Språk-
BANKEN



GÖTEBORGS
UNIVERSITET

Towards a gold standard for Swedish CEFR-based ICALL

Lärka
LÄR språket via KorpusAnalys

Elena Volodina, Dijana Pijetlovic, Ildikó Pilán, Sofie Johansson Kokkinakis
Språkbanken (Swedish Language Bank), University of Gothenburg

Some useful terminology

- **Lärka – Lär** språket via **K**orpus**A**nalys, a platform for learning Swedish as a Second Language (L2)

- **CEFR** – Common European Framework of Reference for Languages, a document providing guidelines and standards for language learning, teaching and testing including the scale of proficiency levels


WORK IN PROGRESS

Presentation plan

- Pedagogical framework (CEFR)
- Lärka: exercise generation (sub-projects) +Demo
- Immediate research agenda
- **A Gold Standard**: *CEFR-corpus* (sub-project) + Demo
- A *"taste"* of initial sentence readability tests
- Planned uses for the corpus

Pedagogical framework 1

- **CEFR** - Common European Framework of Reference for Languages (CEFR, Council of Europe, 2001)
  - international initiative, accepted inside and outside of Europe
  - guidelines about teaching and assessing languages

The six proficiency levels are named as follows:

C2	Mastery	Proficient user
C1	Effective Operational Proficiency	
B2	Vantage	Independent user
B1	Threshold	
A2	Waystage	Basic user
A1	Breakthrough	

Pedagogical framework 2

"can-do" statements

- **CEFR** "can-do" statements for each competence or skill and each level of proficiency.

Can collate short pieces of information from several sources and summarise them for somebody else. Can paraphrase short written passages in a simple fashion, using the original text wording and ordering.

CEFR descriptor for **B1**, for **ability to process text**

Can understand familiar names, words and very simple sentences for example in notices, posters or in catalogues.

CEFR descriptor for **A1**, **overall reading skills**

Pedagogical framework 3
CEFR weaknesses

- non-specific, expressed in terms of competences rather than linguistic constituents
- given to subjective interpretations
- performance outweighs competence
- efforts to interpret CEFR guidelines:
  - **top-down** approaches: start with CEFR guidelines, e.g. Reference Level Descriptions
  - **bottom-up**: start with interpretations that have been made up-to-date (e.g. course materials and graded essays)

Introducing Lärka

- **Lärka** (Eng. Lark) – **LÄR** språket via **K**orpus**A**nalys:
  - web-service based ICALL platform
  - at the moment consisting of an exercise generator, and two supportive modules for rating corpus hits and annotating learner-oriented copora
  - eventually other learner-related activities, e.g. performing readability analysis, selecting texts for language learners from the web, etc.

http://spraakbanken.gu.se/eng/Research/icall/architecture

Zooming into the exercise generator

Target groups

- Students of Linguistics
  - ✔ Items for training parts of speech
  - ✔ Items for training syntactic relations
  - ✔ (coming) Items for training semantic roles

- Learners of Swedish
  - ✔ Multiple-choice items for vocabulary training
  - ✔ Dictation&spelling items
  - ✔ (coming) Wordbox items for training vocabulary and morphology



The user interface in Lärka

http://spraakbanken.gu.se/larka

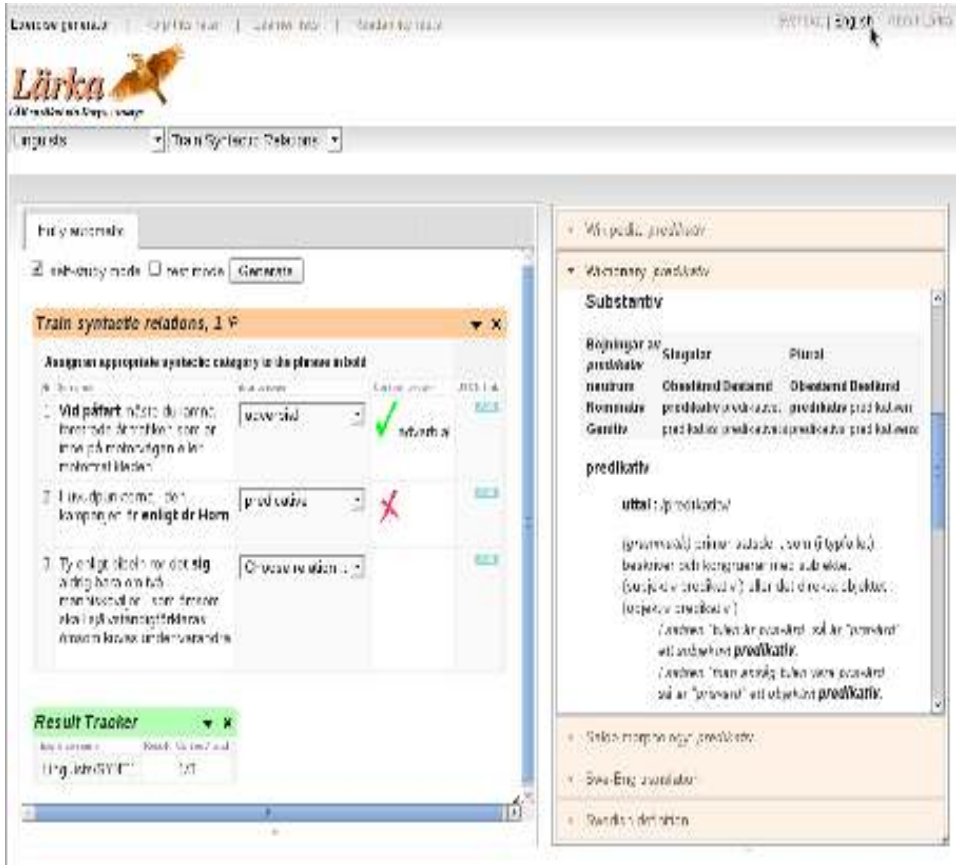

Vocabulary items for language learners

- Based on SUC3.0; eventually more corpora
- Multiple-choice principle
- Builds on vocabulary from the Kelly list
- As soon as one item is answered, a new one is generated

Vocabulary items 2

simplified present version*

1. Randomly select an item for training from the Kelly list

2. Randomly select a sentence from SUC containing the target item

3. Select distractors



** Same refers to the dictation exercises.*
Soon: item and sentence selection – depending on proficiency level, defined wordclass and/or domain

Vocabulary items 3
future version*

1. Randomly select an item for training from the CEFR-based list with the scope of receptive vocabulary per proficiency level

1. Randomly select an item for training from the Kelly list

2. Select an appropriate sentence containing the target item with a level-aware algorithm

2. Randomly select a sentence containing the target item

3. Adjust distractor selection to proficiency levels

3. Select distractors



**Same refers to the spelling and dictation items*

Lärka's research agenda

- Dictated by the practical needs of development
- Automatic generation of learning materials
  - ✔ *for L2 vocabulary training & for students of Linguistics (at the moment)*
  - ✔ *in sentence-long context (at the moment)*
- Practical needs:
  - ✔ *receptive vocabulary scope per level*
  - ✔ *sentence readability measure per level*
- How?
  - ✔ *e.g. study texts used for teaching CEFR-based courses, per level?*
  - ✔ *crowdsourcing?*
  - ✔ *any other ways?*

CEFR-corpus

project financed by the Department of Swedish

- Gold standard for CEFR-based research
- Text types: normative (input) and learner-produced (output)



- Focus in this project: normative texts

CEFR-corpus 2
identifying relevant sources

- Interviews with teachers on relevant course books & novels used in CEFR-based teaching
  - ✔ *resulted in a list of 15+ titles*
  - ✔ *that contain 3187+ pages;*
  - ✔ *with an estimated corpus size of approx. 3 mln tokens*

- Contacts with publishers
  - ✔ *Folkuniversitets förlag, Studentlitteratur, Natur och Kultur, Svenska institutet – negative to sharing electronic materials*
  - ✔ *Liber – positive to collaboration; provided e-texts for research*

UNIVERSITY OF GOTHENBURG

CEFR-corpus 3

optical scanning approach

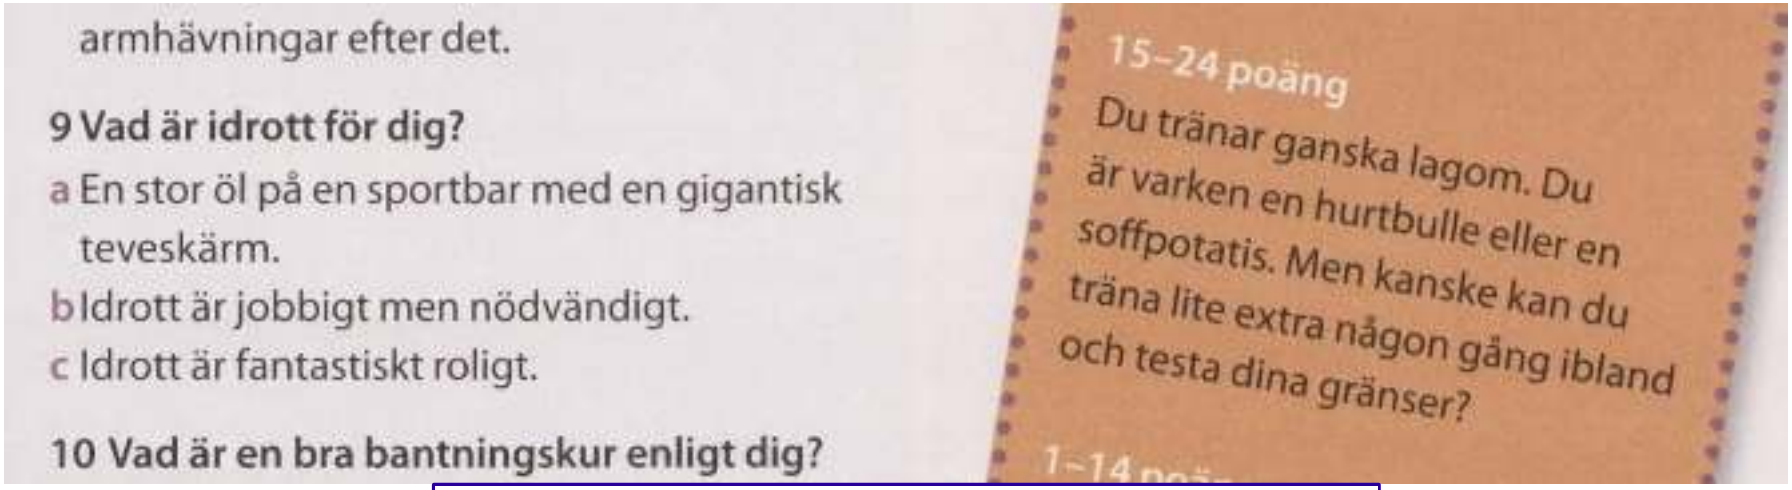
armhävningar efter det.

9 Vad är idrott för dig?

a En stor öl på en sportbar med en gigantisk teveskärm.

b Idrott är jobbigt men nödvändigt.

c Idrott är fantastiskt roligt.

10 Vad är en bra bantningskur enligt dig?

15–24 poäng

Du tränar ganska lagom. Du är varken en hurtbulle eller en soffpotatis. Men kanske kan du träna lite extra någon gång ibland och testa dina gränser?

1–14

9 Vad är idrott för dig?
a En stor öl på en sportbar med en gigantisk teveskärm.
b Idrott är jobbigt men nödvändigt.
c Idrott är fantastiskt roligt.
braät"öTn!hU"bu"e!Det
ar
^ attrÖraPåsigoch mer> kanske* CL. . a
tänka på att
danske ska r,
: Osanna . Uanfa
; Kr°PPenbehöv ""ani"9iliVet ; 'bland. 0också vila
:
ar varken enh5ka 'd90m Du SOffP«afe.Men?U"ee"eren 'rän*l*eeZ
.kansk^ndu
• 0ch^«nagZ2fn9ibl*™
10 Vad är en bra bantningskur enligt dig?

CEFR-corpus 4
text-level annotation

- Lärka-based editor helps to insert text variables:
  - ✔ *proficiency level for the "lesson" (i.e. chapter in a course book)*
  - ✔ *texts, genres, topics*
  - ✔ *other types of language: activity instructions, tasks themselves (e.g. gaps), lists, grammar/vocabulary focus, etc.*

UNIVERSITY OF GOTHENBURG

Taxonomy of text variables

Text parameters: Genre	Text parameters: Topic	Other types of text in lessons

Genre
• Narration
  • Personal story
  • Fiction
  • Description
  • News article
• Facts
  • Historical facts
  • Biography
  • Autobiography
  • Explanation
  • Instruction
  • Rules
  • Procedures
  • Report
  • Demonstration
• Evaluation
  • Argumentation
  • Exposition
  • Discussion
  • Personal reflection
  • Review
  • Interpretation, exegesis
  • Persuasion
• Other
  • Dialogue
	Topic
	• Personal identification
	• House and home, environment
	• Daily life
	• Free time, entertainment
	• Travel
	• Relations with other people
	• Health and body care
	• Education
	• Shopping
	• Food and drink
	• Services
	• Places
	• Languages
	• Weather
		Activity instruction
		• Listening
		• Reading
		• Writing
		• Speaking
		• Discussion
		• Grammar exercise
		• Vocabulary exercise
		• Text question
		Task
		• Listening
		• Reading
		• Writing
		• Speaking
		• Discussion
		• Grammar exercise
		• Vocabulary exercise
		• Text question
		• Gaps
		List
		• Vocabulary
		• Grammar
		• Sentences
		Language example
		• Vocabulary
		• Grammar
		• Pronunciation

UNIVERSITY OF GOTHENBURG

CEFR-corpus editor

www.spraakbanken.gu.se/larka/larka_cefr_editor.html

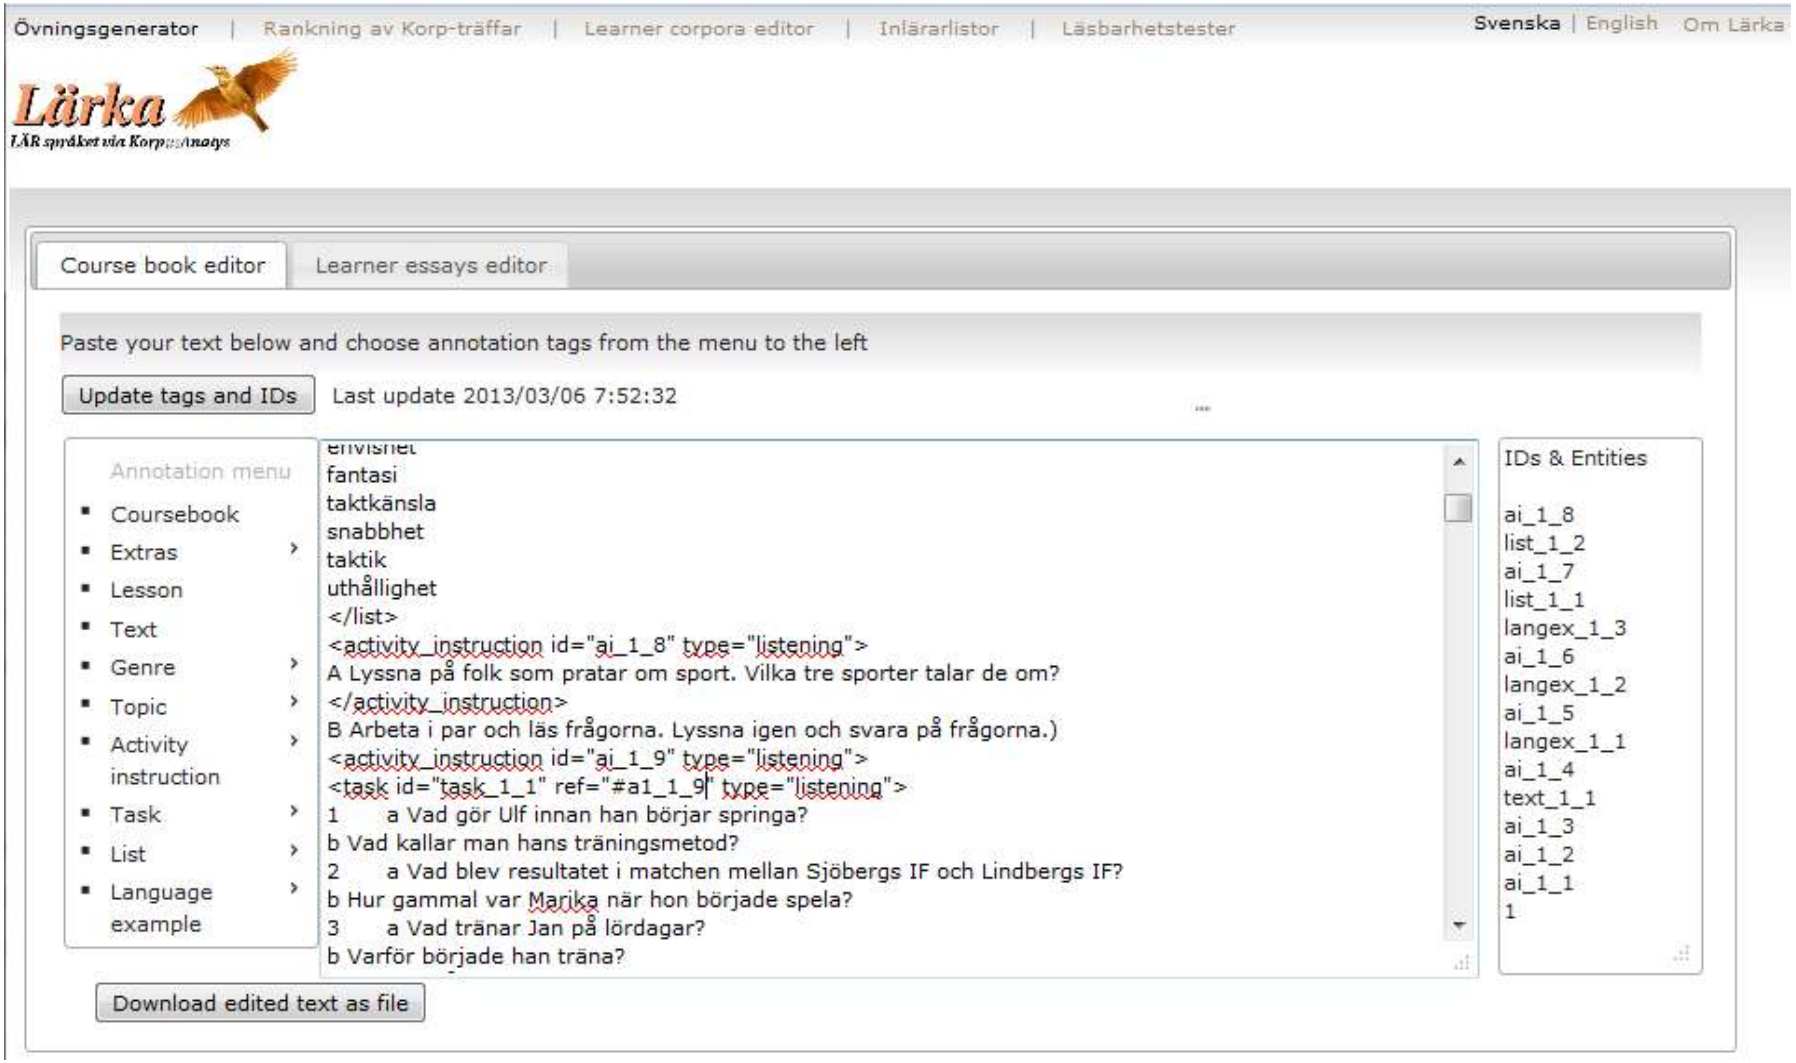

LASSE-MAJA



På 1800-talet var biografin *Lasse-Majas äventyr* den mest lästa boken i Sverige vid sidan av Bibeln. I boken berättar tjuven och transvestiten Lars Molin själv om sina öden och äventyr. Lars Molin föddes som Lars Larsson, men bytte efter en tid efternamn. Namnet Lasse-Maja kommer av att Lars oftast gick klädd i kvinnokläder.

Lars Larsson föddes 1785 i närheten av Arboga, i södra Bergslagen. Han var en busig pojke som tyckte mer om att snatta pengar, spela kort och lata sig än att arbeta. En bit ifrån Lasse bodde Maja som blev hans första fästmö. Lasse var en smal och söt pojke och en dag provade han sin fästmös kläder. Maja tyckte att Lasse var mycket fin i kvinnokläder och även hennes föräldrar blev imponerade.

Från den dagen gick Lasse oftast klädd i kvinnokläder och han övade sig på allt som en kvinna förväntades kunna. Han arbetade klädd som bondpiga på gårdar, ibland tillsammans med Maja, och lärde sig att mjölka, laga mat, baka, städa, tvätta och annat. Det verkade som om kvinnojobb passade honom bättre än mansjobb, som lätt tråkade ut honom.

Lasse-Maja blev en duktig kock och han lärde sig att sy och dansa. Många trodde att han var en fin fröken och han fick enkelt tjänst på olika fina gårdar med hjälp av förfalskade betyg. På gårdarna blev han

CEFR-corpus
teaser1

- What is the genre?
  - ✔ narration / description?
  - ✔ facts / biography?

- What is the topic?
  - ✔ famous people?
  - ✔ crime & punishment?

CEFR-corpus

teaser 2

- What is the genre?
  - ✓ facts / instruction?
  - ✓ evaluation / personal reflection?

Ulf Frövi är psykolog och arbetar som konsult med personer som ska flytta utomlands. Här ger han några råd som kan underlätta processen:



- När det känns jobbigt, tänk på att livet till stor del består av små och stora problem som ska lösas, även i ditt hemland.
- Försök lära dig så mycket som möjligt om den nya kulturens historia, politik, geografi, konsthistoria osv. Ju mer du vet desto mer förstår du.
- Glöm inte bort dina intressen och hobbyer. Om du förut var medlem i någon klubb, försök då att hitta motsvarande klubb i ditt nya land. Det kan vara svårt att få nya vänner, men ett bra sätt är garanterat att försöka hitta personer som har samma intressen som du.
- Värdera inte och jämför inte olika länder. Konstatera bara att man gör på olika sätt i olika länder.
- Om du är frustrerad över hur dina nya landsmän beter sig, tänk då på att du inte kan ändra på ett helt folk. De är ganska nöjda med sakernas tillstånd. Du kan bara ändra på din egen attityd och ditt eget beteende.
- Om du har en partner från ett annat land, försök då att vara flexibel utan att glömma bort värderingar och principer som är viktiga för dig. Välj dina krig. Ta bara upp diskussioner om sådant som du tycker är extra viktigt. Det är kanske viktigare t ex att vara överens om hur barnen ska uppfostras, än exakt vilka jultraditioner ni ska ha.

CEFR-corpus 5
linguistic annotation

- Linguistic annotation (standard Korp pipeline):

  parts of speech (*pos*), morpho-syntactic information (*msd*), syntactic relations (*ref, dephead, deprel*), *lemmas*, and linking to morphology lexicon (*lex, saldo*).

```
<w pos="HP" msd="HP.NEU.SIN.IND" lemma="|vad|"
lex="|vad..pn.1|" saldo="|vad..1|" prefix="|" suffix="|"
ref="1" dephead="4" deprel="+F">vad</w>

<w pos="VB" msd="VB.PRS.AKT" lemma="|vilja|"
lex="|vilja..vb.1|" saldo="|vilja..1|" prefix="|" suffix="|"
ref="2" dephead="4" deprel="MS">vill</w>
```

CEFR-corpus
present-day status

- Two course books for B1 (intermediate) level
  - ✔ *scanned*
  - ✔ *annotated*
  - ✔ *uploaded into Korp (demo?)*

- Tests on sentence readability for B1 level
  - ✔ *master thesis project by Ildikó Pilán*
  - ✔ *to be presented at EuroCALL 2013*



MT on sentence readability: Purpose

- Automatically **select** and **rank** sentences from Swedish native language texts.
- Sentences should be:
  - **understandable** by students of Swedish as a second language (L2), especially at B1 level
  - suitable **exercise item**
  - appropriate **examples** to illustrate a new lexical item.

- Target users:

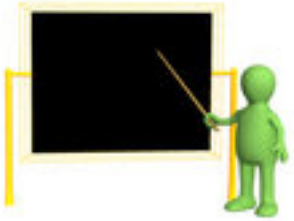

Teachers of L2 Swedish



Students of L2 Swedish



Lexicographers

Most informative features	Logistic Reg. (RFE)	Decision Tree
Sentence length	✓	✓
Average token length	✓	✓
Percentage of words longer that 6 characters		✓
Modifiers	✓	
Average dependency depth		✓
Average number of senses per word	✓	✓
Nominal Ratio	✓	✓
Average frequency in the Wikipedia list	✓	
Average frequency in Kelly list	✓	✓
Percentage of difficult words	✓	✓
Number of difficult words	✓	
Adverb variation	✓	
Noun / Verb ratio	✓	
Model Verb / Verb ratio	✓	

The readability module



preferences



keyword → ORP → sentences

parameters



FRONTEND

(user interface)

BACKEND

(web service)

filtered and **ranked** sentences

The user interface in Lärka

http://spraakbanken.gu.se/larka/larka_hitex_index.html

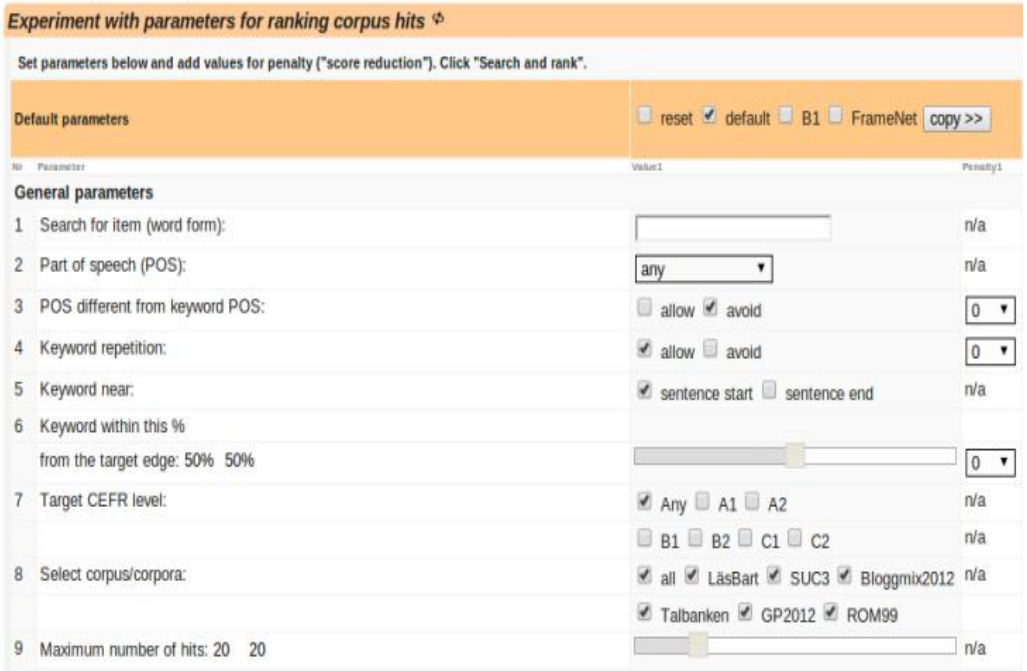

Experiment with parameters for ranking corpus hits

Set parameters below and add values for penalty ("score reduction"). Click "Search and rank".

Default parameters	reset ☑ default ☐ B1 ☐ FrameNet copy >>	
Nr Parameter	Value1	Penalty1
General parameters		
1 Search for item (word form):		n/a
2 Part of speech (POS):	any	n/a
3 POS different from keyword POS:	☐ allow ☑ avoid	0
4 Keyword repetition:	☑ allow ☐ avoid	0
5 Keyword near:	☑ sentence start ☐ sentence end	n/a
6 Keyword within this %		
from the target edge: 50% 50%		0
7 Target CEFR level:	☑ Any ☐ A1 ☐ A2	n/a
	☐ B1 ☐ B2 ☐ C1 ☐ C2	n/a
8 Select corpus/corpora:	☑ all ☑ LäsBart ☑ SUC3 ☑ Bloggmix2012	n/a
	☑ Talbanken ☑ GP2012 ☑ ROM99	
9 Maximum number of hits: 20 20		n/a

CEFR-corpus
intended use

- Identification of receptive vocabulary per proficiency level
- Test on *sentence* readability per proficiency level
- Tests on *text* readability per proficiency level
- Topic modeling
- Question generation
- Mapping CEFR “can-do” statements to linguistic constituents
- etc.



Lärka's research agenda

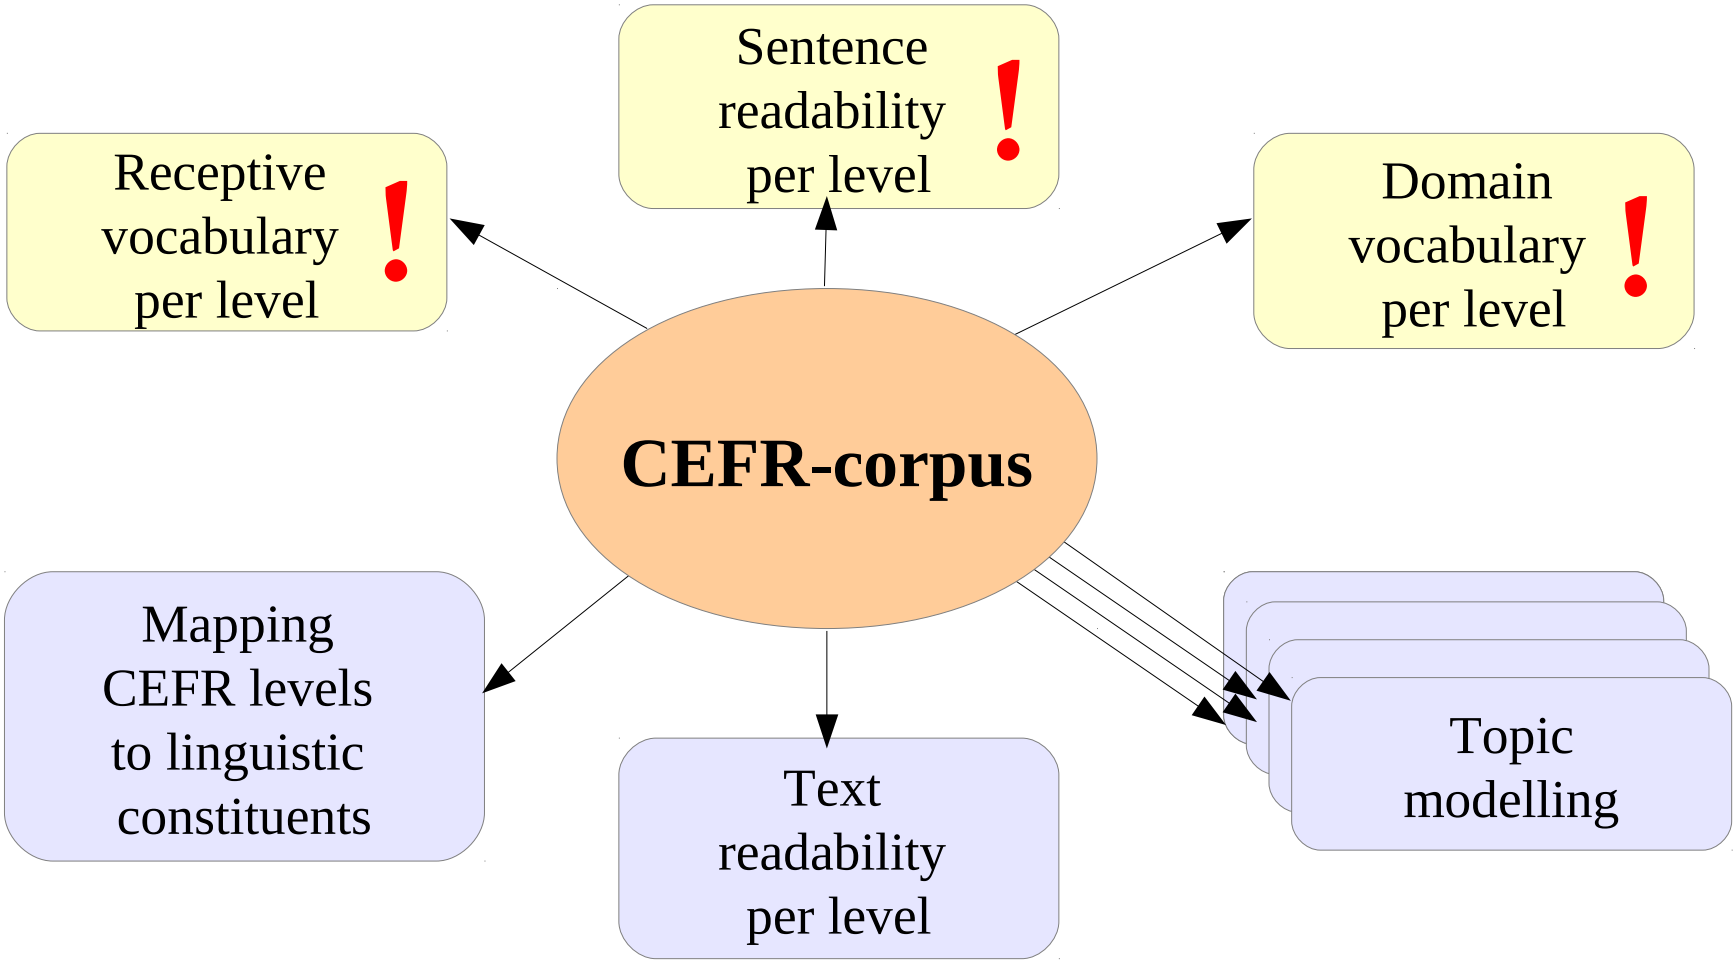

Thank you!

Questions?