-egg	Speech and EGG (Electroglossography) Simultaneous Recordings	ACA		LAT		»
amph	amph-Corpus	ACA		Lataus		»
ArkiSyn-korp	ArkiSyn Database of Finnish Conversational Discourse, Helsinki Korp Version	PUB		Korp		»
BeserCorp	The Corpus of Beserman Udmurt	PUB		Korp		»
Classics of English and American Literature						

Kielipankki corpora

<https://www.kielipankki.fi/corpora/>

Downloadable Version					
Suomi24-2001-2014-korp	The Suomi 24 2001-2014 (Sample) Corpus, Helsinki Korp Version		Korp		”
Suomi24-2001-2015	The Suomi 24 2001-2015 (Sample) Corpus			Download	”
Suomi24-2016H2	The Suomi 24 Corpus (2016H2)			Download	”
Suomi24-korp-2016H2	The Suomi 24 Sentences Corpus (2016H2)		Korp		”

Reference instructions

Kielipankki corpora

<https://www.kielipankki.fi/corpora/>

[suomeksi] [in English]

Reference instructions: Suomi24-korp-2016H2

Please cite the language resource as follows:

Aller Media Ltd. (2014). *The Suomi 24 Sentences Corpus (2016H2)* [text corpus]. Kielipankki. Retrieved from <http://urn.fi/urn:nbn:fi:lb-2017021505>

[Bibtex] [Zotero]

Suomi24-20 16H2	The Suomi 24 Corpus (2016H2)		Download	“
Suomi24- korp-2016H 2	The Suomi 24 Sentences Corpus (2016H2)		Korp	”
susanne- uhlcs	The Susanne Corpus (UHLCS)		Taito	”



Kielipankki list of corpora

<https://www.kielipankki.fi/corpora/>

01-2015	(Sample) Corpus			
Suomi24-2016H2	The Suomi 24 Corpus (2016H2)		Download	" "
Suomi24-korp-2016H2	The Suomi 24 Sentences Corpus (2016H2)		Korp	" "
susanne-uhlcs	The Susanne Corpus (UHLCS)		Taito	" "

Metadata



321 16

The Suomi 24 Sentences Corpus (2016H2)

▶ View resource name in all available languages

Suomi24-korp-2016H2

<http://urn.fi/urn:nbn:fi:lb-2015120401>

ID: <http://urn.fi/urn:nbn:fi:lb-2017021505>

The corpus is available in Kielipankki - the Language Bank of Finland (korp.csc.fi), <http://urn.fi/urn:nbn:fi:lb-2015120401> (sub-corpora 1/10-10/10).

The corpus contains all the discussion forums of the Suomi24 online social networking website from 1st January 2001 to 24th September 2016 available... [Read More](#)

▶ View resource description in all available languages

[« Back](#)

[Edit Resource](#)

Distribution
Availability
Available - Unrestricted Use
Licence
CC - BY - NC
Restrictions:
Attribution
Attribution Details:
See Documentation section.
Distribution Access/Medium:
Accessible Through Interface

text
Monolingual text corpus
Languages
Finnish
Linguality
Linguality type: Monolingual
Size
2,663,114,497 Tokens
Modalities
Written Language
Metadata
Created:
09/17/2015
Last Updated:
09/17/2015
Metadata Language:
English, Finnish (en, fi)
Metadata Creator
Imre Bartis
Version
Version: 2016H2
Relation
Detailed Description The Suomi24 S

Kielipankki list of corpora

<https://www.kielipankki.fi/corpora/>

SSDC-2016	Skolt Saami Documentation Corpus (2016)			LAT	”
Stu- dentsvenska	Studentsvenska 79-80 -korpus			Korp	”
Suomi24-20	The Suomi 24 2001-2014				

Licence (restricted use)



LANGUAGE BANK ACCESS CORPORA TOOLS ORGANIZATION SUPPORT

SUOMEKSI PÅ SVENSKA

CLARIN RES end-user license +PRIV 1.0

Resource: Skolt Saami Documentation Corpus (2016) (URN: <urn:nbn:fi:lb-2014073037>)

Copyright holder: University of Helsinki and Institute for the Languages of Finland

The Copyright holder grants the End-User a free, non-exclusive and perpetual (for the duration of the copyright) right to use and make copies of the Resource for personal use as such, as modified, or as part of a compilation or derived work. The permission applies to all known or future modes and means of communication and includes a right to make modifications enabling the use of the Resource on other devices and in other formats.

Additional license terms as defined in the Terms of Service Agreement:

Identification and Access Conditions

- ID: The user needs to be authenticated or identified.
- PLAN: The right holder requires a research plan for granting access.

General Use conditions

- BY: Attribution, i.e. acknowledgement of authorship, is required.
- PRIV: There are personal data in the resource.

Distribution conditions

- NORED: The user is not permitted to redistribute the resource.

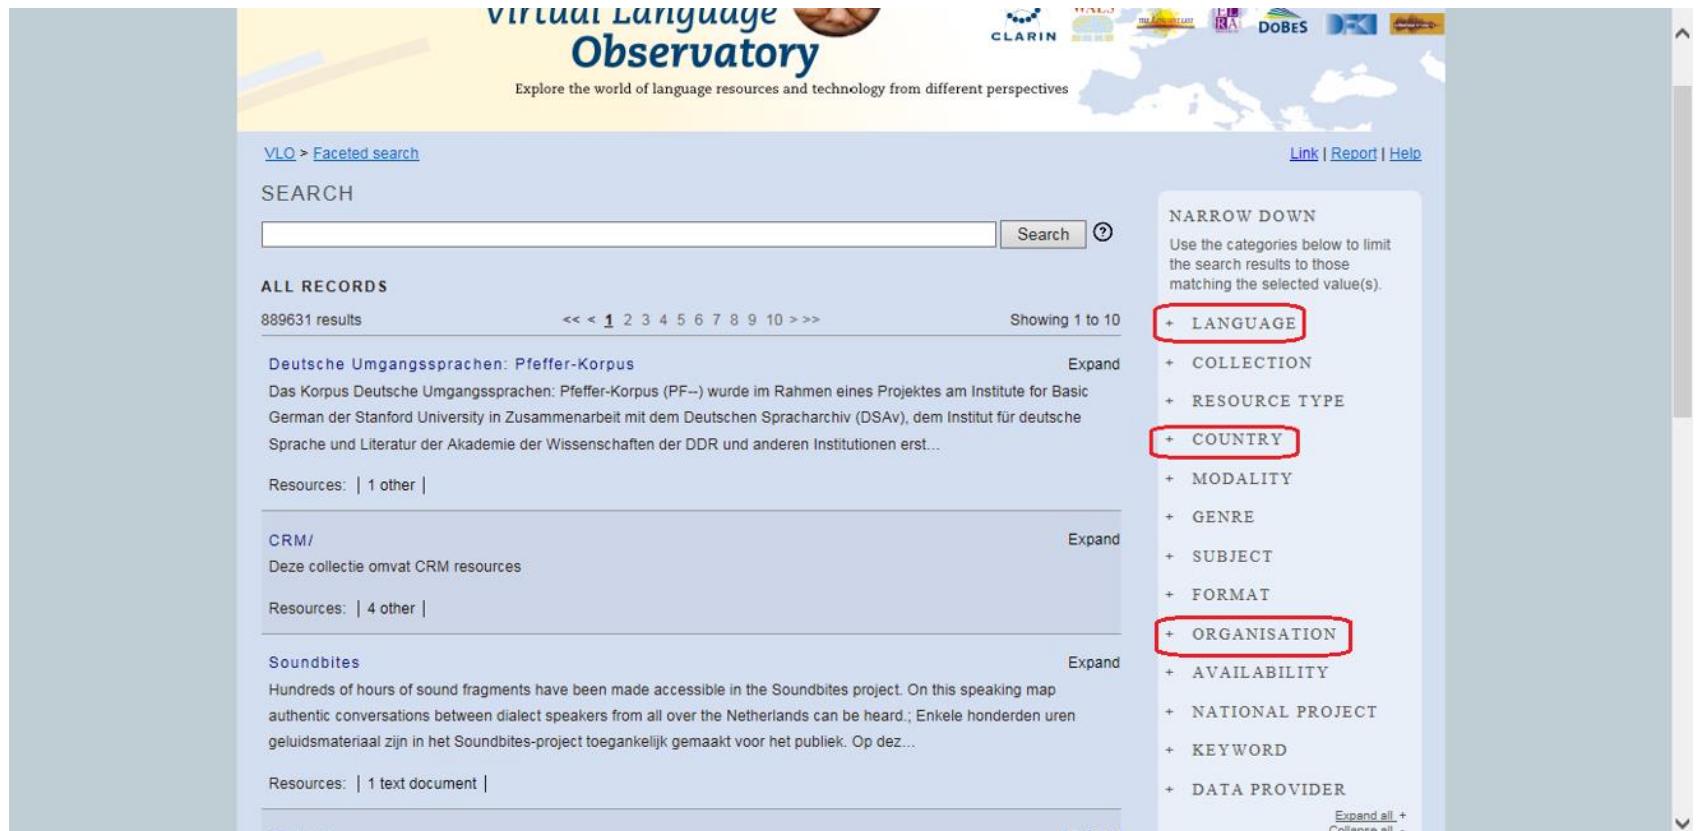
This license has been made in compliance with copyright agreements by WIPO – the World Intellectual Property Organization. The rights granted in this license shall be so interpreted that in case applicable intellectual property laws grant rights not mentioned in this license, they are also regarded as part of the rights to be licensed; the purpose of this license is not to restrict any rights intended to be licensed within different legal systems. Additional rights to the Resource may be agreed separately in writing.

Finding corpora: Metadata catalogues



Search metadata via VLO

vlo.clarin.eu



VIRTUAL LANGUAGE Observatory

Explore the world of language resources and technology from different perspectives

[Link](#) | [Report](#) | [Help](#)

SEARCH

[Search](#) [?](#)

ALL RECORDS

889631 results [<< < 1 2 3 4 5 6 7 8 9 10 >>](#) Showing 1 to 10

Deutsche Umgangssprachen: Pfeffer-Korpus [Expand](#)

Das Korpus Deutsche Umgangssprachen: Pfeffer-Korpus (PF-) wurde im Rahmen eines Projektes am Institute for Basic German der Stanford University in Zusammenarbeit mit dem Deutschen Spracharchiv (DSA), dem Institut für deutsche Sprache und Literatur der Akademie der Wissenschaften der DDR und anderen Institutionen erst...

Resources: | 1 other |

CRM/ [Expand](#)

Deze collectie omvat CRM resources

Resources: | 4 other |

Soundbites [Expand](#)

Hundreds of hours of sound fragments have been made accessible in the Soundbites project. On this speaking map authentic conversations between dialect speakers from all over the Netherlands can be heard.; Enkele honderden uren geluidsmateriaal zijn in het Soundbites-project toegankelijk gemaakt voor het publiek. Op dez...

Resources: | 1 text document |

NARROW DOWN

Use the categories below to limit the search results to those matching the selected value(s).

- + LANGUAGE
- + COLLECTION
- + RESOURCE TYPE
- + COUNTRY
- + MODALITY
- + GENRE
- + SUBJECT
- + FORMAT
- + ORGANISATION
- + AVAILABILITY
- + NATIONAL PROJECT
- + KEYWORD
- + DATA PROVIDER

[Expand all +](#) [Collapse all -](#)

Search META-SHARE

metashare.csc.fi



META-SHARE

Logout

Use Resources Manage Resources Administration Community Documentation Statistics Your Profile, Inve

META-SHARE

311 language resources at your disposal

Type in your keywords, please...

What is it? - About the project

META-SHARE, the open language resource exchange facility, is devoted to the sustainable sharing and dissemination of language resources (LRs) and aims at increasing access to such resources in a global scale.

Language Bank support

www.kielipankki.fi/support

Helpdesk regarding the corpora:

fin-clarin@helsinki.fi

Technical support:

kielipankki@csc.fi



Ohjeita ja oppaita

- Käyttöoikeudet ja niiden hakeminen
- Tutkijan käyttöliittymä
- Työkalujen käyttöohjeet



Uutisia

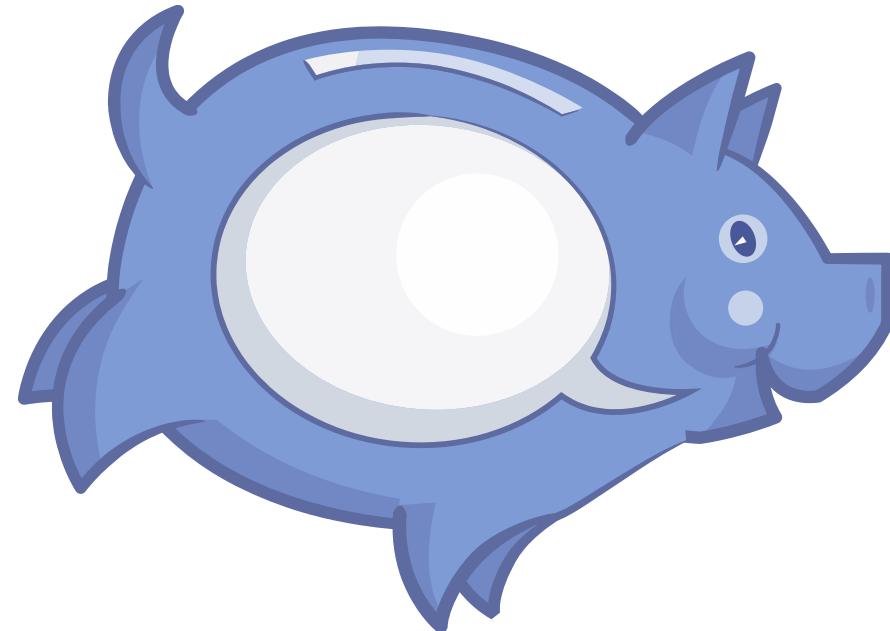
Courses

- FIN-CLARIN organizes online courses that are open to all Finnish universities (restricted number of participants from abroad):
 - Corpus linguistics and statistical methods (introductory course), 5 credits
 - Puheen analyysin perusteet – Introduction to speech analysis (Praat and ELAN), 5 credits
 - Corpus Clinic – Aineistoklinikka, 5 credits
- Starting from autumn 2018, Introduction to speech analysis will be organized in English.

Staying tuned

- Subscribe to the newsletter (see website)
- Follow us on
 - Facebook: Kielipankki – The Language Bank of Finland
 - Twitter: @FinClarin
- Website:

www.kielipankki.fi



Kiitos! Thank you!