

# Bilingual Lexicography: Relevance of Corpora

## The example of German-Basque as language pair

David Lindemann  
PhD cand.  
UPV-EHU University of the Basque Country  
[david.lindemann.soraluze@gmail.com](mailto:david.lindemann.soraluze@gmail.com)



# Motivation for this paper

## The Problem

Translation Studies, Philology, Lexicography vs. Computational Linguistics

- ▶ Experts on both sides, lack of comprehensive discipline-linking publications with focus on practical issues

Low or Medium Density Languages and more or less 'exotic' Language Pairs

- ▶ DE-EN is not DE-EU is not FI-EU

## The Intention

Useful information for lexicographers that start from scratch

- ▶ as computational linguist
  - ▶ as corpus linguist
- ▶ with no or little work done on their language pair

## The Example

- ▶ German-Basque

# Overview

- ▶ 1. Lexicography and Corpus Linguistics
- ▶ 2. Bilingual Lexicography and Corpus Linguistics
  - ▶ 2.1 Corpus based lemma list retrieval (German)
    - ▶ 2.1.1 Comparing corpus-based vs. editorial-only lemmalist
  - ▶ 2.2 Corpora and Corpus based lemma list retrieval (Basque)
  - ▶ 2.3 Usage examples from monolingual corpora
  - ▶ 2.4 Translation examples from parallel corpora
- ▶ 3. New DE-EU dictionary: Editing, Corpora, Tools
  - ▶ 3.1 New DE-EU dictionary: frontend design
  - ▶ 3.2 New DE-EU Literary Corpus
  - ▶ 3.3 Verb entry
  - ▶ 3.4 Noun entry
  - ▶ 3.5 Adjective and Adverb
- ▶ 4. Automatic pairing of Translation Equivalents or SADD
  - ▶ Corpus-based methods, Wikimedia, WordNet
- ▶ 5. Conclusions

# 1. Lexicography and Corpus Linguistics

## ► Making dictionaries from corpora

- Introductions: Atkins & Rundell 2008: 53-96; Svensén 2009:43-58
- “Corpus Linguistics and Lexicography” (Teubert 1999, 2002, 2007)
- “Corpus Lexicography” (Kilgarriff & Tugwell 2002, Kilgarriff 2012)
- “Korpusgestützte Lexikographie” (Klosa 2007)

- Quantity: Large electronic corpora, much larger than in pre-computer age
- Quality: Human made index cards vs. e-corpora: The rare rather than the common
- Automatic retrieval of frequency lists / lemma lists
- Lexicographers' Documentation process when editing entries
  - Concordances (KWIC)
  - Cooccurrence / Collocation Statistics / Multiword LU
  - 'Wordsketch' incl. grammar (eg for verbs: Subjects, objects, prepos., conjunct.)
- “Corpus-based” vs. “corpus-driven” lexicography: Trust Corpora for WSD?
- Evidence from parallel corpora: TE proposed by biling. dics vs. translators' choice
- Data from large corpora in electronic dictionary publishing
  - On-the-fly KWIC generation as part of dictionary search result page
    - as shown on some (still not many) dictionary websites

## 2. Bilingual Lexicography and Corpus Linguistics

### ► Monolingual and Bilingual Lexicography:

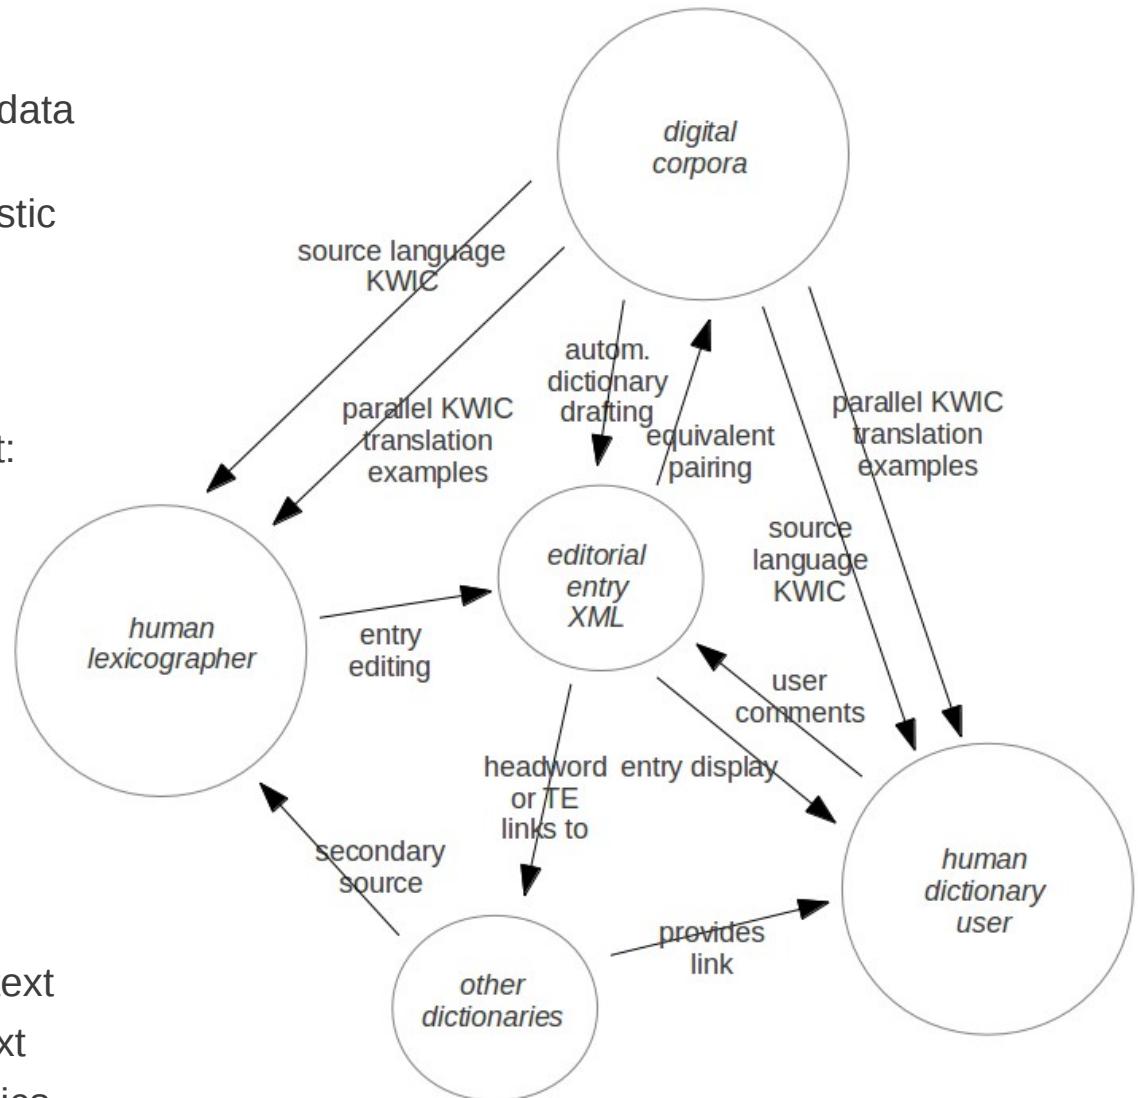
- Corpus-based lemma-list retrieval (frequency lists)
  - Frequency list becomes lemma list combining automated and hand-craft methods (IDS 2009)
  - Corpus frequency = look-up frequency (in the top few thousand) (De Schryver 2010)
- Usage examples from monolingual corpora
  - Commonplace in Lexicography: Useful for dictionary entry editing
  - Corpus Concordances shown on monolingual dictionary websites (e.g. <http://www.dwds.de>)

### ► Bilingual Lexicography:

- Automatic pairing of Translation Equivalents
  - Different strategies and software tools (examples Héja 2010, Nazar 2012)
- Translation examples from parallel corpora
  - Useful for bilingual entry editing
- Parallel KWIC as part of the dictionary search-result page
  - Teubert, *op. cit.*; first mention in: Atkins 1996, Dickens & Salkie 1996.
  - Recent, maybe leading example: <http://www.linguee.com/> (no German-Basque)
  - Mainly based on software localization files: <http://en.glosbe.com/de/eu> (also German-Basque)

# Corpora in bilingual Lexicography

- ▶ Lexicographer or Dictionary editor
  - ▶ “reasoned condensation” of linguistic data provided by computers
  - ▶ “introspection”, use of their own linguistic competence
- ▶ Digital Corpora
  - ▶ monolingual: automatically built
  - ▶ parallel corpus building and alignment:
    - ▶ automatically
      - ▶ statistical methods
      - ▶ starting from (reliable) bilingual lexicon
    - ▶ semi-automatic or by hand
- ▶ Dictionary user
  - ▶ condensed in one search result:
    - ▶ editorial entry
    - ▶ headword in source language context
    - ▶ headword and TE in parallel context
    - ▶ headword or sense links to other dics



# Density: Availability of digitally stored material (Varga et al. 2005)

## ► Approximation indicators

- Number of speakers of a language
- Web size of a language

## ► Parallel Corpus Building methods

### ► Web mining

- Fine for monolingual corpora even for low density languages

- For parallel corpora more difficult:

“When the other language is much lower density, the actual number of automatically detectable parallel pages is considerably smaller”

### ► Other sources

- Literary text, religious text, international law, movie dubs/subtitles, software internationalization, bilingual magazines, annual reports, corporate home pages

- Apply to German-Basque / Don't apply

- UPV-EHU: German-Basque literature corpus (81 books, 2 million tokens)

	German	Basque
Speakers	98 million	0,8 million
Biggest Corpus	5,4 billion	0,12 billion
Wikipedia Articles	1,6 million	0,15 million
ELRA Products	444	6

## 2.1 Corpus based lemma list retrieval (DE)

- German: DeReWo (IDS 2009)
  - Based on DeReKo (5,4 bill. words)
  - DeReWo 40.000: Lemmatized
  - Comp. w. DUDEN (2011 [240.000])

First sample: abc-first 2000

61 sorted out

23 not found in DUDEN

(29 found in another form)

20 female human gender

15 proper names (orgs, geogr.)

4 other cases

35 added

Homonyms: 8

Infinitives (corr. Part. or -ung): 27

**2000 - 61 + 35 = 1974 (98,7%)**

**76 added** acc. to lexicographer's subjective relevance criteria

**2000 - 61 + 35 + 76 = 2050 (102,5%)**

Most freq.	Least freq.	abc-first	abc-last
<u>der/die/das</u>	Kindheitstraum	á	<u>Zwischenspiel</u>
<u>und</u>	<u>Gulaschsuppe</u>	à	<u>Zwischenspurt</u>
<u>sein</u>	<u>verschreibungs pflichtig</u>	<u>Aal</u>	<u>zwischenstaatlich</u>
<u>in</u>	Superminister	<u>Aar</u>	Zwischenstand
<u>ein</u>	Seniorentreffen	<u>ab</u>	<u>Zwischenstopp</u>
<u>werden</u>	<u>Schlampe</u>	<u>abändern</u>	<u>Zwischenzeit</u>
<u>von</u>	<u>Rinnsal</u>	<u>arbeiten</u>	<u>zwischenzeitlich</u>
<u>mit</u>	<u>Kronprinzessin</u>	<u>Abbau</u>	<u>Zwist</u>
<u>haben</u>	<u>Hockeyspieler</u>	<u>abbauen</u>	<u>zwitschern</u>
<u>zu</u>	Heimaufsicht	<u>abbekommen</u>	<u>zwölf</u>
<u>für</u>	Führungsmitgli ed	<u>Abberufung</u>	<u>Zwölfe</u>
<u>er/sie/es/sie</u>	<u>Wegweisung</u>	<u>Abbestellung</u>	<u>Zwölfer</u>
<u>auf</u>	Umbaukosten	<u>abbezahlen</u>	<u>zwöljfährig</u>
<u>nicht</u>	<u>Straßenbahnhaf testelle</u>	<u>abbiegen</u>	<u>zwölfköpfig</u>
<u>eine</u>	<u>Stahlrohr</u>	<u>Abbild</u>	<u>zwölfmal</u>

DeReWo-40.000	EAH-2007	LDS	DeReWo Pos.	DeReWo-Freq	Leipzig Freq.
Befehl befehlen	Befehl befehlen	Befehl befehlen	5926	13	12
		<b>Befehlsform</b>	10262	14	16
		<b>Befehlsgewalt</b>			21
Befehlshaber	Befehlshaber	Befehlshaber	18747	16	14
		Befehlsverweigerung			16
befestigen befestigt	befestigen	befestigen	8204	14	15
Befestigung	Befestigung	Befestigung	21221	16	15
befeuchten	befeuchten	befeuchten			18
befeuern			33303	17	16
befinden	befinden	befinden	569	9	10
Befinden	Befinden	Befinden	24672	16	15
befindlich		befindlich	5499	13	19
Befindlichkeit		Befindlichkeit	13423	15	15
		befingern			21
		beflaggen			18
	beflecken	beflecken			18
beflissen			39294	17	17
beflügeln		beflügeln	8895	14	13
beflügelt			25788	16	13
		befohlen			14
befolgen	befolgen	befolgen	12262	15	14
		<b>Befolgung</b>			17
		<b>Beförderer</b>			20
befördern	befördern	befördern	4647	13	12
befördert			12377	15	12
Beförderung	Beförderung	Beförderung	9731	14	13
		<b>Beförderungsmittel</b>			19
		<b>Beförderungsmittel</b>			20
befragen	befragen	befragen	2829	12	12
befragt			14584	15	11
Befragte			4367	13	14
Befragung	Befragung	Befragung	5226	13	11
befreien	befreien	befreien	2234	11	11
Befreier	Befreier	Befreier	30667	17	15
befreit			8821	14	11
Befreiung	Befreiung	Befreiung	4917	13	11
<b>Befreiungsarmee</b>			23679	16	16
Befreiungsbewegung		<b>Befreiungsbewegun</b>	30167	17	16
		<b>Befreiungskampf</b>			17
Befreiungsschlag			14791	15	13
<b>Befreiungstiger</b>			33275	17	14
		<b>Befreiungsweg</b>			21
befremden		befremden	15373	15	15
		<b>Befremden</b>			15
befremdlich		befremdlich	19219	16	14
		befreunden			19
befreundet		befreundet	5158	13	13

## 2.1.1 Comparing corpus-based list with dictionary lemmatists

- ◀ Not on freq.list but freq. (according to other sources)
  - ◀ Not on freq.list, less freq.
  - ◀ Not on freq.list, not freq.
  - ◀ On freq.list, not on DUDEN lemmatist, to be erased (proper names)
  - ◀ Gaps from a human lexicographer's point of view
- ...on a freq.list sample of 33:
- 2 to be erased
  - 3 frequent to be included
  - 4 less freq. to be included

# German Lemma List: Problems (1)

- Schnorr 1991
- Lötzsch 1991

## ▼ Partizipien

### ▼ Partizip I mit und ohne adjektivischer Bedeutung

- ▼ Eigenes Lemma, wenn im Duden als "Adjektiv": *alleinerziehend*
- ▼ Infinitiv auf Derewo, Part I. nicht, aber Part. I im Duden, Verbinfinitiv nicht:  
Geänderte Aufnahme (*andersdenken>andersdenkend*)

### ▼ Partizip II mit und ohne adjektivischer Bedeutung

- ▼ Wie im Duden als "Adjektiv" und/oder "Partizip"
- ▼ Link vom Partizip zum Verbinfinitiv (der bei Fehlen aufgenommen wird)

## ▼ Weibliches Human Gender

### ▼ Zusammen mit der männlichen Form als Lemma-Nebenform

## ▼ "Transparente Komposita" (Mehrwortsyntagmen)

### ▼ *Abschlusstabelle, Abschleppwagen, Holzhaus, Küchentisch*

- ▼ Wenn auf DEREWO und im Duden-230.000, dann als Lemma aufnehmen (auch hier: Frequenz als Kriterium)
- ▼ "Postulat der optimalen Platzverwendung" gilt nicht
- ▼ Erscheinen im WB für DE L2 Produktion sinnvoll, über EU-Register suchbar.

# German Lemma List: Problems (2)

- ▼ Substantiv-Nennform immer Singular?
  - ▼ (Quasi-)Plurale Tantum
    - ▼ Aufgenommen wie im Duden, DEREWO-Form bei Bedarf geändert
      - ▼ *Abbrucharbeiten, Achtzigerjahre, Arbeitsbedingungen*
- ▼ Nicht auf DEREWO enthaltene Lemmata
  - ▼ Gewonnen aus Abgleich mit den Lemmastrecken der drei Sekundärquellen
    - ▼ *Aas, AASFresser, abbinden, abbüßen, Abendrot, Abendschule, abgefeimt, abgekartet, abgepackt, abgeschmackt, abgesehen, abgespannt, abgestanden, abgetakelt, abgetreten, abgewetzt, abgezehrt, abgießen, Abguss, abhärteln, abkacken, abkehren, Abklatsch, Abkömmling, abküssen, ablecken, abmessen, Abrede, abreiben, Abreibung, Abreise, Abriss, abrüsten, Abschleppwagen, Absolutismus, Absonderlichkeit, absondern, Abspann, abspülen, abstollen, abstinent, abstumpfen, abteilen, abwertend, abwracken, achtsam, Adoptivbruder, Adoptivkind, Adoptivschwester, Adoptivsohn, Adoptivtochter, Afroamerikaner, Ähre, Akkordarbeit, Aktiv, Alabaster, Albaner, Alias, allwissend, altklug, am, amen, Amphibie, Andalusier, andersartig, anfeuchten, anflehen, Angeberei, angeberisch, Angemessenheit, ankern, Anschnallgurt, anspitzen, Antiquitätenhändler*

# German Lemma List: Problems (3)

## ▼ Nicht übernommene DEREWO-Einträge:

- **Nicht im DUDEN:** á, abend, Abfahrts, abgründen, ablaufend, aborigines, Abstiegsrunde, Abstimmungskampf, abwartend, Abwässer, accessoires, achtelfinal, Achtelfinals, achtzehnt, Acrylbild, Adventkonzert, Adventsbasar, adventsingens, afro, Aktienkursus, alleinbleiben, allround, Allstar, allzuoft, allzusehr, allzuviel, Alpenliga, Alpenstraße, Alpin, Altenheimen, Alterssiedlung, altertum, Altertümer, älterwerden, Altstadtfest, Altstadtfreund, Ampelregelung, Anders, Anerkennungspreis, Angeln, anglo, Angriffsbemühung, anlaufend, Anwaltskosten, Arbeits, Arbeitsamtsbezirk, Arbeitsjahr, Arbeitsmarktdatum, Arbeitsmarktexperte, Arbeitsmarktlage, Arbeitspartei, Arbeitsschwerpunkt
- **Spez. Eigennamen:** Achensee, Ackermann, Akademietheater, Alaska, Alb, Allen, Alster, Am, Amnesty, AOK, Aphrodite, Apostelkirche, Appenzell, Appenzeller, Apulien

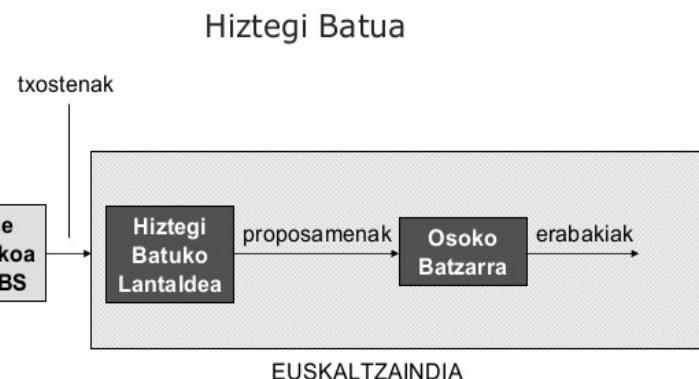
# German Lemma List: Prediction on [2000] sample

- ▼ German Lemmata:
  - ▼  $[\text{DEREWO-40.000}] \cap [\text{DUDEN-230.000}] \approx 38.700$
  - ▼ + 5-6% from Secondary Sources
  - ▼ results in approx. 42.000 Lemma signs
- ▼ Basque Lemma Sources (future)
  - ▼ *Hiztegi Batua* 2011 (52.615 lemmata)
    - ▼ freely available XML (GPL)
  - ▼ *Basque WordNet* (26.727 lemmata)
    - ▼ ELRA resource (not free)
  - ▼ Elhuyar/EHU Science & Technology Corpus frequency list (78.600 lemmata)

## 2.2 Corpora and Corpus based lemma list retrieval (EU)

### Euskaltzaindia (Language Academy): Lexicography

- ▶ OEH Corpus: All (304) printed books (religious and secular literature) until 1970: 5 mill. words
- ▶ UZEI 20th century corpus: 4,6 mill. words
- ▶ Automatic filtering of lemma candidates, final decision one-by-one by editorial board
- ▶ Hiztegi Batua: 52.615 entries



### UPV-EHU/Elhuyar

- ▶ Science and Technology Corpus
  - ▶ 1990-2002 scientific pub.
  - ▶ 8,5 mill. words
    - ▶ filtered lemmalist: 78.600 words
- ▶ EPG Contemporary Prose Corpus
  - ▶ from 2000 onwards
  - ▶ 13,1 mill. words from 287 books
  - ▶ 12 mill. words from press
    - ▶ frequency lists or lemmalists?
- ▶ XUXEN spell-checker/EDBL
  - ▶ 120.000 lemmata, flexion-morphemes and irregular word forms

## 2.3 Usage examples from monolingual corpora

- German DWDS monolingual: Entries in several editorial dictionaries, wordsketch, KWIC of several corpora, hit statistics. Appearance fully customisable.
- For German, leading in dictionary publishing

**D W D S**

Ressourcen - Erschließung - Projekt - Aktuelles -

Begriff

Der Tagesspiegel

Treffer: 8981 | 1 2 3 4 >>

1 ...haften Muster, das sie mit den Begriffen "Feierabend, Kühlschrank, Wein..."  
 2 ... Stam (1899 - 1986) wiesen die Begriffe noch auf die soziale Verantwortung...  
 3 ...hr auffällt. Nehmen wir den Begriff Ein-Euro-Jobber. Er ist zwa...  
 4 ...: Sowjetunion gewählt, und die Begriffe Glasnost und Perestroika waren...  
 5 ... Er benutzt gern militärische Begriffe , äußert sich zu Verteidigungs...  
 6 ...bis 9. Juli). Und würde der Begriff Nonkonformist noch in aller an...  
 7 ...deutung dieser sehr abstrakten Begriffe zu vermitteln? Wie jedes ne...  
 8 ... Von Elke Windisch, Moskau Der Begriff "strategische Partnerschaft" ...  
 9 ...meisten jüngeren Deutschen ein Begriff , doch wie der Bundesrat funk...  
 10 ...mt das Haus der Kulturen große Begriffe in einer globalisierten Welt a...

DDC-Query | Darstellung | Suchfilter

Korpusfrequenzen

Korpus	Hits	Hits [ppm]	Korpusgröße [Mill. Token]
Berliner Tagesspiegel	8981	54.3685	165.19
Berliner Zeitung	10628	41.9471	253.37
C4-Korpus	5052	63.1500	80.00
Compact Memory Corpus	3101	118.1451	26.25
DDR-Korpus	738	85.2524	8.66
Die ZEIT & ZEIT Online	71350	155.1087	460.00
DWDS-Kernkorpus	18196	180.8730	100.60
DWDS-Korpus21	145	77.5968	1.87
Juilland-Korpus	120	240.0000	0.50

Kernkorpus 21

Treffer: 145 | 1 2 3 4 >>

1 Fa ...ges Mal wurde von Plessner der Begriff der Kulturnation im emphatisch...  
 2 Fa ...in sentimental-oppositioneller Begriff des zu Höherem bestimmten Mens...  
 3 Fa ...der DDR-Gesellschaft hatte den Begriff der Politik, so schien es, auf...  
 4 Fa ...richt lange darauf, sowohl den Begriff der » Deutschen Nation « als a...  
 5 Fa ...nd Haltungen. Amerikanische Begriffe und Haltungen sind es nicht, ...  
 6 Fa ...st eben, als könnte man diesen Begriff nicht weit genug fassen, ihn n...  
 7 Fa ...nen Debatte machte ein anderer Begriff Karriere. Wegen ihrer Weige...  
 8 Fa ...vortretend gab ihm ganz andere Begriffe , wohin die Menschheit gelange...  
 9 Fa ...und Genie= Pathologie, das den Begriff Deutschtum zusammen mit je...  
 10 Fa ...nteligenz vor den politischen Begriffen . Das Zoon politikon, diese...

DDC-Query | Darstellung | Suchfilter

DWDS-Wörterbuch

Begriff mask.; -sl.-es; -e

Aussprache: ►

Zusammensetzungen: Elementarbegriff, Gattungsbegriff, Grundbegriff, ... ▲

1. • wesentliche Merkmale einer Sache oder einer Gruppe von Erscheinungen, die zu einer gedanklichen Einheit zusammengefasst sind ▲

2. a) ♦ Vorstellung ▲  
 b) ♦ Auffassung, Meinung ▲  
 3. schwer, langsam von Begriff sein + schwer, langsam auffassen umgangssprachlich ▲  
 4. im Begriff sein, stehen ♦ etw. tun wollen, gerade anfangen, etw. zu tun ▲

dwdswb-0.3.41

Etymologisches Wörterbuch

Begriff, ferner: Begriff , begreiflich , begrifflich , begriffsstutzig

begreifen Vb. 'verstehen, geistig voll erfassen, umfassen, einschließen'. Ahd. *bigrifan* (8. Jh.), mhd. *begrifien*, mnd. *begripen*, nl. *begrijpen* bedeuten ursprünglich 'ergreifen, betasten', auch 'umfassen, enthalten' (zur Herkunft s. greifen). Schon in ahd. Zeit, wo es lat. *comprehendere* 'begreifen' übersetzt, später vor allem bei den Mystikern, erfährt das Wort eine Bedeutungsverweiterung, indem körperliches 'Greifen, Fassen' auf geistige Aneignung, 'mit dem Verstande erfassen, verstehen', ausgedehnt wird. – Begriff m., mhd. *begrif* ist zu *begreifen* im Sinne von 'umfassen, enthalten' gebildet und bedeutet 'Umfang, Bezirk, Umfang und Inhalt einer Vorstellung', ferner 'Zusammenfassung, kurzer Auszug'. Begriff kommt durch die philosophischen Aufklärer Wolff und Thomasius allgemein in Gebrauch; Begriff und Vorstellung werden in der philosophischen Terminologie bald gegeneinander abgegrenzt, so daß Begriff die heute vorherrschende Bedeutung wesentliche Merkmale einer Sache oder einer Gruppe von Erscheinungen, die zu einer gedanklichen Einheit zusammengefaßt sind' erhält.

etymwb-1.0.27

ZEIT & ZEIT online

Treffer: 71350 | 1 2 3 4 >>

1 ...tans Armee und Regierung haben begriffen , dass die Taliban zu einer er...  
 2 ... und Regierung Pakistans haben begriffen , dass die Taliban zu einer er...  
 3 ...t hörte sie zum ersten Mal den Begriff "Zwänge" und erfuhr, dass es v...  
 4 ...tritt nur Branchenkennern ein Begriff . Gekommen war der Mann mit...  
 5 ...spare mir meinen Kommentar zum Begriff "sozial schwach", denn in dies...  
 6 ...erwerk, ein ziemlich dehnbarer Begriff , anfällig für Stimmungen und ...  
 7 ...stellte, rückte er einen neuen Begriff in das Zentrum: » Afpak «, Er ...  
 8 ...Immer wieder spielt er mit dem Begriff der geordneten Insolvenz «, ...  
 9 ...aber Walther ist Demjanjuk ein Begriff . Hinter ihm verbirgt sich ...  
 10 ...ke staatstreuer Propaganda den Begriff » Spinenternet « geprägt das sol...

DDC-Query | Darstellung | Suchfilter

Wortprofil 2012 für Begriff : 5578 signifikante Verbindungen

Substantiv Dice MI Freq. Anzahl: 1

Attribut

abstrakten dehnbarer englischen gebrauchten gelaufenen geographischer geprägten gängigen philosophischen relativ schillernden schwammigen vagen verwendetem zentralen

hat Genitivattribut

ist Akkusativobjekt von

ist Aktivsubjekt von

Tabellenansicht | Darstellungsoptionen | Suchfilter

Kernkorpus 20 (eingeschränkte Version)

Im Kernkorpus wird zwischen Groß- und Kleinschreibung unterschieden.

Treffer: 831 | 1 2 3 4 >>

1 ...e Haus durchnummeriert. Der Begriff geht vielmehr auf die Bandung-...  
 2 ...assen. Die Besatzung war im Begriff , eines der zahlreichen Prohib...  
 3 ...eichen Prozess durchlaufen die Begriffe , Trends, Wörter der » Design-...  
 4 ...her nach dem anderen dieselben Begriffe vorträgt, auf die, völlig unab...  
 5 ...It gehängt. Da stehen jetzt Begriffe wie » Retro «, » Balance «, » ...  
 6 ...iskutierte zu bündeln. Alle Begriffe vorne an der Tafel werden um d...  
 7 ...Walther von Hollander noch ein Begriff . Mit 66, also schon ziemli...  
 8 ..."klassisches Erbe", und um den Begriff von der "deutschen Kulturnatio...  
 9 ... Argument, dass die Mathematik Begriffe des Unendlichen konstruiert un...  
 10 ...eist nur noch als romantischer Begriff existiert - die 'Gesamtkraft' ...

nach Anmeldung 18196 von 20794 Treffern anzeigen

DDC-Query | Darstellung | Suchfilter

## „Begriff“

kontzeptu	18
ideia	11
hitz	2
adigai	1
burutapena	1
ezagutza	1
gai	1
hitz	1
ikusmolde	1
pentsakera	1
termino	1
ulerbide	1
ulerkera	1

## „im Begriff sein“

-tzena joan	5	-tzekotan izan	1
-tzeko zorian	4	-tzera apoderatzen izan	1
-tzearegon	3	ekarri	1
-tzeko asmoa izan	3	gutxi falta + subjkt.	1
-tzeko asmotan egon	2	hasia izan	1
-tzea pentsatu	1	inf. nahi izan	1
-tzearezan	1	inf. nahian	1
-tzeko duda egin	1	egin behar izan	1

LU and TE candidates in Parallel Corpus (SkE). Example: “Begriff” (noun)

kein Begriff sein	ez ezagutu	1
kein Begriff sein	horren entzuterik ere ez izan	1
keinen andern Begriff haben als ...	... baino ez pentsatu	1
nicht allzu schnell von Begriff sein	ez oso azkarra izan	1
schwer von Begriff sein	burugogorra izan	1
sich einen stillen Begriff machen	gutxi gora behera irudika ahal izan	1
sich kaum einen Begriff machen	ozta-ozta ideia bat izan	1
sich keinen Begriff machen	ez jakin	1
sich keinen Begriff machen	ezin imajinatu ere egin	1
über alle Begriffe	ezin esan bezain	1
Der Begriff X	X	1
einen Begriff geben	aditzera eman	1

## 2.4 Translation examples from parallel corpora

Parallel KWIC from lemmatized and POS-tagged DE-EU corpus using SkE.  
Example: “Begriff” (noun)

Corpus: DE_1	Hits: 86 (37.3 per million) [EU_1] [EU_2]
Page 1 of 5   Go   Next   Last	
#95733	war frisch , davon machen Sie sich keinen <b>Begriff</b> . Denken Sie sich , ich hab meinen Überzieher
EU_2: Zoragarria zen ... Maiatzaz ... Bero egiten zuen ... Eta ni lotsagabe sentitzen nintzen , ez dakizu ondo .	
#110678	Gedächtnis , weil ich gerade zu dieser Zeit im <b>Begriffe</b> war , die Reisebeschreibung des berühmten
EU_2: Orolmenean geratu zitzaldan ; izan ere , hain zuzen garai hartan , izen bereko ibiltari ezagunaren bidaiel buruzko kontakizunak irakurtzekotan nintzen .	
#136122	sonnverbrannte Wüste geht . Und schon war Andreas im <b>Begriffe</b> , den Helden des Films sympathisch und
EU_2: Eta Andreas hasia zeanet heroikart simpatia eta atxikimendua hartzan , filmeari uste ez bezala zorion alderia makurtu , handik pasaten zen zientifiko espedizio batek deserriuan galduztako gizonia salbatu , eta Europako zibilizazioaren genizpera ekartzen zuen azera .	
#136185	den Helden des Films . Und schon war er im <b>Begriff</b> , sich zu erheben , als auf der Leinwand
EU_2: Eta jeikitzeko zorian zegoela , hara non pantxan agertu zen lehentxeago , barran zegoela , tabernariaren biskzar atzean ikusitako eskola lagunaren irudia .	
#139853	Hier stieß er auf einen Mann , der eben im <b>Begriffe</b> war , die Treppe hinaufzusteigen , und
EU_2: Han , eskaliereten gora hastear zen gizon batetkin topo egin zuen . Oso ezaguna egin zitzaln .	
#151414	aufgewachsen und hatte von dorther eine Menge von <b>Begriffen</b> und Schablonen beibehalten . Er hatte theoretisch
EU_2: Gainera hezimolde burges txikian hazi zen , eta ordudan kontzeptu eta kate andana gordetzen zituen .	
#154557	den Dichtungen des alten Indien ist dieser <b>Begriff</b> ganz unbekannt , die Helden der indischen
EU_2: India zaharreko poesietan kontzeptu hori erabat ezezaguna da , Indiako epopeietako heroek ez dira pertsonak , pertsona matakazak , enkamazio sailak baizik .	
#155264	Leben . Was die Menschen jeweils unter dem <b>Begriff</b> „Mensch“ verstehen , ist stets nur eine
EU_2: Gizonek " gizaki " kontzeptuaren bidez gehienetan ulerzen dutena , akordio burges iragankor bat besterik ez da betiere .	
#160170	und erkannte mich erst , als ich schon im <b>Begriff</b> war , an ihm vorüberzugehen . Er stützte
EU_2: Parez pare zetorkidan jakituna , zurrun eta nahiko begialuso , eta jaramonik egiteke albotik pasatzena pentsatzen nuen unean ezagutu ninduen .	
#202482	Ihre Arbeit zu Ende zu führen . Wenn der <b>Begriff</b> der Pflicht Ihnen unbekannt ist ... " Er
EU_2: Egitekoaren ideia ezezaguna bazazu ... .	
#202528	Warten Sie ! " sagte Gustav höflich . " Den <b>Begriff</b> der Pflicht allerdings kenne ich nicht
EU_2: - Egitekoaren idea egiaz ez dut ezezagutzen , ez gehiago .	
#202602	Gegenteil getan . Aber wenn ich auch den <b>Begriff</b> der Pflicht nicht mehr kenne , so kenne
EU_2: Baino eginbeharraren ideia gehiago ezezagutzen ez badut ere , ongi ezezagutzen dut ordea kulparena ; agian biak gauza bera izango dira .	
#203637	Menschen , einst ein hohes Ideal , ist im <b>Begriff</b> , zu einem Klischee zu werden . Wir Verrückten
EU_2: Gizarra , garai batean ideal alitu bat , azken batean kiltze bihurtzeko zorian dago .	
#204784	lückenhafte Seelenlehre der Wissenschaft durch den <b>Begriff</b> , den wir Aufbaukunst nennen . Wir zeigen
EU_2: Guk horregatik , akatsez beteriko jakintza horren arrimari buruzko irakaskintza osatu egiten dugu , eraikuntz deritzogu n idearen bidez .	
#392066	der Herr Vorsteher schwieg . Ich war im <b>Begriff</b> , ihm irgendwie grobe Beleidigung ins
EU_2: Irain satsuren bat aurpegira botatzear egin nintzen .	

**Begriff m. kontzeptu | adigai** ▶ ich stand im Begriff, das Haus zu verlassen: *Etxea uzteko abian nengoen*

editorial EAH 2007

14.03.13

Bilingual Lexicography DE-EU

## 2.4.1 Summary: Functions

### ► Parallel KWIC display: real translation examples

- TEs for the headword that are not listed in the editorial entry
- TEs in context
  - domain, register, regional
- TEs for MWE and collocations
  - MWE: "im Begriff sein"
  - phraseological coll.: "üblicher Begriff"
  - idiom: "schwer von Begriff"
- POS-transposition
  - in editorial entry POS is maintained even if translators don't
- other adaptations done by human translator

berücksichtigen (V)	consider (V)	aintzat hartu (PosP+V) kontuan izan (PosP+V)
Berücksichtigung (N)	consideration (N)	aintzat hartze?? (PosP+N) kontuan izate?? (PosP+N)
unter Berück-sichtigung +Gen. (Prep+N+Gen.)	considering sth.; taking sth. into account (Part. Phrases)	zbt. aintzat harturik; zbt. kontuan izanik (Part. Phrases)

Abfrageergebnis für Ihre Anfrage nach »Begriff«		
30 Treffer aus dem deutsch->englisch Lexikon:	#Belege	
Begriff	notion	6
Begriff	concept	3
Begriff	term	2
begriff	comprehended	2
Begriff	idea	2
begriff	understood	2
Begriff	sense	2
Begriff	realization	2
Begriff	acquaintance	2
Begriff	knowledge	2
Begriff	item	2
Begriff	apprehension	1
Begriff	seidea	1
Begriff	conception	1
Begriff	perception	1
im Begriff sein	to be about to	1
üblicher Begriff	commonly used term	1
aktrakter Begriff	abstract idea	1
im Begriff sein zu	be about to	2
abstrakter Begriff	abstract term	2
im Begriff sein zu	to be on the point of	2
im Begriff sein zu	to be about to	2
abstrakter Begriff	abstract concept	1
schwer von Begriff	slow on the uptake	1
im Begriff sein zu	to be going to	1
im Begriff sein zu	gonna	1
numerischer Begriff	numeric character	1
langsam von Begriff	slow-witted	1
der Begriff 'Pferd'	the concept 'horse'	1
mehrdeutiger Begriff	ambiguous concept	1

[dict.uni-leipzig.de](http://dict.uni-leipzig.de): DE-EN parallel corpus TE extraction  
and cooccurrence statistics as on-the-fly generated  
dictionary entry (under development; still noisy)

14.03.13

## Editorial Dictionary:

### **Begriff** noun, masculine

- term *n*
- concept *n*
- notion *n*
- idea *n*
- item *n*
- conception *n*
- specialist term *n*
- perception *n*

### **begriff**

- understood *v*
- saw
- recognized *v*
- comprehended *v*
- savvied

"er/sie/es begriff" could be 3rd person simple past

### **begreifen** verb

- understand *v*
- comprehend *v*
- see *v*
- grasp *v*
- realize *v*
- conceive *v*
- realise *v* [BE]
- recognize *v*
- apprehend *v*
- figure out *v*
- catch on *v*
- grok *v* [sl]
- savvy *v*

### **Begreifen** noun, neuter

- comprehension *n*
- apprehension *n*
- uptake *n*

## Examples:

### **im Begriff sein zu**

- be going to *v*
- be on the point of
- gonna [AE] [colloq.] [sl]

### **dieser Begriff bezieht sich auf**

- this term refers to

### **abstrakter Begriff** noun, masculine

- abstract term *n*

### **zu einem Begriff werden** verb

- become a household name *v*

### **schwer von Begriff**

- slow on the uptake *adj*

### **allgemeiner Begriff** noun, masculine

- general term *n*
- universal concept *n*

### **Übergeordneter Begriff** noun, masculine

- superordinate *n*
- hyponym *n*

### **üblicher Begriff** noun, masculine

- commonly used term *n*

### **ich/sie begriff**

- I/he/she understood

## Translation examples from external sources for 'Begriff':

### German

[...] Syntax der Marke sowie ihre Eignung als unmittelbar und direkt beschreibender **Begriff** für die fraglichen Waren und Dienstleistungen falsch beurteilt habe, (ii) nicht [...]

[eur-lex.europa.eu](#)

### English

[...] mark, as well as its aptness or otherwise as an immediate and direct **descriptive term** for the goods and services in question; (ii) failed to establish facts of its [...]

[eur-lex.europa.eu](#)

The first paragraph of Article 1 of the Convention of 27 September 1968 on Jurisdiction and the Enforcement of Judgments in Civil and Commercial Matters, as amended by the Convention of 9 October 1978 on the Accession of the Kingdom of Denmark, Ireland and the United Kingdom of Great Britain and Northern Ireland and by the Convention of 25 October 1982 on the Accession of the Hellenic Republic, must be interpreted as meaning that the concept of 'civil matters' encompasses an action under a right of recourse whereby a public body seeks from a person governed by private law recovery of sums paid by it by way of social assistance to the divorced spouse and the child of that person, provided that the basis and the detailed rules relating to the bringing of that action are governed by the rules of the ordinary law in regard to maintenance obligations.

[eur-lex.europa.eu](#)

Es folgten - um nur einige Werke zu nennen - das Buch "Der hörende Mensch", in dem er seine Forschungen auf die harmonikalnen Strukturen in der Chemie, der Astronomie, der organischen Natur, in Licht und Farbe und in der Architektur ausdehnt; die "Harmonia Plantarum", eine Entwicklung der Morphologie der Pflanzen aus harmonikalnen Grundelementen; das Büchlein "Akroasis", das eine allgemeinverständliche Einführung in die Gedankenwelt der Harmonik geben will, und das auch heute noch erheblich ist (der Begriff "Akroasis" = Anhörung wurde von Kayser als anderer Name für die Harmonik geprägt, da der Begriff "Harmonik" oft falsch verstanden wurde) und als umfassendstes Werk das "Lehrbuch der Harmonik", in dem er die Ergebnisse seiner Forschungen zusammenfaßt und sie in Form eines Lehrbuches präsentiert.

[harmonik.de](#)

Der Begriff "persönliches Interesse", wie er im vorstehenden Absatz verwendet wird, findet keine Anwendung auf jedweide Beziehung und jedwedem Interesse, die nur [...]

[iacuna-fonds.net](#)

The term "personal interest" as used in the above section shall not apply to any relationship and any interest which arise only due to the fact that the legal transaction [...]

[iacuna-fonds.net](#)

[...] unterschied zu den üblichen dokumentationen, bei denen wert auf gewicht und beständigkeit gelegt wird, zeigt sich dieses druckwerk besonders fragil und vergänglich: auf über 600 seiten sind nur die namen der künstler zu lesen. sie sind auf extrem dünnes papier gedruckt. es ist durchscheinend, wie die geräusche, die in der ausstellung zu hören sind. der charakter des tons schlägt sich nieder in der verliezlichen gestalt. der buchblock hat keinen schützenden einband, so dass bereits das erste durchblättern spuren hinterlässt. das

**Editorial dictionary entry and parallel KWIC combination as e-dictionary search result ([linguee.com](#))**

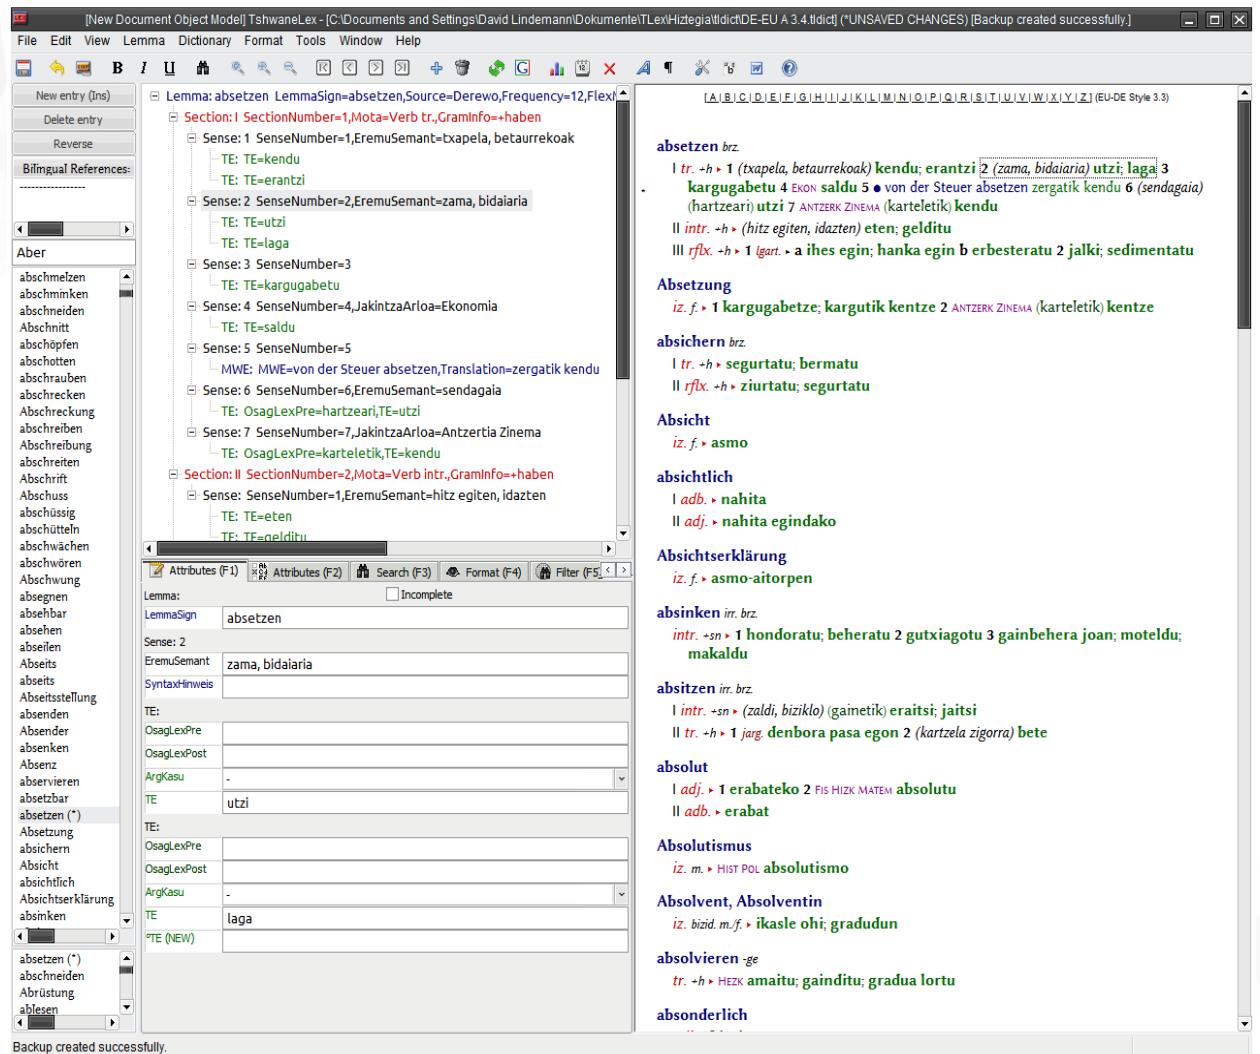
**Noise: word highlighted without clear reason**

**"vote up" / "vote down" buttons:  
crowd votes for good examples  
(affects display order)**

**Noise: 3 TEs for 2 appearances of the HW: "word", "term" plus  
"intellectual world" (TE for  
"Gedankenwelt"="Begriffswelt")**

# 3.0 New DE-EU dictionary: Editing, Corpora, Tools

- ▶ **Editing Software:**  
**TshwaneLex (TLex)**  
(de Schryver & Joffe 2005, 2010)
  - ▶ Freely designable DTD, Styles
  - ▶ Output as XML, html, rtf, tsldict
  - ▶ Attribute Lists, Label Sets
  - ▶ Import, Reverse, Compare, Merge
  - ▶ CrossRefs, Hyperlinks
- ▶ **Software for Corpus Tagging and KWIC:**  
**SketchEngine (SkE)**  
(Kilgarriff et al. 2004)
  - ▶ Queries in large annotated corpora for DE and EU
  - ▶ Wordsketch, GDEX
  - ▶ Parallel Concordances



## 3.1 New DE-EU Literary Corpus

- ▶ Created at UPV-EHU  
(Sanz Villar 2011, Zubillaga 2012)
- ▶ 81 Digital and OCR-ed literary DE originals and official EU versions
- ▶ about 2 million tokens per language
- ▶ 146.457 sentence pairs
- ▶ Sentence alignment  
one-to-many alignment revision by hand
  - ▶ Improved sentence alignment tools like *hunalign* (Varga et al. 2005) require seed lexicons (DE-EU still not available)
- ▶ Exported to TMX format, imported in the SketchEngine
- ▶ DE: Lemmatized with TreeTagger
- ▶ EU: Tokenized, not lemmatized (at the moment)

lemma	Freq
d	<a href="#">145113</a>
und	<a href="#">57846</a>
sein	<a href="#">54259</a>
ich	<a href="#">46686</a>
er	<a href="#">43723</a>
ein	<a href="#">39059</a>
haben	<a href="#">25846</a>
sie	<a href="#">25470</a>
in	<a href="#">22647</a>
zu	<a href="#">22589</a>
nicht	<a href="#">22374</a>
es	<a href="#">19506</a>
er es sie	<a href="#">18760</a>
mit	<a href="#">15777</a>
auf	<a href="#">15423</a>
du	<a href="#">14433</a>
ihr	<a href="#">13580</a>
wie	<a href="#">11903</a>
von	<a href="#">11372</a>
an	<a href="#">10944</a>
so	<a href="#">10854</a>
als	<a href="#">10526</a>
aber	<a href="#">10518</a>
sagen	<a href="#">10474</a>
wir	<a href="#">10217</a>
werden	<a href="#">9393</a>
Sie sie sie	<a href="#">9335</a>
noch	<a href="#">8271</a>
was	<a href="#">7530</a>

word	Freq
eta	<a href="#">58220</a>
zuen	<a href="#">29551</a>
ez	<a href="#">28415</a>
zen	<a href="#">21353</a>
bat	<a href="#">16811</a>
ere	<a href="#">16025</a>
egin	<a href="#">14295</a>
da	<a href="#">10926</a>
bere	<a href="#">9961</a>
zion	<a href="#">9338</a>
izan	<a href="#">8328</a>
du	<a href="#">6907</a>
baina	<a href="#">6592</a>
behar	<a href="#">6149</a>
egiten	<a href="#">6032</a>
nahi	<a href="#">5746</a>
Eta	<a href="#">5647</a>
esan	<a href="#">5407</a>
Ez	<a href="#">5143</a>
bezala	<a href="#">5089</a>
ziren	<a href="#">4948</a>
zegoen	<a href="#">4688</a>
Baina	<a href="#">4664</a>
nuen	<a href="#">4493</a>
hori	<a href="#">4374</a>
dut	<a href="#">4182</a>
zituen	<a href="#">4134</a>
nire	<a href="#">4130</a>
zuten	<a href="#">3887</a>

# 3.2 New DE-EU dictionary: frontend design

## Begriff ~s, ~e

*Substantiv m. s. Verbinf. begreifen* ▶ 1 kontzeptu; ideia; hitz; ezagutza 2 • im Begriff sein -tzena joan; -tzenko zorian egon; -tzenko asmoa izan 3 • sich (k)einen Begriff (von etw.) machen (ez) jakin

Article has cross-references to >>

**begreifen** unregelmäßig begreift, begriff, begriffen

*Verb Transitiv* +haben ▶ 1 = verstehen ulertu; aditu; barrendu 2 [als etw.] -tzat hartu

Corpus: deTenTen  
Hits: 280464 (98.6 per million)

Page 1 of 7012 Go Next | Last

#2706173999 denjenigen vernünftig reden, die unseren **Begriff** von Öffentlichkeit nicht teilen? Nachvollziehen Leistungen sind aber nur durchschnittlich. Der **Begriff** Zeitgeschichte ist aus dem Informationsinteresse wiederum hinterließ dem 18. Jahrhundert den **Begriff** einer dynamischen, offenen Geschichte.  
#2271543246 ausgewähltes Forum wird dann nach den eingegebenen **Begriffen** durchsucht. Gib einfach den Benutzernamen . Zumindest gegen Ihr Verständnis dieses **Begriffs**. Ein sportlich gehaltener Kinderodel in Projektbeschreibung taucht immer wieder der **Begriff** Modul auf. Ein Modul ist letztlich ein Beipackzettel finden Sie dies unter dem **Begriff** Gegenanzeigen. Auch weitere Hinweise zu nicht zusammenpassen. Und entfernte den **Begriff**? gesund? von der Verpackung. Im Internet Kommunikationspartner einander sind, desto mehr werden auch **Begriffe** aus dem umgangssprachlichen Bereich verwendet .  
#210412987 Expedition@bo.drs.de bestellt werden. Der **Begriff** Narzissmus ist so vieldeutig, dass ihm Text: Abbrev Erzeugt aus einer Liste von **Begriffen** eine Abkürzungstabelle. Text: Balanced Friedrichstraße liefern. Präsenzpflicht Der **Begriff** "City-Filiale" bürgerte sich ein. Hier programmatische Vorgabe für die nächsten Jahre. Der **Begriff** ist ehrlich. Denn Talent bedeutet nicht eines tragenden Bauteils nach § 24 . Der **Begriff** "raumbeschließend" ist somit nicht im landläufigen Tschemobyl hat die tödliche Dimension des **Begriffs** Risiko spüren lassen. Nicht Überheblichkeit spirits" nur am Rande auftaucht und der **Begriff** behavioral finance" nicht einmal Erwähnung Kulturforum: der Melancholie. Obwohl als **Begriff** durchaus gebräuchlich, dürften die meisten Eine Firmware? Ein ROM? Ich höre immer die **Begriffe** Firmware und ROM, wie soll man sich das nichts Ernstes. Nie, sagt sie, würde ihr der **Begriff** "Provinz" über die Lippen kommen. Nicht einer einfachen Suche. Dokumente, welche den **Begriff** "keine" enthalten, werden unverändert gewichtet meint: (17.2.2008 um 23:29) Antworten Der " **Begriff** WLAN-Kabel" ist ein Oxymoron, wie ich neulich Weder trifft es bei mir zu noch ist der **Begriff** "Bumsel" in meinen Augen sozialadäquat. Vollends absurd wird eine Orientierung an **Begriffen**, wenn die benutzten Begriffe mit den abgebildeten Erkrankung ist der medizinisch korrekte **Begriff**, unter dem über 800 derzeit bekannte Krankheitsformen von Absatz 1 dient der Legaldefinition des **Begriffs** " internationale Koproduktionen ". Zu § Zugangsdaten und Standortdaten. Bezüglich des **Begriffes** "Zugangsdaten" wird auf § 92 Abs. 3 Z 4 geförderten, betrieblichen Altersversorgung. Der **Begriff** stellt für eine Lebensversicherung, die Entwicklungsumgebungen und Werkzeuge nimmt der **Begriff** der Produktivitätssteigerung eine zentrale eine Krümmung dieser Raumzeit zurück. Der **Begriff** der Gravitationskraft wird dabei ersetzt allerdings nur, wenn man einen sehr weiten **Begriff** von Techno heranzieht. Noch stärker als neue Bedeutung der Biologie z.B. durch den **Begriff** der Bionik einer größeren Öffentlichkeit diese Weise sollte es möglich sein, den **Begriff** der Regelsstudienzeit ab absurdum zu führen natürliche oder künstliche Allergene aus der Der **Begriff** der Umwelt ist geprägt durch die anthropogene Leben der Menschen und die Welt durch den **Begriff** der Gerechtigkeit zurückge gebunden an Gott ich die Politik. Nehmen wir den Marxschen **Begriff**: hier ist Politik die Herrschaft des Menschen zwischenmenschliche Kommunikation mit den **Begriffen** aus der Signalübertragung beschrieben wird Diskussion so bedeutsamen aber auch schwierigen **Begriff** des Habitus zu erläutern und in seinen

## Hyperlinks Block:

- German monolingual dicts  
DWDS, Leipzig, Openthesaurus...
- Wiktionary & Wikipedia
- Comment form (user comments)

Corpus: DE\_1  
Hits: 86 (37.3 per million) [EU\_1] [EU\_2]

Page 1 of 5 Go Next | Last

#95733 war frech , davon machen Sie sich keinen **Begriff** . Denken Sie sich , ich hab meinen Überzieher EU\_2: Zoragarria zen ... Malata ... Bero egiten zuen ... Eta ni lotsagabe sentitzen nintzen , ez dakizu ondo . #110678 Gedächtnis , weil ich gerade zu dieser Zeit im **Begriffe** war , die Reisebeschreibung des berühmten EU\_2: Orolmenean geratu zitzaidan ; izan ere , hain zuzen garai harten , izen bereko ibiltari ezagunaren bidaiet buruzko kontakizunak irakurtekoen nintzen . #136122 sonnverbrante Wüste geht . Und schon war Andreas im **Begriffe** , den Helden des Films sympathisch und EU\_2: Eta Andreas hasia zeanean heroiai sinpatia eta atxikimendua hartzten , filmeara uste ez bezala zorian aldera makurtu , handik pasaten zen zientifiko espedizio batek desertuan galduko gizuna salatu , eta Europa biziolaizazioen gerizperra ekartzen zuten atzera . #136185 den Helden des Films . Und schon war er im **Begriff** , sich zu erheben , als auf der Leinwand EU\_2: Eta jeikitzeko zorian zegoela , hara non panta-Han agertu zen lehentxeago , barran zegoela , tabemariaren bizkar atzean ikusitako eskola lagunaren irudia . #139853 Hier stieß er auf einen Mann , der eben im **Begriffe** war , die Treppe hinaufzusteigen , und EU\_2: Han , eskaileraten gora hastear zen gizon batekin topo egin zuen . Oso ezaguna egin zitzaina . #151414 aufgewachsen und hatte von dorther eine Menge von **Begriffen** und Schablonen beibehalten . Er hatte theoretisch EU\_2: Gainera hezimolda burges txikian hazia zen , eta ordudan kontzeptu eta kate andana gordetzen zitzen . #154557 den Dichtungen des alten Indien ist dieser **Begriff** ganz unbekannt , die Helden der indischen EU\_2: India zaharreko poesietan kontzeptu hori erabat ezaguna da , Indako epopeyakto heroiekaz e dira pertsonak , pertsona matalazak , enkarmazio sailak baizik . #155264 Leben . Was die Menschen jeweils unter dem **Begriff** " Mensch " verstehen , ist stets nur eine EU\_2: Gizeonek " gizaki " kontzeptuetan bidez gehienetan ulerten dutena , akordio burges iragankor bat besterik ez da betiere . #160170 und erkannte mich erst , als ich schon im **Begriff** war , an ihm vorüberzugehen . Er stürzte EU\_2: Parez pare zetorkidan jakituna , zurrun eta nahiko begialuso , eta jaramon egiteke albotik pasatzena pentsatzen nuen unean ezagutu ninduen . #202482 Ihre Arbeit zu Ende zu führen . Wenn der **Begriff** der Pflicht Ihnen unbekannt ist ... " Er EU\_2: Egitekoaren ideia ezaguna bazaizu ... #202528 Warten Sie ! " sagte Gustav höflich . " Den **Begriff** der Pflicht allerdings kenne ich nicht EU\_2: - Egitekoaren ideia egiaz ez dut ezagutzen , ez gehiago . #202602 Gegentlich getan . Aber wenn ich auch den **Begriff** der Pflicht nicht mehr kenne , so könne EU\_2: Baino eginbeharren ideia gehiago ezagutzen ez badut ere , ongi ezagutzen dut ordea kulparena ; agian biak gauza bera izango dira . #203637 Menschen , einst ein hohes Ideal , ist im **Begriff** , zu einem Klischee zu werden . Wir Verrückten EU\_2: Gizarrudia , garai batean ideal altu bat , azken batean kiltze bihurtzeko zorian dago . #204784 lückenhafte Seelenlehre der Wissenschaft durch den **Begriff** , den wir Aufbaukunst nennen . Wir zeigen EU\_2: Guk horregatik , akatsez beteherik jakinzia horren arimari buruzko irakaskintza osatu egiten dugu , eraikuntz deritzogu n idelaren bidez . #392066 der Herr Vorsteher schwieg . Ich war im **Begriff** , ihm irgendeine grobe Beleidigung ins EU\_2: Irain satzuren bat aurpegira botatzear egin nintzen .

### 3.3 XML element hierarchy

```
<entry>
  <sense>
    <gramGrp>
      </gramGrp>
    </sense>
  </entry>
```

- Bilingual entry (TEI)
  - syntactical information below WSD
  - TEI Standard
  - most common
  - redundancies kept on the syntax level

```
<entry>
  <synt>
    <sense>
      </sense>
    </synt>
  </entry>
```

- Bilingual entry (2)
  - WSD below syntactical disambiguation
  - Redundancies
  - Common in German
    - monolingual for learners (PONS GW DaF)
    - bilingual (Langenscheidt)
    - never different POS
  - Useful for Basque(?)
    - possible to group different POS below the same headword

```
<synset>
  <LexUnit>
  </LexUnit>
</synset>
```

- WordNet
  - Lexical Headword below WSD

abkühlen sep.  
I tr./h ▷ hoztu <sup>+du</sup>  
II intr./sn ▷ hoztu <sup>+da</sup>  
III rflx./h ▷ hoztu <sup>+da</sup>

bake

verb UK US /berk/

**Definition**

- [I or T] to cook inside a cooker, without using added liquid or fat  
*I made the icing while the cake was baking.*  
a baked potato  
freshly baked bread  
Bake at 180°C for about 20 minutes.  
Bake for 5-7 minutes in a preheated oven.  
a baking dish/tin/tray
- [I or T] to make something such as earth or clay hard by heating it, usually in order to make bricks
- [I] INFORMAL to be or become very hot  
*It's baking outside.*  
*You'll bake in that fleece jacket!*

(Definition of **bake** verb from the Cambridge Advanced Learner's Dictionary & Thesaurus © Cambridge University Press)

heldu

I Verb Transitiv -dio ▷ 1 fassen; greifen; halten; festhalten 2 ergreifen; anfangen 3 (Tier) beißen; stechen  
II Verb Transitiv -du = bidali ▷ 1 schicken 2 nbi. hilarazi jdm. zukommen lassen  
III Verb Intransitiv -da ▷ 1 ankommen; kommen; herkommen 2 kommen; geschehen 3 reifen  
IV Adjektiv ▷ 1 reif 2 erwachsen 3 vernünftig  
V Substantiv ▷ 1 (eines Tiers) Biss; Stich

## 3.4 Verb entry

```
<Lemma id="19375" LemmaSign="befinden" Source="Derewo" DerewoRang="569" Frequency="9"
FlexMorfTag="unregelmäßig, ohne ge">
<Section id="211053" SectionNumber="1" POS="Verb Transitiv" GramInfo="+haben">
<Sense id="211054" SenseNumber="1" SyntaxHinweis="jdn./etw. für +adj.">
<TE id="211055" TE="-tzat eman"/>
<TE id="289097" TE="iritzi"/>
<MWE id="289101" MWE="etw. für gut ~" Translation="ontzat eman; -i oniritzi"/>
</Sense>
</Section>
<Section id="289102" SectionNumber="2" POS="Verb Intransitiv" GramInfo="+haben">
<Sense id="289103" SenseNumber="1">
<TE id="289104" TE="erabaki"/>
<TE id="289105" TE="erabakia hartu"/>
</Sense>
</Section>
<Section id="289098" SectionNumber="3" POS="Verb +'sich'" GramInfo="+haben">
<Sense id="289099" SenseNumber="1">
<TE id="289106" TE="izan"/>
<TE id="289100" TE="egon"/>
<TE id="289107" TE="aurkitu"/>
</Sense>
</Section>
</Lemma>
```

**befinden** Derewo 569 - unregelmäßig, ohne ge.

- I *Verb Transitiv +haben* ▶ 1 [jdn./etw. für +adj.] **-tzat eman; iritzi**
  - etw. für gut befinden ontzat eman; -i oniritzi
- II *Verb Intransitiv +haben* ▶ 1 **erabaki; erabakia hartu**
- III *Verb +'sich' +haben* ▶ 1 **izan; egon; aurkitu**

## 3.5 Noun entry

**Ausdruck<sup>1</sup>** Derewo 1918 ~s, Ausdrücke

*Substantiv m. s. Verbinf. ausdrücken* ▶ 1 adierazpen 2 termino; esamolde; esapide  
3 ezaugarri; adierazgarri 4 adierazkortasun; adierazgarritasun

**Ausdruck<sup>2</sup>** Derewo 1918 ~s, Ausdrücke

*Substantiv m. s. Verbinf. ausdrucken* ▶ 1 inprimatze; inprimaketa

## 3.6 Adjective and Adverb

**anständig** Derewo 8054

I *Adjektiv* ▶ 1 zintzo  
II *Adjektiv adverbial* ▶ 1 zintzo; zintzoki; jendetasunez

**anteilig** Derewo 20466

I *Adjektiv* ▶ 1 zatikako; proportzional  
II *Adjektiv adverbial* ▶ 1 zatika; proportzionalki

**arg** Derewo 3262

I *Adjektiv* ▶ 1 latz; gaitz 2 veraltend gaizto; maltzur  
II *Adjektiv adverbial* ▶ 1 ugs. südd. oso

**anders** Derewo 596

I *Adverb* ▶ 1 ezberdin; bestela; beste era batean  
II *Adverb präd./att.* ▶ 1 ezberdin; bestelako; beste era bateko

## 4.0 Automatic TE pairing for Bilingual Dictionary Drafting

- ▶ Corpus based
  - ▶ 1. GIZA++
  - ▶ 2. Bifid
  - ▶ 3. Elhuyar Pivot Dictionaries
- ▶ Others
  - ▶ 4. Wikimedia
  - ▶ 5. WordNet

# 4.1 Corpus-based strategies: GIZA++

## ► Bilingual Parallel Corpus, GIZA++

- English-Swedish 700.000 sentence pairs, 82,3% precision, 73,3% recall (Holmqvist 2010)
- Lithuanian 1.765.000 tokens, Hungarian 2.121.000 tokens, 4026 TE-candidates (Héja 2010)
- DE-EU:
  - DE: 2.303.307 tokens,
  - EU: 1.948.504 tokens,
  - Extremely low recall:
    - 573 TE-candidates,
    - 153 after revision
  - Low precision
  - First attempt, Gorka Labaka, UPV-EHU
  - Second attempt: After lemmatizing EU corpus

abend	<i>gauean</i>	aber	<i>ordea</i>
abend	<i>gau</i>	aber	<i>-baina</i>
abend	<i>arrats</i>	abgesehen	<i>utzita</i>
abend	<i>arratsean</i>	abgesehen	<i>aparte</i>
abend	<i>iluntzean</i>	abgrund	<i>amildegira</i>
abend	<i>arratsaldean</i>	abgrund	<i>amildegiaren</i>
abend	<i>gauerako</i>	abgrund	<i>amildegia</i>
abend	<i>arratsalde</i>	abgrund	<i>amildegi</i>
abend	<i>gauez</i>	abholen	<i>bila</i>
abendessen	<i>afaria</i>	abrupt	<i>-batean</i>
abendessen	<i>afaltzeko</i>	abschied	<i>agur</i>
abends	<i>gauean</i>	abschied	<i>adio</i>
abends	<i>iluntzean</i>	absicht	<i>asmoa</i>
abends	<i>gauez</i>	absicht	<i>nahita</i>
abends	<i>arratsean</i>	absicht	<i>asmo</i>
abends	<i>gauetan</i>	absicht	<i>asmorik</i>
abends	<i>arratsalde</i>	absichten	<i>asmo</i>
abenteuer	<i>abentura</i>	absichtlich	<i>nahita</i>
abenteuer	<i>abenturak</i>	absichtlich	<i>propio</i>
aber	<i>baina</i>	abstand	<i>tartea</i>

## 4.2 Corpus based strategies: Bifid

### ► Bilingual Corpus, **Bifid** (cf. Nazar 2012)

- First attempt done: 2089 pairings,
- Works much worse than with other language-pairs, evaluation in course
- Insufficient corpus size
- Second attempt: After lemmatizing EU corpus

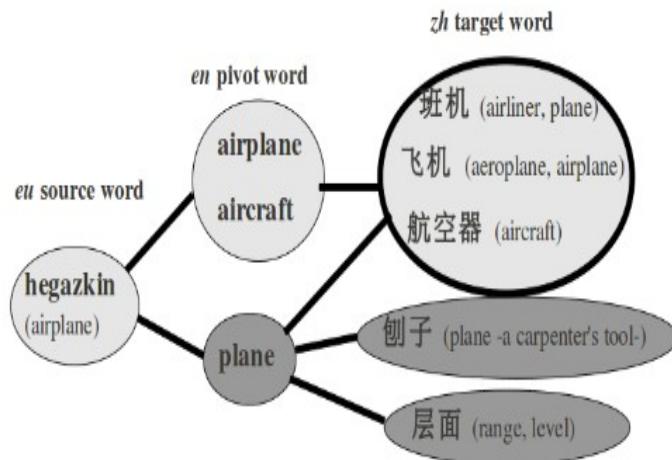
wills gesicht	<i>willen aurpegia</i>
bildhauer	<i>eskultorea</i>
einem tiefen	<i>hasperen sakon</i>
individuum	<i>gizabanako</i>
eines hundes	<i>txakur baten</i>
mensch ärgere	<i>partxisean</i>
rechts links	<i>eskuin ezker</i>
schrantür	<i>armairuko</i>
sagte irene	<i>irenek</i>
wolfgang	<i>amadeo</i>
fünfunddreißig	<i>hogeita hamabost</i>
fußgänger	<i>oinezko</i>
tante	<i>izeba</i>

# 4.3 Corpus-based strategies: Elhuyar Pivot Dictionaries

## Pairing by combining pivot and corpus based methods

### Research in course at Elhuyar (Saralegi et al., 2012): Pivot-based bilingual dictionary building

- Pairings obtained by two reference dictionaries with English as a pivot
- Inverse Consultation (IC) and Distributional Similarity (DS) in bilingual comparable corpora
- Problems resolving polysemy (words with ambiguities are skipped)
- Done for Basque and Chinese, German, Hindi, Swahili, Arabic
- German-Basque: In the actual version, 13.000 DE lemmata with 1-25 basque TE each
- Evaluation in course. Still noisy.



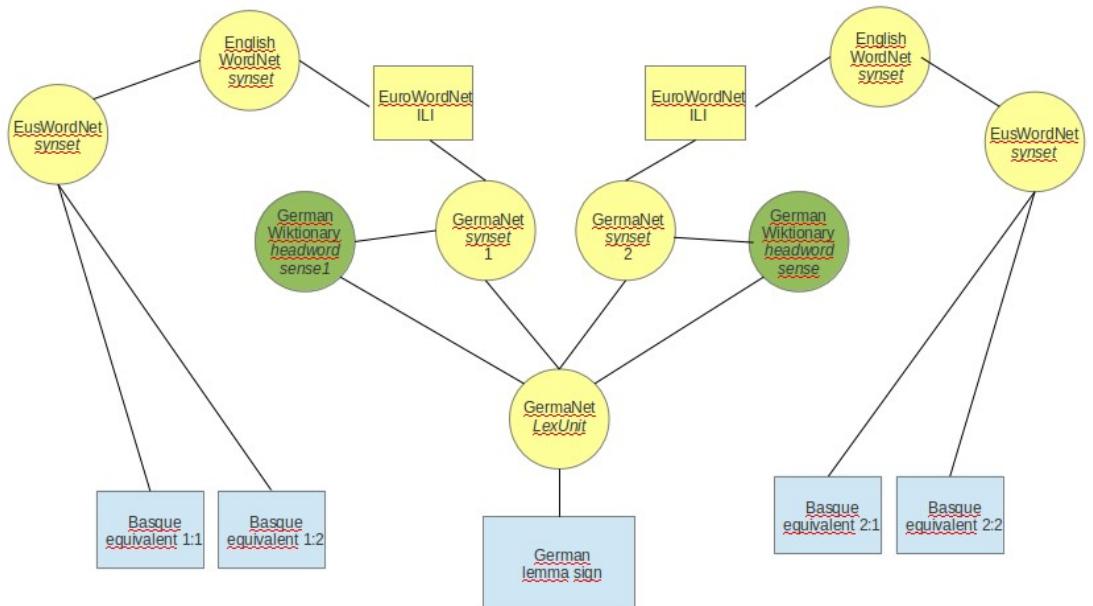
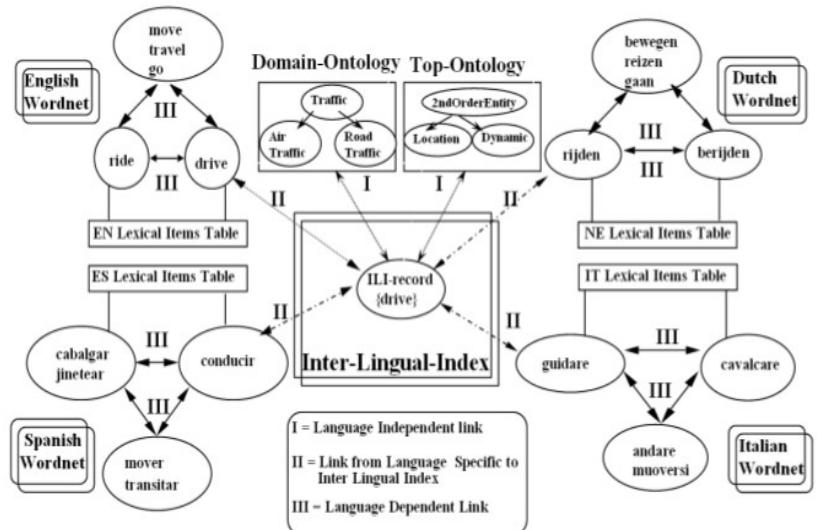
The screenshot shows the homepage of the **hiztegienataria** website. The top navigation bar includes links for eu, es, en, de, hi, sw, ar, zh, and Babeslea. The logo features a brain icon and the text 'ELHUYAR fundazioa'. The main search bar has 'Alemana – Euskara' selected and contains the word 'Begriff'. Below the search bar, a message says 'Emaitza: 1 sarrera topatu dira hiztegian.' The results section is titled 'Topatutako sarrerak' and lists one result: 'Begriff'. The result details a German word entry with its definition in German and English, along with a link to 'Erakutsi adibide gehiago'. To the right, a box titled 'Ordainak' displays statistics: '1 itzulpen zituzten eta 0 zalantzako aurkitu dira' and a 'kontzeptu' section with a +1 like button and a -0 dislike button. The footer includes the date '14.03.13' and the text 'Bilingual Lexicography DE-EU'.

## 4.4 TE extraction from Wikimedia

- ▼ First attempts: TE extraction from Wikimedia database dumps (source: <http://www.dicts.info>)
  - ▼ Wiktionary (by 2012):
    - ▼ DE-EN 2161 pairings. DE 3066 LU (905 syn.), EN 2161 LU (0 syn.)
    - ▼ DE-EU 2131 pairings. DE 2316 LU (185 syn.), EU 2338 LU (207 syn.)
      - ▼ *Eval. by hand: 80%+ nouns, very freq. words and toponyms, nearly no wrong translations*
      - ▼ *after MWE filtering and synonym cut-off: 2030 pairings. 1330 yes, 700 not on our lemmalist.*
  - ▼ Omegawiki interlanguage links (by 2012):
    - ▼ DE-EN 5603 pairings. DE 6836 LU (1233 syn.) EN 6393 (790 syn.)
    - ▼ DE-EU 4603 pairings. DE 5362 LU (759 syn.), EU 6771 LU (2168 syn.)
      - ▼ *Eval. by hand: mostly rare terms, some wrong translations*
  - ▼ Wikipedia interlanguage links (wikipedia article titles) (by 2012):
    - ▼ DE-EN 7433 pairings
    - ▼ DE-EU: ?
      - ▼ *Eval. by hand: only nouns, frequent and rare terminology, no wrong translations*
      - ▼ Erdmann 2007: Much better results!
        - no significant difference between the two language pairs
        - Wiktionary & Omegawiki (still) not useful for automatic dictionary drafting
        - Wikipedia bilingual term extraction: More research for DE-EU required

# 4.5 TE pairing via EuroWordNet

- ▶ Stops on the way:
  - ▶ German lemma-sign
  - ▶ GermaNet Lexical Unit
  - ▶ GermaNet synset(s)
  - ▶ EuroWordNet ILI record(s)
  - ▶ Princeton WordNet synset(s)
  - ▶ EusWN synset(s)
  - ▶ EusWN lemma-signs
- ▶ Advantages:
  - ▶ large databases
  - ▶ link on sense level
  - ▶ human-made WSD
- ▶ Known Problems:
  - ▶ Different approaches interling. WN
  - ▶ Different versions of PWN



## 5. Conclusions

- ▶ Importance of corpus methods in Lexicography increases
  - ▶ Indispensable in dictionary editing
  - ▶ Upcoming trend in dictionary publishing
  - ▶ Automatic Dictionary Drafting
- ▶ Not without large bilingual corpora
- ▶ Human Lexicographers (still) needed...

*... The main resource remains the lexicographic knowledge of the project members in combination with large annotated text corpora which serve as a reference in all cases of doubt.*

(Introduction to German Wordnet)

Thanks for your attention  
Vielen Dank, Eskerrik asko

[david.lindemann.soraluze@gmail.com](mailto:david.lindemann.soraluze@gmail.com)