



英語コーパス学会第48回大会

2022年10月1日 (土) 9時30分～17時40分 On Zoom

Workshop : Data-Driven Course Design

Tom Cobb

Université du Québec à Montréal

cobb.tom.3@gmail.com

Sat Oct 1 2022 9:40-10:40



The importance of vocabulary knowledge in any type of language course or curriculum is now acknowledged but still not easy to incorporate in a systematic manner. There are few dedicated vocabulary courses, and the ones there are do not match the increasing specialisation of many learner programs. Lextutor has been designed to basically take on the whole job of a dedicated vocabulary supplement from a practical corpus perspective. My workshop will show the main steps in this process, from building a corpus of learning materials, to placement testing, to text selection and adaptation, to assuring a manageable supply of new and appropriate items, to test writing that reflects what learners have actually been exposed to sufficiently to be tested on. The theme is 'corpora for courses' and I will share results from locales where this approach and technology is being deployed.

Premise and RQ

Much learning research has been done

- And replicated

Many good corpus tools based on it are available

- And online or free to download

How often/systematically are these be brought together for the benefit of learners?

- IE, as courses? Curricula?

What would doing so look like? SOME CONCRETE IDEAS→

Definitions, context, rationale

Corpus

- Representative collection of texts
 - Ex Brown Corpus (1960s)
 - 1 million words
 - 500 textes on 15 topics of 2000 words each
 - BNC (1980s)
 - 100 million words
 - >4000 texts on 100 topics of 25,000 words (approx.)
 - COCA, Subtlex, TenTen ...

Corpus – read and interpreted how ?

001. ☐ 0 décembre, 134 personnes 53 hommes, 55 FEMMES 26 enfants de un à treize ans ét
002. ☐ de ces deux affaires, une homme et une FEMME : Alfred Sirven, ancien directeur
003. ☐ ns cent quatre-vingt-dix hommes et deux FEMMES ? Un peu plus tôt, a-t-il partici
004. ☐ chorégraphie. La pièce met en scène une FEMME agressée par deux hommes et appela
005. ☐ pide peur de l'homme, des hommes et des FEMMES aussi... Un besoin maladif d'igno
006. ☐ août 1942. Déjà, de nombreux hommes et FEMMES avaient été astreints à des péri
007. ☐ amenant vers l'emploi des hommes et des FEMMES dans la force de l'âge, souvent c
008. ☐ 'hématocrite chez 46 athlètes hommes et FEMMES de haut niveau (participant à des
009. ☐ . Les hommes d'aujourd'hui traitent les FEMMES de manière aussi primitive, aussi
010. ☐ de vingt-cinq ans et aux hommes et aux FEMMES de plus de vingt-cinq ans. En rev
011. ☐ long desquelles se succèdent hommes et FEMMES de toutes conditions et origines
012. ☐ ne se reproduisent, tous les hommes et FEMMES du groupe qui travaillent à la re
013. ☐ hommes d'affaires tout-puissants... "La FEMME du président" a encore six heures
014. ☐ ravallait comme un homme, ou comme une FEMME Elle croit ce qu'elle dit et dit
015. ☐ onnage principal, l'homme trompé par sa FEMME employant maints stratagèmes pour
016. ☐ ports ambigus d'un vieil homme et d'une FEMME en fleur. Une tragédie intimiste s
017. ☐ janvier, traite ainsi des hommes et des FEMMES en politique dans le monde, du "m
018. ☐ nt ce partage de la vie entre hommes et FEMMES en termes politiques et culturels
019. ☐ emportent maintenant des hommes et des FEMMES encore jeunes qui laissent des en
020. ☐ e malade et doit subir la cruauté de sa FEMME Enlevé par ses hommes, il finit p
021. ☐ rieusement atteinte ? "J'espère que les FEMMES et aussi les hommes de ce pays e
022. ☐ vant ces ouvrages historiques signés de FEMMES et d'hommes publics, dont on imag
023. ☐ du Soudan ROUX OLIVIER DES hommes, des FEMMES et des enfants meurent de faim au
024. ☐ le monde a toujours fermé les yeux. Des FEMMES et des hommes n'ont cessé de tire
025. ☐ es", "filières criminelles") contre des FEMMES et des hommes prêts à se laisser

Definitions...

“Data driven learning” or “corpus based learning”




Figure 1. The place of data-driven language learning in the broader scheme

Main idea of DDL

Language learning happens through input,

BUT

- Language input reveals its patterns slowly
 - Too slowly to be effective in most L2 learning
- Input, however, can be treated by computer programs to expose patterns more quickly
 - more clearly
- To create more transparent, 'learnable' input
 - Patterns exposed through data 'agglomeration'
 - As compared to rules or explanation

DDL (Data driven learning)

is well established as a set of learning tools

- Concordances, frequency lists, learner-as-linguist, discovery learning, pattern extraction, exemplar-based not rule-based learning, etc.
 - But does it work?
- Boulton & Cobb (2017) meta-analysis of DDL
 - Effect size of **1.5** cf 'traditional' learning method
 - Meaning scores 1.5 standard deviations higher
- Many ESL courses now employ these tools piecemeal
 - But can they be integrated systematically?
 - At the point of course conception?

Learning from corpora (=DDL)

Apprendre à travers l'utilisation des corpus / Apprentissage faisant appel aux corpus


- Récemment montré efficace de façon concluante (2017)

Comparé à une gamme d'autres
moyens d'apprendre...

Le vocabulaire
Les locutions
Le syntaxe
La grammaire
La culture

... DDL 'GAGNE' par la taille de l'effet de
1,5 écarts-types (**effect size of 1.5**) pour
les études pré-post

Ex. <u>Control Group Mean</u>	65 , SD 15
<u>DDL Group Mean</u>	80 , SD 15



Example of a DDL learning activity?

Constructing word meanings from raw data vs pre-constructed knowledge

<=Back Save on Lextutor as L'ENA[4].html

HYPERTEXT FILE: in_progress_42
Click twice for concordance (50 lines) & dictionary, with AltKey (Option) to grab word

L'Ecole normale supérieure tentée par la philosophie des affaires -
Le Monde Diplomatique, d'août 2011, par Mathias Roux

Des serviteurs de l'Etat poussés vers le privé

Créée après guerre, l'ENA devait former des grands commis de l'Etat ; bicentenaire, l'Ecole normale supérieure avait pour mission de produire un corps enseignant d'élite baigné de valeurs humanistes. Devenues des instruments de reproduction de la classe dirigeante française, ces deux institutions **prestigieuses** tentent de s'imposer comme un sas vers le monde des affaires.

Concordance for *equals* **PRESTIGIEUSES** sorted 1 wds left of key Dictionnaire: Fren_Eng Get

Change >> Key equals prestigieuses +assoc on left sorted 1 wd/s left

7 hits (normalized to 6 per million for comparison) Click keyword for more context

001. ☐ en passant des accords avec ces institutions **PRESTIGIEUSES**, disait : "Regardez, la Bibliot
002. ☐ t. Destiné à faire de l'ombre aux limousines **PRESTIGIEUSES**, ce modèle vendu près de 300 00
003. ☐ est devenu le lieu d'accueil d'une des plus **PRESTIGIEUSES** séries de musique de chambre d'
004. ☐ n en trouve désormais partout. Même les plus **PRESTIGIEUSES** institutions du royaume comme l
005. ☐ usieurs centaines de médecins issus des plus **PRESTIGIEUSES** universités inoculèrent à des c
006. ☐ évisionniste qui compte plusieurs signatures **PRESTIGIEUSES**. Mais aussi son éviction de SPA
007. ☐ niste, pour réunir une palette de signatures **PRESTIGIEUSES** : Nouvel, Portzamparc, Vasconi

←vs.→

Swisscom 10:39 AM 67%

French - English

prestigieux

French - English French - Verbs

prestigieux [LINKS]

ECOUTER: FRANCE [pʁɛstizjø, jøz]

Inflections of 'prestigieux' (adj): f: prestigieuse, mpl: prestigieux, fpl: prestigieuses

WordReference Collins WR Reverse (4)

WordReference English-French Dictionary © 2019:

Principales traductions

Français	Anglais
prestigie ux <i>adj</i>	prestigious <i>adj</i>
(qui a de l'éclat)	
Cette maison de couture a une réputation prestigieuse.	
This fashion designer has a prestigious reputation.	

Un oubli important ? Signalez une erreur ou suggérez

Qu'est-ce qu'une activité d'apprentissage basée sur un corpus?

Exemple 2 – sensibilisation à la culture

Tâche

- Do concordances for 'woman' with collocation 'man' on either side in English, French, and Spanish corpora
 - Woman - man
 - Femme – homme
 - Mujer – hombre

Then in a one-page report:

- Is the sequence always man first then woman second across these three languages?
- In which language is there most variation in the sequence?
- Is the common sequence formulaic or indicate a belief in the superiority of one gender?
 - Or with one gender acting and the other being acted upon?

001. ☐ 0 décembre, 134 personnes 53 hommes, 55 FEMMES 26 enfants de un à treize ans ét
002. ☐ de ces deux affaires, une homme et une FEMME : Alfred Sirven, ancien directeur
003. ☐ ult life of the average American man or WOMAN. Following a vigorous campaign of
004. ☐ not standing up to them. An aggressive WOMAN wants a man to demand, not knuckle
005. ☐ all the way home. The ordinary man and WOMAN, however, saw little of the great
006. ☐ to the life of the middle-class man or WOMAN, dictating the methods of child re
007. ☐ t exasperating to men, who expect every WOMAN to verify their preconceived notio
008. ☐ er, he muttered, to meditate on man (or WOMAN) than on God. David finished shavi
009. ☐ dresser". "I guess it's children make a WOMAN old. A man gets old anyhow". After
010. ☐ e. There was a very old man and a young WOMAN and a brood of children ranging fr
011. ☐ r tilted back. "So you're looking for a WOMAN who married a man who might have 1
012. ☐ ecial reason to believe that the man or WOMAN they sought had stayed only overni
013. ☐ at? The door opened and three men and a WOMAN in a sari swept past him and down
014. ☐ a scout ship, partnered with a man or a WOMAN, whichever she chose, as the mobil
015. ☐ house. Now he saw that both the man and WOMAN were moving slowly and irregularly
016. ☐ many affairs of the heart, a man and a WOMAN meet and something clicks. Somethi
017. ☐ in stormy weather I marry this man and WOMAN together. Let none but Him who rul
018. ☐ who rules the thunder Put this man and WOMAN asunder". Absolution for his lie?
019. ☐ fteen miles east of here. Eleven men, a WOMAN and a teen-age boy tramped over co
020. ☐ ." is a problem piece about a man and a WOMAN and the three "figures" that bothe
021. ☐ hem somehow. Unfortunately, the man and WOMAN were not made to appear very inter
022. ☐ the rain came more heavily, and men and WOMEN in light summer clothes began to d
023. ☐ en my experience to find as many men as WOMEN in church, and to hear almost ever
024. ☐ he church school, missions, men's work, WOMEN's work, youth program, social acti
025. ☐

Why *should* this learning method be effective ?



The case in principle (1)

Analys
010011
1 Trait
010011
de010

Data-driven learning (DDL): using the tools and techniques for teaching/learning/using a foreign/second language

- Greater effort
better retention/deeper learning
- Strategy training
learn to observe patterns in environment (exposure)
- Incidental learning
“pick up” collocations while assembling word meanings
- Appeal to research-oriented clientele
as opposed to ESL textbooks; PhD students, etc.



The case in principle (2)

Analys
010011
1 Trait
010011
de0101a0100011101

Data-driven learning (DDL): using the tools and techniques of CL for teaching/learning/using a foreign/second language

- A basis for CALL
that goes beyond read/listen + MCQ with fixed answer
- Show not tell (constructivism)
complex, dynamic, probabilistic, usage-based
- Autonomy
own questions, life-long learning, multiple affordances
- Shapes up what students do anyway
use Google for language research

But *learning* with corpora is not the topic of today's lesson

Rather *teaching* with corpora

Or, the design of courses conceived as corpora

And for this we need some DDL research tools

- Frequency lists based on both standard and course corpora
 - Frequency-list based tests
 - Frequency-list based text profiler
 - Lexical frequency profiler (LFP, Laufer & Nation)
- Some empirical findings to guide tool development
 - E.g. that reading comprehension depends on 95% know-word coverage
 - Laufer (1989 ... 2020)


The standard French corpus used on Lextutor

Corpus

List

	# de mots (approx.)	Genre
Oral		
	175,000	Conversations
	3,750,000	Hansard canadien
	3,020,000	Transcrits d'interviews
	1,000,000	Débats parlementaires de l'UE
	855,000	Appels téléphoniques
	470,000	Dialogues de théâtre
	2,230,000	Sous-titres de films
TOTAL	11,500,000	
Écrit		
	3,000,000	Agences de presse
	2,015,000	Articles de quotidiens
	4,734,000	Œuvres littéraires (fiction, non-fiction)
	434,000	Magazines de vulgarisation technique
	1,317,000	Bulletins de presse, manuels d'emploi
TOTAL	11,500,000	
AU TOTAL	23,000,000	

Tableau 1 : Composition du corpus



FREQUENCY LIST

1. de 64006
2. la 31617
3. le 23365
4. et 20555
5. les 19532
6. des 19202
7. en 15185
8. du 14915
9. un 12781
10. a 12091
11. une 11168
12. est 10026
13. qui 9128
14. que 8796
15. dans 8124
16. pour 7600
17. par 7469
18. au 6991
19. pr 6428
20. sur 6224
21. pas 5382
22. ne 5303
23. plus 4987
24. ... 4751

Lemmatized
and sorted by
LEMMA
frequency
(not
individual
word freq.)

Aller	10,000
vais	3,000
vas	750
allé	500
etc.	
TOTAL	14,250

... and divided into groups of 1,000 lemmas

1k

<https://lextutor.ca/vp/c>
lextutor.ca/vp/comp/fr_5

à
âge
école
économie
économique
écouter
écrire
éducation
également
égard
élément
élection
élever
émission
énergie
époque
équipe
équipement
établir
établissement
état
étranger
étude
étudiant
étudier
événement
éviter
être
accès
accepter

2k

lextutor.ca/vp/c

âgé
âme
écarter
échange
échapper
échec
échelle
écho
éclater
écrivain
édition
égal
égalité
église
élève
élaborer
électeur
électoral
éliminer
élire
éloigner
émettre
énorme
épaule
époux
épreuve
éprouver
équilibre
équivalent
été
étape
étendre
étonner

3k

lextutor.ca/vp/comp/fr_5

écart
échanger
échouer
éclairer
écouler
écran
écraser
écrit
écriture
écu
éditeur
élargir
électricité
électrique
électronique
élite
émotion
énormément
épargne
épouser
équilibrer
équité
équitable
étage
éteindre
éternel
éthique
étoile
étonnant
étroit
évacuer
éventuellement
ainé

4k

lextutor.ca/vp/comp/fr_5



ère
échéance
échantillon
éclat
écologique
économiste
écoute
écrier
édifice
éditorial
égyptien
élémentaire
élaboration
élan
élargissement
élevé
élimination
élu
émaner
émerger
émetteur
émouvoir
énergétique
énoncer
épais
épargner
épidémie
épisode
épuiser
équipage
équiper
étaler
état major

5k etc ... → 25k

lextutor.ca/vp/comp/fr_5

échéant
échelon
éclaircir
économiquement
économiser
écrasant
écrouler
élégant
éloge
émeute
éminent
énergique
énumérer
épanouir
épouvantable
équation
équivaloir
ériger
étroitement
évasion
éventail
éventualité
abord
aboutissement
abstenir
accélération
acceptation
accessoire
accompli
accumulation
acharner
acheteur
acide

Such that every word has its 'serial number'



Reflecting the order they are typically found in the environment

+ the importance of their being learned

(depending on the corpus used, obviously)

So, with corpus and numbered word-lists in hand...
What can we do with this?

- Mainly, we have the means of providing learners with systematic vocabulary development
- Starting with systematic tests of vocabulary level in any language

With these lists and some tools anyone can make reliable level-based tests

- ONE
Format Oui-Non

[Home](#) > [Randomize](#) > RandWords FR_5

Random **F R E N C H** items
generator v. 1

What:
Generate x random items from TEN Lonsdale & Le Bras
French frequency lists [\[?\]](#)

How:
Choose list, click Go (repeatable)

List:

Number of Items:


Re-Clickable

List framework IS **FR_5**
fr_5_heads(02).txt

vide
fabriquer
pétrole
revoir
impression
ignorer
acteur
entretien
avocat
côte

List framework IS **FR_5**

fr_5_heads(02).txt



poulard
sconber
radeurs
cageait
atérait

vide
fabriquer
pétrole
revoir
impression
ignorer
acteur
entretien
avocat
côte

USE RANDOM WORDS TO...


OPTION ONE

Do whatever you like

OPTION TWO

Make novel Yes-No Checklist Tests in
four easy steps ([Why & How](#))

[1] From Generator on the left screen,
get 25 random real words
at a level, eliminate 5



[2] Click **HERE** to add 50% PNWs to
your list
(Length-appropriate random PNWs)

[See all PNWs](#) 'plausible non-words'
Note which are PNWs before integrating!

[3] Click [HERE](#) to integrate

[4] Make an MS-Word document with
three or four columns or [use template](#)

List framework IS **FR_5**

fr_5_heads(02).txt

acteur
atérait
avocat
cageait
côte
entretien
fabriquer
ignorer
impression
poulard
pétrole
radeurs
revoir
sconber
vide

USE RANDOM WORDS TO...

OPTION ONE

Do whatever you like

OPTION TWO

Make novel Yes-No Checklist Tests in
four easy steps ([Why & How](#))

[1] From Generator on the left screen,
get 25 random real words
at a level, eliminate 5

[2] Click **HERE** to add 50% PNWs to
your list
(Length-appropriate random PNWs)

[See all PNWs](#) 'plausible non-words'

Note which are PNWs before integrating!




[3] Click [HERE](#) to integrate

[4] Make an MS-Word document with
three or four columns or [use template](#)

[5] Select, Copy, & Paste your words to
one column

FRANCAIS 101 - 2k receptive vocab. Knowledge/diagnostic test
PROF BATISTA / student _____ 21 MAR 2019

Put a check mark beside each word you know, however slightly. Some of the words are not real words, do not check those.



2k	3k	4k	5k
acteur	aistrophe	abbey	aerial
atérail	axis	abolish	bourgeois
avocat	battalion	acklon	cambule
cageait	berrow	blunt	cramp
côte	beta	bypass	dole
entretien	binoculars	clap	dowrick
fabriquer	charitable	connery	eccentric
ignorer	commemorate	cradle	eldred
impression	dazzle	delete	fatigue
poulard	dispense	dissent	gummer
pétrole	eldred	duffin	haque
radeurs	elusive	elastic	hinge
revoir	forthcoming	immerse	kiley
sconber	galpin	junction	lavish
vide	inhale	lannery	leaflet
	knight	limp	millilitre

LEXTUTOR

Down
Load

MOBILE

FRENCH Y-N Tests

ID

100 and 1,000-Lemma Sets x Freq.

K0-1	K1-2	K2-3	K3-4	K4-5
C1	C1	C1	C1	C1
C2	C2	C2	C2	C2
C3	C3	C3	C3	C3
C4	C4	C4	C4	C4
C5	C5	C5	C5	C5
C6	C6	C6	C6	C6
C7	C7	C7	C7	C7
C8	C8	C8	C8	C8
C9	C9	C9	C9	C9
C10	C10	C10	C10	C10
K1	K2	K3	K4	K5

List Info

"k1c1" = 1,000-1,100 zone

Allez version anglaise!

<www.lex tutor.ca

<

Y-N Test

k5

ID

Check the words you know then Score

- | | | |
|--------------------------------------|---------------------------------------|--|
| ☐ agenda | ☐ encourageant | ☐ parriteur |
| ☐ agrandir | ☐ inattendu | ☐ perturbation |
| ☐ avantageux | ☐ licenlier | ☐ portable |
| ☐ blâmer | ☐ maitissant | ☐ querelle |
| ☐ certirait | ☐ mallenier | ☐ redévant |
| ☐ coderait | ☐ maqueteur | ☐ ruiner |
| ☐ compliqué | ☐ merveille | ☐ régiment |
| ☐ concilier | ☐ mexicain | ☐ spéculation |
| ☐ contaire | ☐ occupant | ☐ terriblement |
| ☐ déploiement | ☐ olchefêque | ☐ théoriquement |

Score

<

Y-N Test

k0c1

ID

Check the words you know then Score

- | | | |
|-------------------------------------|---------------------------------|----------------------------------|
| ☐ aller | ☐ fois | ☐ pour |
| ☐ bien | ☐ guirum | ☐ pouvoir |
| ☐ bria | ☐ jour | ☐ rendre |
| ☐ colé | ☐ mais | ☐ rester |
| ☐ comprendre | ☐ monde | ☐ suite |
| ☐ dernier | ☐ notre | ☐ tané |
| ☐ dolium | ☐ nous | ☐ taître |
| ☐ dont | ☐ part | ☐ tout |
| ☐ exacté | ☐ passin | ☐ trouver |
| ☐ falloir | ☐ polète | ☐ vignée |

Score

[2] Or something more standard, similar to Nation's VST

- Exemple
(Le “TTV”, RCLV, 2016)

A New Receptive Vocabulary Size Test for French

Box 4. A noun cluster from 5K frequency section of the TTV

- | | |
|----------------|---------------------------------------|
| 1. brouillard | |
| 2. coïncidence | |
| 3. farce | _____ une histoire qui fait rire |
| 4. instituteur | _____ ce qui empêche de voir loin |
| 5. pneu | _____ un professionnel de l'éducation |
| 6. soumission | |

A New Receptive Vocabulary Size Test for French

Roselene Batista and Marlise Horst

Abstract: Researchers have developed several tests of receptive vocabulary knowledge suitable for use with learners of English, but options are few for learners of French. This situation motivated the authors to create a new vocabulary size measure for French, the *Test de la taille du vocabulaire* (TTV). The measure is closely modelled on Nation's (1983) Vocabulary Levels Test (VLT) and follows the guidelines written by Schmitt, Schmitt, and Clapham (2001). Initially, a pilot version was trialled with 63 participants; then an improved version was administered to 175 participants at four proficiency levels. Results attest to the TTV's validity: mean scores across the four frequency sections decreased as the tested words became less frequent, and more proficient learner groups outperformed less proficient groups. The TTV in its current form is intended to be of practical use to teachers and learners, but it is also expected to evolve; ideas for future improvements are discussed.

Keywords: frequency, French L2 vocabulary, vocabulary size, assessment

Résumé : Des chercheurs ont développé plusieurs tests de vocabulaire réceptif pour les apprenants d'anglais, mais les options pour les apprenants de français ne sont pas nombreuses. Ce scénario a motivé les auteurs à créer un nouvel outil qui mesure la taille du vocabulaire en français, le *Test de la taille du vocabulaire* (TTV). Cet outil repose sur le modèle du *Vocabulary Levels Test*, conçu par Nation (1983), et suit les directives proposées par Schmitt, Schmitt et Clapham (2001). Premièrement, une version pilote a été testée auprès de 63 participants, ensuite une version améliorée a été complétée par 175 participants de quatre niveaux de compétence distincts. Les résultats confirment la validité du test: les moyennes obtenues par les participants à chacune des qua-



LEXTUTOR

Down
Load

MOBILE LEVELS TESTS

Score-Recording Tests

Back Button to return to this page


VLT
Vocab Levels Test

VLT v.2

VST
Vocab Size Test

TTV
Test de la taille du vocab

www.lextutor.ca



Swisscom 11:31 AM 83%

lextutor.ca

Home > Tests > Levels > TTV (Fr: 2-10k)

Test de la taille du vocabulaire

Mode = practice [Go Test mode](#)

Batista & Horst, 2016

Tip: For easy entry, following Question 1, use TAB key to select boxes for number entry. Or ^ and v keys on iPad keyboard

[Instructions](#) [Print Test](#)

SCORE as practice

2k score 3/30 (10%)
Prob. sets 2 3 4 5 6 7

3k score 0/30 (0%)
Prob. sets 1 2 3 4 5 6

5k score 0/30 (0%)
Prob. sets 1 2 3 4 5 6

10k score 0/30 (0%)
Prob. sets 1 2 3 4 5 6

SET ORDER
1>2
3>4
5>6
7>8
9>10

RESET

La deuxième tranche de mille mots

1. concours		1. brûler	
2. division	3 grand plaisir	2. distinguer	imaginer
3. joie	6 un moyen de transport	3. examiner	remarquer
4. phase	2 séparation en deux parties	4. mentionner	détruire par le feu
5. stade		5. rêver	
6. véhicule		6. supprimer	
1. autorisation		1. fondamental	
2. bonjour	erreur	2. global	complet
3. confusion	le besoin de manger	3. moderne	qui est la base
4. faim	la maison de la justice	4. prudent	qui ne prend pas de risques
5. rupture		5. récent	
6. tribunal		6. traditionnel	
1. adapter		1. attaque	
2. crier	partager	2. contribution	institution
3. distribuer	parler très fort	3. dommage	action violente
4. formuler	aller d'un côté à l'autre	4. église	ensemble de pièces
5. procéder		5. incident	
6. traverser		6. mécanisme	
1. bras		1. actif	
2. circuit	tour	2. inutile	occupé
3. détermination	principe et règle	3. fier	qui ne sert à rien
4. match	une partie du corps	4. majeur	qui a un grand pouvoir
5. réception		5. puissant	
6. théorie		6. scolaire	

SCORE

as
practice

2k score
3/30 (10%)

Prob. sets
2 3 4 5 6 7

3k score
0/30 (0%)

Prob. sets
1 2 3 4 5 6

5k score
0/30 (0%)

Prob. sets
1 2 3 4 5 6

10k score
0/30 (0%)

Prob. sets
1 2 3 4 5 6

SET ORDER

1>2

3>4

5>6

7>8

9>10

Typical findings from either test are that ~

- Intermediate learners know $\approx$ 1,000-1,500 lemmas in their L2
- High school graduates know $\approx$ 2,000-3,000 lemmas
- But is this good or bad?
 - Sufficient or insufficient?
 - To do what?

To answer this, we also need a similar *test* for texts

On the same metric as the tests for learners

- A.k.a. a text profile
 - How many words at each k-level does this text contain?
 - 'Know' replaced by 'contain'

Text profiling by frequency level

- Also known as LFP and Vocabprofil(e) – “vp”
- For example, this text (893 words) from a Montreal news story
 - “L’abandon scolaire”



Sus à l'abandon scolaire! 200 écoles secondaires partageront 125 millions de dollars en cinq ans Marie-Andrée Chénier Le mardi 14 mai 2013 Pour s'attaquer au problème qu'est l'abandon scolaire, le gouvernement a décidé de réduire de 10 % en cinq ans le budget du ministère de l'Éducation (MEQ) propulse 125 millions de dollars en cinq ans dans une opération de 200 écoles secondaires. Agir autrement, c'est le but de l'opération lancée par le ministre de l'Éducation, Sylvain Simard, inspirée du droit d'un projet-pilote du même nom, qui n'a pas été livré ses premiers fruits. L'intervention ne concerne toutefois pas de la même enveloppe qu'ont obtenu les écoles secondaires l'année dernière. L'expérimentation: chacune a

mais je ne pense pas qu'on le mettre ce que le is.» Est-il trop tôt que pilote n'a pas sa première aucun résultat disponible? onmes pas encore lire avec précision impacts du mais nous en pour dire que importante, et le ble», notait on, sous-ministre seignement secondaire, le suivi de ces serré. Et on de fonds? «Ce ment une gent», ajoute M Bisailon. «Je souhaiterais que

Profile summary		
K	#tokens	cumul%
K-1	816	85.2
K-2	66	92.1
K-3	36	95.9
K-4	11	97.0
K-5	6	97.6
K-6	1	97.7
K-7	2	97.9
K-8	2	98.1
K-10	4	98.5
K-11	2	98.7
K-12	2	98.9
K-13	2	99.1
K-14	1	99.2
K-17	1	99.3
K-18	1	99.4
K-20	1	99.5
K-24	1	99.6
OFF	3	≈100

Colour-coded k-levels

Profile summary		
K, #tokens, cumul%		
K-1	816	85.2
K-2	66	92.1
K-3	36	95.9
K-4	11	97.0
K-5	6	97.6
K-6	1	97.7
K-7	2	97.9
K-8	2	98.1
K-10	4	98.5
K-11	2	98.7
K-12	2	98.9
K-13	2	99.1
K-14	1	99.2
K-17	1	99.3
K-18	1	99.4
K-20	1	99.5
K-24	1	99.6
OFF	3	≈100



sus à le **abandon scolaire** chiffre écoles **secondaires**
se partageront chiffre millions en cinq ans
marie andrée chouinard
le mardi chiffre mai chiffre
pour se **attaquer** au **fléau** que est le **abandon scolaire**
et le réduire de chiffre en dix ans le ministère de le
éducation meq **propulse** chiffre millions en cinq ans
dans un **concentré** de chiffre écoles **secondaires** agir
autrement ce est le nom de le opération lancée hier
par le ministre de le éducation sylvain simard **inspirée**
tout droit de un projet **pilote** du même nom qui ne a
pas encore **livré** ses premiers résultats le intervention
ne **bénéficiera** toutefois pas de la **généreuse**
enveloppe que ont reçue les six écoles **secondaires**
ciblées par le **expérimentation** chacune a reçu chiffre
chiffre million pour des mesures **échelonnées** sur
trois ans tandis que les chiffre écoles **ciblées** par
québec se **disputeront** chiffre millions par an
distribués selon le bon vouloir de leurs commissions
scolaires respectives pour permettre cette annonce la
directrice de le école **secondaire** Édouard montpetit
lucie lalande ouvrait sa porte au ministre sylvain
simard hier depuis presque un an son école est sous
la **lorgnette** du meq parce que elle fait partie du projet
agir **autrement** coups de **centaines de milliers** de
dollars les résultats sont déjà **palpables** affirme elle

Compare previous profile to this one ~

- Hier Daisy s'était levée tôt ce matin de printemps. Elle travaillait sur une affaire dans la ville voisine. Elle arriva à son bureau à huit heures avec à la main un sac en papier contenant des petits pains. Elle mourrait d'envie d'une tasse de café.

Note – Demo only; short texts = unreliable VP

Profile summary		
K, #tokens, cumul%		
K-1	42	87.5
K-2	3	93.7
K-3	2	97.9
K-6	1	100.0
OFF	0	≈100

hier daisy se était levée tôt ce matin de printemps elle travaillait sur une affaire dans la ville voisine elle arriva à son bureau à huit heures avec à la main un sac en papier contenant des petits pains elle mourrait de envie de une tasse de café

Profiles are somewhat different !→

But without these instruments, would we have noticed how much?

To read Daisy with 95% word knowledge, 2000 word families should be know

To read Abandon Scolaire with 95% word knowledge, 3000 word families should be know

Daisy le matin

Profile summary		
K, #tokens, cumul%		
K-1	42	87.5
K-2	3	93.7
K-3	2	97.9
K-6	1	100.0
OFF	0	≈100

L'abandon scolaire

Profile summary		
K, #tokens, cumul%		
K-1	816	85.2
K-2	66	92.1
K-3	36	95.9
K-4	11	97.0
K-5	6	97.6
K-6	1	97.7
K-7	2	97.9
K-8	2	98.1
K-10	4	98.5
K-11	2	98.7
K-12	2	98.9
K-13	2	99.1
K-14	1	99.2
K-17	1	99.3
K-18	1	99.4
K-20	1	99.5
K-24	1	99.6
OFF	3	≈100

These tests and measures let us compare/contrast profiles of learners & profiles of texts

And determine the quality of the match

- Empirical research has shown
 - Ss need to know 95% of the words on a page to read with basic comprehension
 - **> 95%** of words known = fluent reading for comprehension
 - **85-95%** = intensive reading
 - Many look-ups, comprehension gaps, unresolved passages
 - **< 85%** = unuseful experience
 - (zone where much of school reading lies, in L1 but especially L2)

With these tools we can begin Data-Driven Course/Curriculum design (DDCD)

Start with the raw materials of a course

- E.g., A “reading course” with a set of texts drawn as “interesting” from Internet news

Step 1 – get all course materials into digital form as a corpus

- In two formats:
 1. Separate chapters, texts or units (ideally ‘zipped’)
 2. One large single file
- What will this enable us to do?

What would course-as-corpus let us do?

Find out

1. Whether our course level is anywhere near our learners' level
2. If not, what would bring it nearer?
 1. Learners up, texts down?
3. What if anything can legitimately be tested from this course?

* Level in this case refers to lexis but could be other aspects

Here is the course-corpus described in one course I re-designed

ESL Adult Reading, 14 units,

- >7000 words,
- in-house course,
- intermediate adults
- high stakes

→ Simple 'flat' corpus

- 2 formats
 - Separate files
 - A combined file



Camouflage pants.txt	4 KB	Text Document	2020-01-27 4:36 PM
Certification Prep.txt	8 KB	Text Document	2020-01-27 4:37 PM
Charity.txt	2 KB	Text Document	2020-01-27 4:45 PM
Child Labour.txt	2 KB	Text Document	2020-01-27 4:42 PM
Importance of English.txt	8 KB	Text Document	2020-01-27 4:39 PM
Muhammad Yunus.txt	2 KB	Text Document	2020-01-27 4:33 PM
Music Couple.txt	4 KB	Text Document	2020-01-27 4:40 PM
Polling station.txt	2 KB	Text Document	2020-01-27 4:41 PM
Protest or threat.txt	3 KB	Text Document	2020-01-27 4:38 PM
Social Media Booklet.txt	4 KB	Text Document	2020-01-27 4:34 PM
Understanding Poverty....	2 KB	Text Document	2020-01-27 4:35 PM
Unprepared voters.txt	2 KB	Text Document	2020-01-27 4:44 PM
Women and Vote.txt	3 KB	Text Document	2020-01-27 4:43 PM
Your Clothes.txt	5 KB	Text Document	2020-01-27 4:36 PM
ZZ_CORPUS_7198wds.txt	43 KB	Text Document	2020-01-29 2:16 PM

Now a new course For FL2 learners in Sweden

Le Petit Nicolas

(Sempé and Goscinny, c. 1959)



- 18 children's stories
- Similar lengths
- No passé simple/historique
- 28,000 words ($\approx$ 1500 per story)

= a plausible French reading course for
9-year-olds

Name	Date modified	Size	Type
01_souvenir_cherir.txt	2022-09-01 5:29 PM	8 KB	TXT File
02_cow-boys.txt	2022-09-01 5:30 PM	8 KB	TXT File
03_le_bouillon.txt	2022-09-01 5:30 PM	8 KB	TXT File
04_le_football.txt	2022-09-01 5:31 PM	8 KB	TXT File
05_l'inspecteur.txt	2022-09-01 5:31 PM	8 KB	TXT File
06_rex.txt	2022-09-01 5:32 PM	8 KB	TXT File
07_djodjo.txt	2022-09-01 5:32 PM	8 KB	TXT File
08_chouette_bouquet.txt	2022-09-01 5:32 PM	8 KB	TXT File
09_les_carnets.txt	2022-09-01 5:32 PM	8 KB	TXT File
10_louissette.txt	2022-09-01 5:33 PM	14 KB	TXT File
11_je_fume.txt	2022-09-02 11:39 AM	8 KB	TXT File
12_le_petit_poucet.txt	2022-09-01 5:34 PM	8 KB	TXT File
13_le_velo.txt	2022-09-02 11:39 AM	8 KB	TXT File
14_suis_malade.txt	2022-09-01 5:34 PM	8 KB	TXT File
15_bien_rigole.txt	2022-09-01 5:34 PM	7 KB	TXT File
16_frequent_agnan.txt	2022-09-01 5:34 PM	9 KB	TXT File
17_pas_le_soleil.txt	2022-09-02 10:37 AM	8 KB	TXT File
18_quitte_la_maison.txt	2022-09-02 12:01 PM	8 KB	TXT File
Pet_Nic_18.zip	2022-09-02 12:02 PM	61 KB	ZIP File
PN_original_30k.txt	2022-09-05 9:53 AM	136 KB	TXT File

Petit Nicolas (tout) - lexical frequency profile

[Home](#) > [VocabProfilers](#) > [VP-Compleat Input](#) > [Output](#) ('Back' preserves inputs) **FRAMEWORK IS fr_5**

Freq. Level	Flemmas (%)	Types (%)	Tokens (%)	Cumul. token (%)
K-1 :	2451 (72.4)	2651 (65.98)	23531 (86.3)	86.3
K-2 :	248 (7.3)	454 (11.30)	1420 (5.2)	91.5
K-3 :	157 (4.6)	256 (6.37)	660 (2.4)	93.9
K-4 :	110 (3.2)	152 (3.78)	354 (1.3)	95.2
Coverage 95 				
K-5 :	83 (2.5)	111 (2.76)	263 (1.0)	96.2
K-6 :	92 (2.7)	122 (3.04)	274 (1.0)	97.2
K-7 :	36 (1.1)	52 (1.29)	150 (0.5)	97.7
K-8 :	33 (1.0)	39 (0.97)	93 (0.3)	98.0
Coverage 98				
K-9 :	26 (0.8)	29 (0.72)	72 (0.3)	98.3

Result

95% lexical coverage is reached only when 4,000 lemmas are known

Knowing 1,000=86.3% coverage

Knowing 2,000=91.5% coverage

How many French words do Swedish 9-yr-old learners know? Probably < 1,000

So these texts probably correspond to learners' interests but...

- Will be challenging for some/most of them
 - (This could only be established through testing)
 - So here is a prima facie test case for Data-Driven Course Design
- How can DDL help make this text accessible?

Simplest, DDL can just give us the specific 2k-3k words to teach

- Whether Pre-Teach or emphasize and invite discussion when encountered
- Teacher would choose based on frequency, cognate-ness
- For the whole book or specific story/stories
 - (Next slide is for whole book)

French v.5 -K2 Flemmas: [flems 248 : types 454 : tokens 1420]

VP-negative: fr_5-2

absolument_[3] accompagner_[3] acteur_[1] agent_[5] anglais_[1] animal_[3] apercevoir_[4] appareil_[2]
approcher_[7] arbre_[7] arrière_[1] assister_[1] attacher_[3] attaquer_[2] avion_[15] baisser_[1] balle_[15]

ba

French v.5 -K3 Flemmas: [flems 157 : types 256 : tokens 660]

cal

cie

coi

coi

de

du

es

fin

ga

inc

joli

ma

mé

pa

pla

pro

rec

re

rol

se

sui

traduire_['

voisin_[4]

VP-negative: fr_5-3

agiter_[7] allumer_[1] amuser_[32] animer_[1] anniversaire_[3] arracher_[1] arranger_[6] bouteille_[8]
boîte_[6] brillant_[2] briller_[4] bête_[7] cadeau_[5] calmer_[1] camarade_[13] capitaine_[7] chaise_[3]

chape

corrig

dent_

douce

embr

feuille

gloire

inspe

malhe

crâne_[1]

dicter_[1]

déboucher_[1]

débrouiller_[2]

déchirer_[3]

dégât_[1]

délivrer_[1]

dépêcher_[1]

désespérer_[2]

désordre_[1]

détacher_[1]

French v.5 -K4 Flemmas: [flems 110 : types 152 : tokens 354]

VP-negative: fr_5-4

accueil_[1] affreux_[1] alcool_[2] amateur_[1] applaudir_[1] attraper_[1] auto_[21] avaler_[1]
avertissement_[1] bain_[6] ballon_[8] banc_[13] blague_[4] bouton_[2] bravo_[2] brutal_[3] bâton_[1]
cahier_[1] canon_[1] caresser_[2] chant_[1] charmant_[1] chasseur_[3] chemise_[10] chimie_[1] château_[1]
chèque_[1] coincer_[1] col_[1] combiner_[2] consoler_[2] corde_[2] correctement_[1] costume_[5] cou_[1]
crâne_[1] dicter_[1] déboucher_[1] débrouiller_[2] déchirer_[3] dégât_[1] délivrer_[1] dépêcher_[1]
désespérer_[2] désordre_[1] détacher_[1] essuyer_[6] fantôme_[2] ficher_[1] fréquent_[2] fréquenter_[2]
fusil_[1] fêter_[1] gendarme_[3] gorge_[1] goûter_[9] guérir_[2] habiller_[14] herbe_[3] hurler_[2] jouet_[12]
joyeux_[1] lampe_[2] laver_[3] liquide_[2] lunette_[24] maigre_[1] mairie_[1] manche_[2] miroir_[1] mordre_[8]
méfier_[4] métal_[1] nerveux_[7] nettoyer_[1] os_[1] pantalon_[4] patte_[2] peindre_[1] pendre_[2]
photographe_[15] photographie_[1] piquer_[1] planche_[3] plume_[3] poing_[19] poitrine_[2] pot_[2]
proclamer_[1] punir_[6] pâle_[1] queue_[4] rage_[1] rattraper_[4] rembourser_[1] ressort_[1] sourd_[2]
stupide_[1] sympathie_[1] tache_[3] tante_[5] taper_[15] thé_[3] transparent_[1] vitre_[1] voleur_[5] élan_[1]
élémentaire_[1]

voisin_[4] voler_[2] voyage_[1] zero_[1] ecarter_[1] echnapper_[1] eclater_[1] éloigner_[1] étonner_[12]

A way to find the most important words Ss must know across a set of texts is with the DDL tool RANGE

- Gives the frequency of each word or lemma in a set of texts
 - Plus the number of texts each features in
- Can boil the lexis down to the frequent PLUS recurring items

Range for Texts v.5.3

Estimated Capacity 8 novels x 125k wds = 1,000,000 wds(/40 secs)

Upload up to 25 text files (chapters of a book, works of an author, frequency lists) and then: (1) find the frequency of each word in the *range* of each across texts (e.g., is in 6 out of 9 texts), (3) build a Frequency x Range word list for the collection [?]

[[Sample Output + Filter Demo](#)]

UPDATE JUNE 2022 - le français de retour!

Tryout ZIPs > ENG Jack London's *Call of the Wild* [Ungraded](#) or [Graded](#) + *FRENCH* de Maupassant's *Boule de Suif* and Camus

(1) Save input files As TEXT FILES with *.txt extension [?] + encoded ANSI if French [?]

(2) To upload as separate files, choose number of files - Or combine as a single *.zip file [?]

(3) Choose unit ☒ Families (lemmas if Fr.) ||| ☐ Types

(4) If families/lemmas, choose VP-Frame ☐ BNC-Coca ||| ☐ BNC ||| ☒ French Fr_5

(5) Choose stoplists if desired [?] Function Words: ☐ English [See] ||| ☒ French [See] ||| ☐ None or ☒ French 1k]

(6) Get files with ↓ "Choose Files" or → *

(7) or

See [bottom](#) for filenames, stoplists, offlist, profile, output filtering (freq x range), & Excel-copiable version ofTITLE: Pet_Nic_18.zip Post-Analysis=>

VP (token coverage)

Range Profile

Loading...

Click headings to sort  (In the table, **T1(25)** means text T1 has 25 occurrences of the word, etc)

000.

Fams

Freq

Range

VP

T1

T2

T3

032.	papa	172	16	2	T1(2)	T2(16)	
036.	maman	154	13	2		T2(5)	
041.	maître	118	12	1	T1(27)		T3(8)
061.	crier	80	16	2	T1(6)	T2(4)	T3(10)
075.	répondre	50	17	1	T1(3)	T2(2)	T3(4)
082.	école	46	15	1	T1(2)		T3(2)
084.	pleurer	44	17	2	T1(2)	T2(1)	T3(6)
088.	fleur	42	2	2			
092.	vélo	40	3	5			
093.	bouillon	39	3	11			T3(32)
095.	rex	39	1	10			
100.	chouette	36	17	7		T2(5)	T3(1)
103.	copain	35	18	3	T1(3)	T2(2)	T3(1)
110.	rigoler	33	13	5	T1(1)	T2(4)	T3(1)
111.	drôlement	32	15	7	T1(3)	T2(1)	T3(2)
115.	inspecteur	30	2	3			
116.	tête	30	12	1	T1(3)	T2(5)	
118.	amuser	29	13	3		T2(4)	
122.	courir	28	13	2	T1(1)	T2(2)	
129.	idée	26	13	1	T1(1)	T2(2)	T3(1)

Offlist

75 OFF-LIST TYPES WITH NO FAMILY HEADER

ac agnan alceste aon arcachon australie blédurt bordenave bouil boxing bril
cyrille dgeorges dinguedingue dissipez djoachim djodjo dubon dég elvire eude

OUTPUT FILTER

Extract data by Frequency >= and Range >=

Format: [☒ As above ☐ Words only]

Go »

Build Frequency- and Range-based word lists; check corpus



These are the key words across these stories –

List can be expanded or shortened by changing the parameters

	FAM	FREQ	RANGE	V
035.	maman	154	13	2
040.	maître	118	12	1
060.	crier	80	16	2
074.	répondre	50	17	1
081.	école	46	15	1
083.	pleurer	44	17	2
099.	chouette	36	17	7
102.	copain	35	18	3
109.	rigoler	33	13	5
110.	drôlement	32	15	7
115.	tête	30	12	1
117.	amuser	29	13	3
121.	courir	28	13	2
128.	idée	26	13	1
135.	chocolat	24	12	5
151.	arrêter	21	11	1
164.	rouge	19	10	2
165.	terrible	19	11	2
168.	embêter	18	11	6
175.	gentil	17	10	3
187.	sûr	16	13	1
196.	côté	15	10	1
197.	drôle	15	10	2
204.	taper	15	11	4

Once the key words' identities are known...

- Flash Cards are back in style with shiny new credentials



Personally I would have Ss go through lists and check out *all the words* at the next level that they don't already know

Browser tabs: Nya MSN Sverige | Nyheter, Nöje | LIST_LEARN *FR_5* - Resourced L | +

Address bar: lextutor.ca/list_learn/fr_10/

Home > List_Learn > French > L-L FR_5(1-10)

Default Corpus: Le Monde 1m

Default Dictionary: Fren_Eng

[1.] Choose k-list: fr_5_heads(03).txt

abandon
abattre
abri
absent
absurde
accent
acceptable
accrocher
accroissement
accumuler
accusation
accusé
accéder
accélérer
acheminement
acheminer
actionnaire
actualité
adaptation
adhésion
adjoint
admirer
adolescent
adversaire
affaiblissement
affrontement
affronter
agiter
agression
aliment

Concordance for (f)lemma **accrocher** in Fr_le_monde.txt

Dictionnaire/TTS Fren_Eng

002. ☐ hanson figurant sur l'album manque de l'**ACCROCHE** décisive qui fait les grands tu
003. ☐ ée national d'art moderne (MNAM), qui l'**ACCROCHE** à ses cimes en 1976 et l'ach
004. ☐ soucis. Aucun grand débat de société n'**ACCROCHE** réellement leur attention hormi
005. ☐ ans foi ni loi. Pourtant quelques-uns s'**ACCROCHENT** pour sauver ce qui peut enco
006. ☐ tête, ou font sauter les barres et leur **ACCROCHENT** de désolants postiches. Quelc
007. ☐ aire pour enrayer la désertification, s'**ACCROCHENT** à ce barrage comme à une boué
008. ☒ éclipsé. Il faut quelques minutes pour **ACCROCHER** à la démonstration et replonge
009. ☐ nd de l'autre côté. Chacun est prêt à s'**ACCROCHER** à des idées rassurantes, y con
010. ☐ cimes en 1996 et se lance un défi fou : **ACCROCHER** à son palmarès les quatorze sc
011. ☐ fiables auxquelles le spectateur peut s'**ACCROCHER**, faute de personnages cohérent
012. ☐ ainsi le Concertium a toute liberté d'**ACCROCHER** un nouveau montant les mérites

Send words to...
Dictator Multiconc
ID-words
accrocher
Highlight Empty

[7.] Save your corpus findings here
Build a Dictionary of Words, Examples, Meanings (with one click from bottom of Larger Context above).
Copy-Paste to an Excel sheet to start building a dictionary of words at your growth-edge.

ACCROCHER POS: VERBE EX: Il faut quelques minutes pour ACCROCHER à la démonstration et replonger dans le dossier.
DEF: fasten to, hook up to (fig.)

[6.] When finished a session, Highlight then copy-paste to Excel on own computer

WordReference.com

Recherche Français-Anglais

accrocher

ECOUTER: FRANCE [akʁɔʃe]

WordReference Collins WR Reverse (47)

WordReference English-French Dictionary © 2022:

Principales traductions

Français	Anglais
accrocher (suspendre) [qch] ⇒ vtr	hang ⇒ vtr
	hang [sth] adv
J'accroche les clés au porte-clés q rentre chez moi. I hang my keys on the key rack wh home.	
accrocher [qch] à [qch] vtr + prép	hook [sth] [sth] v exp
	hitch [sth] vtr + prep

Avant de partir, mon père a accro

More student-centered is to set up a Group Lex database & Ss choose their own words to work on

- And share with others
 - Including by mobile phone
- Leading to a complete lexicon of the whole book with quizzes

#	Qz	NOUVEAU MOT	VP	EXEMPLE	CLASSE DE MOT	DEFINITION	GROUPE	ETUDIA...	DATE/H... SOUMIS...
1	☐	apercevoir	2	« La mi-temps de quoi? a demandé Alceste. Je viens de m'apercevoir que nous n'avons pas de ballon, je l'ai oublié à la maison! »	Verbe	skymta, glimt	Pet_Nic_4	tom_ad...	2022.09.06 8.30
2	☐	musique	1	J'écoute de la musique.	Nom	L'art de la combinaison de sons	Arts	LK1234	2014.12.16 9:31
3	☐	couple	2	Il vit en couple avec Marie.	Nom	deux personnes liées par des sentiments	Economics	LK1234	2014.12.16 11:38
4	☐	couple	2	Seulement un couple sur trois désormais se marie à l'église.	Nom	deux personnes liées par un sentiment	Economics	123French	2014.12.16 11:32
5	☐	pris	1	Elle a pris sa douche antérieurement	Verbe	took (prendre)	Arts	00christi...	2014.09.08 9.35
6	☐	pomme	4	La pomme de pin n'est pas un vrai pomme	Nom	Apple	Arts	tom_ad...	2014.09.08 9.33
7	☐	montre	1	Que dit ta montre?	Nom	(wrist) watch - so 'What time is it?'	Arts	tom_ad...	2014.09.08 9.28
8	☐	nombreux	1	On est demandé de venir 'nombreux' à leur événement	Nom	in large numbers	Arts	tom_ad...	2014.09.08 9.24
9	☐	salut	2	Dis Salut	Nom	Hello	Arts	tom_ad...	2014.09.08 22:34
10	☐	sourire	1	Donne-moi ta sourire	Nom	A smile	Arts	tom_ad...	2014.09.08 22.23

Ceci sera votre entrée :

#	Qz	NOUVEAU MOT	VP	EXEMPLE	CLASSE DE MOT	DÉFINITION	GROUPE	ÉTUDIANT	DATE/HEURE
00	☐	apercevoir		« La mi-temps de quoi? a demandé Alceste. Je viens de m' apercevoir que nous n'avons pas de ballon, je l'ai oublié à la maison! »	V	skymta, glimt	Pet_Nicolas_4	tom_admin	2022.09.06 04.23

< Retour

Sécurité : Taper les chiffres pour trois, deux, un

Valider >

V.Mobile
pad/phone

v. English

COMPUTER
Voir les
53 mots

Ajout. mot

Aj. étudiant

Modif. mot

Besoin de Gp
Lx?

X-tract-liste

Recherche?

Prononcer la
sélection

xxx

Group Lex M

ADD ENTRY

Name

Start typing...

Group

New Word: Max

20

Example: Max

300

Word class

Meaning: Max

300

Add to Group Lex Now >

Telekom.de

11:03 AM

Group Lex M

<

«DEMO»

WORD	Example	POS	Meaning	GROUP
1 apercevoir	« La mi-temps de quoi? a demandé Alceste. Je viens de m'apercevoir que nous n'avons pas de ballon, je l'ai oublié à la maison! »	V	skymta, glimt	Pet_Nico...
2 trip	We went to London on a school trip	N	A short journey for a specific purpose	Arts
3 journey	The journey started at 8	N	When you travel from one place to another	Arts
7 pollution	La pollution atmosphérique tue 5, 5 millions de personnes par an dans le monde (dont 2, 6 millions de décès indirects) selon des chiffres 2016	N	Dégradation de l'environnement par des substances (naturelles, chimiques ou radioactives), des déchets (ménagers ou industriels)	Comm
11	Tan solo en los últimos 13 años, la deforestación ha	N	f. Acción y efecto de deforestar.	Ecología

Check

Questions: 10

Correct: 0

Tries: 0

Percent: 0

History >>

Practice

In-Class

	NEW WORD	EXAMPLE	WORD CLASS	DEF
1		Rousseau's fundamental idea was the _____ of nature and culture.	N	A division or contrast between two things that are or are represented as being different.
2		The word 'flight' has two different _____: a plane journey, and the act of running away.	N	The _____ of something represents
3		He was an _____ person	ADJ	requiring a great deal of
4		House prices have been _____ for months.	ADJ	not moving, or not changing
5		He This was an _____ person	N	eagerly desirous of wealth, a specific goal
6		Gp Lex also works on _____ though with reduced functionality	N	Easily moveable
7		Aerial _____ of the enemy position showed they were ready to attack.	ADJ	Information gathering
8		The _____ sends a beacon signal to the ground indicating how urgent it is to track the spacecraft	N	a vehicle used for tracking

ambitious
ambitious
asteroid
dichotomy
meaning
mobile
reconnaissance
spacecraft
stationary

	NEW WORD	EXAMPLE	WORD CLASS	DEF
1		He This was an _____ person project.	ADJ	requiring a great deal of
2		He was an _____ person	N	eagerly desirous of wealth, a specific goal
3		Aerial _____ of the enemy position showed they were ready to attack.	ADJ	Information gathering
4		The _____ sends a beacon signal to the ground indicating how urgent it is to track the spacecraft for telemetry.	N	a vehicle used for tracking
5		Gp Lex also works on _____ though with reduced functionality	N	Easily moveable
6		Scientists are hoping an _____ will clue them in about early life on earth.	N	one of many large molecules
7		House prices have been _____ for months.	ADJ	not moving, or not changing
8		Rousseau's fundamental idea was the _____ of nature and culture.	N	A division or contrast between two things that are or are represented as being different.
9		The word 'flight' has two different _____s: a plane journey, and the act of running away.	N	The _____ of something represents
10		We are collecting English one _____ after another	N	字

MORE PRINCIPLED HOWEVER – is to use DDL tools to sequence the 18 stories from basic to more complex vocab

- To facilitate the conditions whereby learning by inference can take place
 - IE, > 90% knowledge of words in the context
 - Or as many as possible

These texts...

- Written for NS French kids, these are unlikely to be sequenced at all
- To get a sequence, we return to VP
- And analyse the texts individually, recording each of the 18 profiles
- Then with Excel we sort by the percentage of 1k items
 - *Should* give us a sequence of texts from most-basic to least-basic lexis
 - At least, this is what happened in English
 - Same in French?

K-1 :	305 (73.3)	354 (72.69)	1309 (86.2)	86.2
K-2 :	38 (9.1)	48 (9.86)	75 (4.9)	91.1
K-3 :	18 (4.3)	21 (4.31)	28 (1.8)	92.9
K-4 :	21 (5.0)	23 (4.72)	45 (3.0)	95.9
Coverage 95 				
K-5 :	9 (2.2)	10 (2.05)	13 (0.9)	96.8
K-6 :	4 (1.0)	4 (0.82)	4 (0.3)	97.1
K-7 :	3 (0.7)	3 (0.62)	5 (0.3)	97.4
K-8 :	2 (0.5)	2 (0.41)	2 (0.1)	97.5
K-9 :	3 (0.7)	3 (0.62)	5 (0.3)	97.8
Coverage 98				
K-10 :	1 (0.2)	1 (0.21)	3 (0.2)	98.0
K-11 :	4 (1.0)	4 (0.82)	5 (0.3)	98.3
K-12 :	2 (0.5)	2 (0.41)	5 (0.3)	98.6
K-13 :	1 (0.2)	1 (0.21)	1 (0.1)	98.7
K-14 :	2 (0.5)	2 (0.41)	8 (0.5)	99.2
K-15 :				
K-16 :				
K-17 :				
K-18 :				
K-19 :				
K-20 :	1 (0.2)	1 (0.21)	1 (0.1)	99.3
K-21 :				
K-22 :	1 (0.2)	1 (0.21)	1 (0.1)	99.4
K-23 :				
K-24 :				
K-25 :	1 (0.2)	1 (0.21)	1 (0.1)	99.5
Off-List:	??	6 (1.23)	7 (0.46)	99.96
Total (unrounded)	416+?	487 (100)	1518 (100)	≈100.00

Words in text (tokens):	1518
Different words (types):	487
Type-token ratio (TTR):	0.32
Tokens per type:	3.12
Pertaining to onlist only	
Tokens:	1511
Types:	481
Flemmas:	416
Tokens per Flemma :	3.63
Flemma/token ratio (FTR) :	0.28
Types per Flemma :	1.16
Singletons ratio	
Fams(n=1)[121] / total [416]	0.29

aste to Excel sheet to record comparative coverages. To compare several texts, track learner writing over time, sequence texts by lexis (TIP, sort spreadsheet by K-1% to get more basic lexis first), etc. Note th FL7, etc.)

K-1	86.2	K-2	91.1	K-3	92.9	K-4	95.9	K-5	96.8	K-6	97.1	K-7	97.4	K-8	97.5	K-9	97.8	K-10	98.0
-----	------	-----	------	-----	------	-----	------	-----	------	-----	------	-----	------	-----	------	-----	------	------	------

So 18 profiles assembled
ready for sorting by Column 'C'
- Order texts by the proportion of 1k

[illegible]

Giving us this...

Hmm, this is less useful than expected

1k-Range is only 6 percentage points over 18 stories – is it worth the trouble?

Or do we need to know something about French to make this work

[illegible]

This is where some facts about French lexical distributions is useful

- Fact: Cobb and Horst (2004)
 - But why? Because of the greater number of non-optional function words?
 - Example
 - “Nicolas brought a ball” (1 function word, *a*)
 - “Nicolas a aporté un ballon” (2 function words, *a* and *un*)
- So maybe try some other Excel sorts that group the texts differently?
 - Say, by the k-levels at which 95% coverage is achieved?

So sort by Columns I, then L, then O...

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V
1	LE PETIT NICOLAS																					
2	AS PUBLISHED																					
3	1 SOUVENIR CHERIR	K-1	86.2		K-2	91.1		K-3	92.9		K-4	<u>95.9</u>		K-5	96.8		K-6	97.1		K-7	97.4	
4	10 LOUISETTE	K-1	87.5		K-2	93.4		K-3	<u>95.3</u>		K-4	96.3		K-5	97.0		K-6	97.7		K-7	<u>98.1</u>	
5	11 JE_FUME	K-1	85.5		K-2	89.5		K-3	93.1		K-4	93.8		K-5	94.8		K-6	<u>97.0</u>		K-7	97.7	
6	12 PETIT_POU CET	K-1	86.7		K-2	90.2		K-3	93.7		K-4	94.9		K-5	<u>95.3</u>		K-6	96.6		K-7	96.9	
7	13 VELO	K-1	84.7		K-2	92.1		K-3	93.7		K-4	94.1		K-5	<u>96.8</u>		K-6	97.6		K-7	97.9	
8	14 MALADE	K-1	85.5		K-2	90.4		K-3	93.8		K-4	<u>95.0</u>		K-5	97.1		K-6	<u>98.0</u>		K-7	98.6	
9	15 BIEN_RIGOLE	K-1	88.2		K-2	92.3		K-3	94.4		K-4	94.9		K-5	<u>95.9</u>		K-6	96.4		K-7	96.9	
10	16 FREQUENTE_AGNEN	K-1	85.9		K-2	90.7		K-3	93.1		K-4	<u>95.6</u>		K-5	96.6		K-6	97.4		K-7	<u>98.1</u>	
11	17 PAS_DE_SOLEIL	K-1	86.4		K-2	90.8		K-3	92.8		K-4	93.9		K-5	94.7		K-6	<u>96.5</u>		K-7	97.1	
12	18 QUITTE_MAI SON	K-1	88.2		K-2	92.8		K-3	94.8		K-4	<u>96.3</u>		K-5	97.1		K-6	97.9		K-7	<u>98.4</u>	
13	2 COWBOYS	K-1	83.0		K-2	89.6		K-3	91.1		K-4	93.0		K-5	94.3		K-6	<u>95.0</u>		K-7	96.4	
14	3 BOUILLON	K-1	88.2		K-2	92.4		K-3	94.2		K-4	94.9		K-5	<u>95.7</u>		K-6	96.5		K-7	96.8	
15	4 FOOTBALL	K-1	86.4		K-2	92.6		K-3	<u>95.4</u>		K-4	97.1		K-5	97.9		K-6	<u>99.2</u>		K-7	99.3	
16	5 INSPECTEUR	K-1	87.1		K-2	91.1		K-3	94.4		K-4	<u>96.0</u>		K-5	96.5		K-6	97.8		K-7	<u>98.4</u>	
17	6 REX	K-1	82.6		K-2	90.6		K-3	92.6		K-4	93.7		K-5	93.9		K-6	94.6		K-7	<u>95.3</u>	
18	7 DJODJO	K-1	87.0		K-2	91.0		K-3	94.2		K-4	<u>95.1</u>		K-5	95.6		K-6	96.0		K-7	96.7	
19	8 CHOUETTE_BOUQUET	K-1	86.4		K-2	92.3		K-3	94.8		K-4	<u>95.7</u>		K-5	96.6		K-6	<u>98.2</u>		K-7	98.8	
20	9 CARNET	K-1	88.6		K-2	93.8		K-3	<u>95.1</u>		K-4	95.5		K-5	97.6		K-6	<u>98.4</u>		K-7	98.7	
21																						

43	
44	LE PETIT NICOLAS
45	SORTED BY 5%
46	4 FOOTBALL
47	10 LOUISETTE
48	9 CARNET
49	18 QUITTE_M
50	5 INSPECTEUR
51	1 SOUVENIR CHER
52	8 CHOUETTE
53	16 FREQUENT
54	7 DJODJO
55	14 MALADE
56	13 VELO
57	15 BIEN_RIGOLE
58	3 BOUILLON
59	12 PETIT_POUCET
60	11 JE_FUM
61	17 PAS_DE_SOLEIL
62	2 COWBOYS
63	6 REX
64	

K-3	<u>95.4</u>	K-4	97.1	K-5	97.9	K-6	<u>99.2</u>
K-3	<u>95.3</u>	K-4	96.3	K-5	97.0	K-6	97.7
K-3	<u>95.1</u>	K-4	95.5	K-5	97.6	K-6	<u>98.4</u>
K-3	94.8	K-4	<u>96.3</u>	K-5	97.1	K-6	97.9
K-3	94.7	K-4	<u>96.0</u>	K-5	96.5	K-6	97.8
K-3	92.9	K-4	<u>95.9</u>	K-5	96.8	K-6	97.1
K-3	94.8	K-4	<u>95.7</u>	K-5	96.6	K-6	<u>98.2</u>
K-3	93.1	K-4	<u>95.6</u>	K-5	96.6	K-6	97.4
K-3	94.2	K-4	<u>95.1</u>	K-5	95.6	K-6	96.0
K-3	93.8	K-4	<u>95.0</u>	K-5	97.1	K-6	<u>98.0</u>
K-3	93.7	K-4	94.1	K-5	<u>96.8</u>	K-6	97.6
K-3	94.4	K-4	94.9	K-5	<u>95.9</u>	K-6	96.4
K-3	94.2	K-4	94.9	K-5	<u>95.7</u>	K-6	96.5
K-3	93.7	K-4	94.9	K-5	<u>95.3</u>	K-6	96.6
K-3	93.1	K-4	93.8	K-5	94.8	K-6	<u>97.0</u>
K-3	92.8	K-4	93.9	K-5	94.7	K-6	<u>96.5</u>
K-3	91.1	K-4	93.0	K-5	94.3	K-6	<u>95.0</u>
K-3	92.6	K-4	93.7	K-5	93.9	K-6	94.6

This would need empirical evaluation

Ongoing study design:

- Group A reads the stories in published sequence
- Group B reads the stories in the DDL-revised sequence
 - Are there differences in rate, comprehension, enjoyment, lexical development, grammar development?
 - Is there impact on writing (sentence length, accuracy, VP?)

Perhaps the point is made

DDL has a lot to offer in the design of this course

Beyond just 'choosing a good book the learners will like'

- But there are several further piecemeal ways DDL can operate in this course
 - Corpus searches of the stories by teacher to explore and teach features of the stories
 - Is a particular word recurring or one-off?
 - Control of examination lexis
 - (Do questions and rubrics **about** the stories match the language **of** the stories?)
 - If a corpus of teacher-talk is available, are teachers reinforcing the language of the texts in the language of the classroom?
 - Is there reinforcement and recycling of new words?

Concordance for (f)lemma **chouette** in petit_nicolas

Dictionnaire/TTS

Fren_Eng

Extract checked ↓ items: ☒ All | ☐ any10 | 20 | 30 | 50 MODIFY: (f)lemma ▾; chouette Petit Nicolas 130,000 sort ▾ subco ▾ +assoc(s) on L|R ▾ side for 25,000 ▾ li

25 hits

001. ☐ tous pour cette idée qui était vraiment CHOUETTE, mais Alceste n'était pas d'acc 02_cow-boys
002. ☐ le voir; tout le monde criait, c'était CHOUETTE, on rigolait bien, terrible. Et 02_cow-boys
003. ☐ ous on était drôlement contents! Il est CHOUETTE mon papa! Nous avons attaché pa 02_cow-boys
004. ☐ à crier et à faire des grimaces. C'est CHOUETTE de savoir s'amuser tout seul, c 02_cow-boys
005. ☐ t un vieux foulard à ma maman. On était CHOUETTES ! On était dans le jardin et m 02_cow-boys
006. ☐ se faire des passes et c'est drôlement CHOUETTE déjouer entre les bancs. Quand 03_le_boui...
007. ☐ llons faire une partie terrible. Il est CHOUETTE, Alceste. Nous nous sommes retr 04_le_foot...
008. ☐ pas bon! — Ça sent pas bon, mais c'est CHOUETTE à manger, a répondu Alceste. Et 05_1'inspe...
009. ☐ et il est entré dans la maison. Il est CHOUETTE papa! Pendant que papa arrangea 06_rex
010. ☐ s, on a commencé à le trouver drôlement CHOUETTE, Djodjo, et moi, je lui ai donn 07_djodjo
011. ☐ ns le pot-au-feu. Le bouquet était très CHOUETTE et très gros, la dame l'a envel 08_chouett...
012. ☐ s. « C'est vrai, a dit Rufus, c'est pas CHOUETTE ce que vous avez fait aux fleur 08_chouett...
013. ☐ ai commencé à jouer avec Eudes et c'est CHOUETTE de jouer aux billes avec Eudes, 08_chouett...
014. ☐ CHOUETTE 08_chouett...
015. ☐ e vous voudrez, mais ma maman, elle est CHOUETTE! 08_chouett...
016. ☐ n pensant à tout ça et me racontant des CHOUETTES histoires, j'avais oublié mon 09_les_car...
017. ☐ s le placard et elle a vu mon avion, le CHOUETTE, celui qui a un élastique, qui 10_louiset...
018. ☐ dessert, mais ça ne fait rien, elle est CHOUETTE, Louissette, et quand on sera gr 10_louiset...
019. ☐ urs au ministre. C'est vrai qu'il a des CHOUETTES idées le directeur et ce sera 10_louiset...
020. ☐ de là où il manque une planche. Il est CHOUETTE le terrain vague, nous y allons 11_je fume

Par contre ~

[Home](#) > [Concordancers](#) > [French Input](#) > [Output](#)

(« [Back](#) keeps original settings)

Copiable extract-link to this data >> [here](#)

Concordance for (f)lemma **apercevoir** in **petit_nicolas**

Dictionnaire/TTS

Fren_Eng

Extract checked ↓ items: ☒ All | ☐ any10 | 20 | 30 | 50

RANGE: apercevoir appears in 2 out of 14 sub-corpora (14.29%)

Click any [KEYWORD](#) for more context + 'Get More' option FEB 2022

3 hits

- 001. ☐ otre vie, c'est raté, parce qu'on s'est **APERÇU** que le photographe n'était plus l 01_souve...
- 002. ☐ quoi? a demandé Alceste. Je viens de m'**APERCEVOIR** que nous n'avons pas de ballo 04_le_fo...
- 003. ☐ amais, comme aujourd'hui, je ne me suis **APERÇU** à quel point notre métier est un 05_l'ins...

Distribution for lemma apercevoir: 01_souvenir_cherir=1 04_le_football=1 05_linspecteur=1 02_cow-bo
05_l'inspecteur=0 06_rex=0 07_djodjo=0 08_chouette_bouquet=0 09_les_carnets=0 10_louisette=0 11_je_fu
13_le_velo=0 16_frequent_agnan=0

RANGE: apercevoir appears in 2 out of 14 sub-corpora (14.29%)

T can go as deep as the Ss' needs, e.g. collocation

Home > Concordancers > French Input > Output (« Back keeps original settings) Copiable extract-link to this data >> h

Concordance for (f)lemma **répondre** in petit_nicolas Dictionnaire/TTS Fren_Eng

Extract checked items: ☒ All | ☐ any10 | 20 | 30 | 50 Go >

RANGE: répondre with que on right side appears in 8 out of 14 sub-corpora (57.14%)

Click any [KEYWORD](#) for more context + 'Get More' option FEB 2022

10 hits

- 001. ☐ plaisir à votre maîtresse? » Nous avons RÉPONDU que oui, parce que nous l'aimons 01_souve...
- 002. ☐ dit de cesser de manger, mais Alceste a RÉPONDU qu'il fallait bien qu'il se nour 01_souve...
- 003. ☐ oachim? » a demandé Clotaire. Joachim a RÉPONDU qu'il ne voyait rien. Alors, Clo 03_le_bo...
- 004. ☐ ce qu'il lui était arrivé et il nous a RÉPONDU qu'il s'était endormi à force de 03_le_bo...
- 005. ☐ mauvais côté du terrain! Moi, je lui ai RÉPONDU que si le soleil ne lui plaisait 04_le_fo...
- 006. ☐ uérir, mais ça fait très mal. Moi, j'ai RÉPONDU à papa que Rex n'était pas malad 06_rex
- 007. ☐ ndé, Eudes. « Je ne peux pas, je lui ai RÉPONDU, il faut que je rentre chez moi 08_choue...
- 008. ☐ re semblant de chanter et Alceste lui a RÉPONDU qu'il ne faisait pas semblant de 10_louis...
- 009. ☐ as du feu? » il m'a demandé, je lui ai RÉPONDU que non. « Ben alors, a dit Alce 11_je_fu...
- 010. ☐ n me ferait mettre en prison. Je lui ai RÉPONDU que j'avais bien envie de lui ta 16_frequ...

E.g., syntax

me > **Concordancers** > **French Input** > **Output** (« Back keeps original settings) Copiable extract-link to this data >> h
Concordance for **chouette** in petit_nicolas Dictionnaire/TTS Fren_Eng

Extract checked items: ☒ All ☐ any10 ☐ 20 ☐ 30 ☐ 50 Go >

MODIFY: equals chouette Petit Nicolas 130,000 sort 1 wd right +assoc(s) on L|R side for 25,000

002. CHOUETTE 08_chouett...
003. llons faire une partie terrible. Il est CHOUETTE Alceste. Nous nous sommes retr 04_le_foot...
004. et il m'a donné sa montre à lui qui est CHOUETTE avec une grande aiguille qui va 13_le_velo
005. de chimie. Il m'a montré et c'est très CHOUETTE. C'est une grosse boîte pleine 16_frequen...
006. s. « C'est vrai, a dit Rufus, c'est pas CHOUETTE ce que vous avez fait aux fleur 08_chouett...
007. s le placard et elle a vu mon avion, le CHOUETTE celui qui a un élastique, qui 10_louiset...
008. ai commencé à jouer avec Eudes et c'est CHOUETTE de jouer aux billes avec Eudes, 08_chouett...
009. à crier et à faire des grimaces. C'est CHOUETTE de savoir s'amuser tout seul, c 02_cow-boys
010. s, on a commencé à le trouver drôlement CHOUETTE Djodjo, et moi, je lui ai donn 07_djodjo
011. se faire des passes et c'est drôlement CHOUETTE déjouer entre les bancs. Quand 03_le_boui...
012. ns le pot-au-feu. Le bouquet était très CHOUETTE et très gros, la dame l'a envel 08_chouett...
013. de, là où il manque une planche. Il est CHOUETTE le terrain vague, nous y allons 11_je_fume
014. dessert, mais ça ne fait rien, elle est CHOUETTE Louissette, et quand on sera gr 10_louiset...
015. tous pour cette idée qui était vraiment CHOUETTE mais Alceste n'était pas d'acc 02_cow-boys
016. ous on était drôlement contents! Il est CHOUETTE mon papa! Nous avons attaché pa 02_cow-boys
017. a distribution des prix et c'était très CHOUETTE même si à la fin ça a un peu r 12_le_peti...
018. le voir; tout le monde criait, c'était CHOUETTE on rigolait bien, terrible. Et 02_cow-boys
019. et il est entré dans la maison. Il est CHOUETTE papa! Pendant que papa arrangea 06_rex
020. pas bon! - Ça sent pas bon, mais c'est CHOUETTE à manger, a répondu Alceste. Et 05_l'inspe...

Plus two uses for Lextutor's Text_Lex_Compare

Text-lexis comparison

- Program determines the words/lemmas ***shared*** between two texts vs. ***unique to one*** text

<u>Unique to old</u> 114 tokens 79 families	Extract	<u>Shared</u> 87 tokens 30 families	Extract	<u>Unique to new</u> 126 tokens 95 families
<u>Freq. first</u> <u>(then alpha).</u>	<u>Same list</u> <u>Alpha first</u>	<u>Freq. first</u> <u>(then alpha).</u>	<u>Same list</u> <u>Alpha first</u>	<u>Freq. first</u> <u>(then alpha).</u>
001. day 7	001. act 1	001. the 17	001. a 6	001. it 8
002. lead 6	002. add 1	002. of 7	002. after 1	002. gildan 7
003. hang 4	003. again 1	003. a 6	003. and 3	003. company 4
004. mp 4	004. alliance 2	004. say 6	004. be 3	004. court 3
005. party 4	005. always 1	005. in 8	005. call 1	005. fruit 3
Footer				68

1. If you can get a corpus of teacher talk for this course...

- Use Text_Lex_Compare to check how much lexis of texts is getting recycled in the classroom
- And if little is recycled, then include re-use/re-cycle practice in TT (teacher training) programs
 - Low transfer is typical →

Text Lex Compare v.4

Research

↓ TEXT COM

- Subtract one text from another; one list from another; a list from a text. (1) Unrelated top
- Find the degree of word repetition of chapters, etc)
- **Researchers** - Find the coverage of
- **Teachers** - See what's new and wh

[Method A] Old or first text here

Alliance MP calls on Day to resign des
Canadian Alliance Leader Stockwell Day
dissent over his leadership Wednesday
unite his caucus, with one MP again cal
Despite Day's claim that he had unanim
plan, Art Hanger emerged from a private

Titles: Old COURSE UNIT

Empty

Count

Home >> INPUTS **Via Back (preserve inputs) || Direct >> Text Lex Output**

New words in second text

↓ **Index-Edit-Area at bottom !**

First text: COURSE UNIT (109 families)

Second text(s): TEACHER TALK (125 families)

FAMILY ANALYSIS

Using the family as unit of comparison means that if cat is in Text 1 and cats in Text 2 then this is considered a repetition of the cat family. Note also that in this routine, "unfamiliar" items revert to classification by type (e.g., repeated proper nouns).

TOKEN Recycling Index: (87 repeated tokens : 213 tokens in new text) = 40.85%**FAMILIES Recycling Index: (30 repeated families : 125 families in new text) = 24.00%***(Token recycling will normally be the most interesting measure of e.g. coverage and hence text comprehensibility, as with V.s.)*

Unique to old		Shared		Unique to new	
114 tokens		87 tokens		126 tokens	
79 families		30 families		95 families	
<u>Freq first</u> (then alpha)		<u>Same list</u> <u>Alpha first</u>		<u>Freq first</u> (then alpha)	
001. day 7	001. act 1	001. the 17	001. a 6	001. it 8	
002. lead 6	002. add 1	002. of 7	002. after 1	002. gildan 7	
003. hang 4	003. again 1	003. a 6	003. and 3	003. company 4	
004. mp 4	004. alliance 2	004. say 6	004. be 3	004. court 3	
005. party 4	005. always 1	005. in 5	005. call 1	005. fruit 3	

2. And finally EXAMS

To write fair examination texts/questions

- Use Text_Lex_Compare to assure that 95% of the words on the test were even ***seen*** in the course

Home > Text Lex Compare

Text Lex Compare

- Subtract one text from another a text.
- Find the degree of word repetition (news articles, book chapters, ...)
- **Researchers** - Find the coverage
- **Teachers** - See what's new and old

[Method A] Old or first text here
Old or first text here - enter text

Home >> INPUTS **Via Back (preserve inputs)** || **Direct >> Text Lex Output**

New words in second text **↓ Index-Edit-Area at bottom ↓**
First text: Call of the Wild, Unadapted, Ch 1 (997 families)
Second text(s): Call of the Wild, Unadapted, Ch 2 (909 families)

FAMILY ANALYSIS
Using the family as unit of comparison means that if *cat* is in Text 1 and *cats* in Text 2 then this is considered a repetition of the *cat* family, i.e. these are equivalent.
Note also that in this routine, "unfamiliar" items revert to classification by type (e.g., repeated proper nouns).

TOKEN Recycling Index: (2559 repeated tokens : 3334 tokens in new text) = 76.75%
FAMILIES Recycling Index: (404 repeated families : 909 families in new text) = 44.44%
(Token recycling will normally be the most interesting measure of e.g. coverage and hence text comprehensibility, as with VPs.)

<u>Unique to old</u> 824 tokens 593 families Freq first	Extract	<u>Shared</u> 2559 tokens 404 families Freq first	Extract	<u>Unique to new</u> 775 tokens 505 families Freq first
<u>Same list</u>		<u>Same list</u>		<u>Same list</u>

Titles: Old

+ Let VP identify words to gloss in an exam

ilers > **VP-Compleat Input** > Output (Use 'Back' to preserve previous inputs) **FRAM**

colleague_[1] communicate_[1] complaint_[2] compromise_[1] conclude_[1] con
congress_[2] consistent_[1] constitute_[1] coordinate_[2] counsel_[2] criticise_[1]
defend_[8] delay_[3] despite_[1] diplomat_[2] disrupt_[2] echo_[1] effective_[1] e
highlight_[1] initial_[2] inquire_[11] intelligence_[4] interfere_[1] internal_[1] interv
meanwhile_[1] obtain_[1] panel_[1] poll_[1] portion_[1] praise_[1] probe_[1] proc
request_[1] respond_[2] response_[2] resume_[1] reverse_[1] scandal_[2] senat
substance_[1] survey_[1] target_[1] task_[1] veteran_[1]

BNC-COCA-K4 Families: [fams 11 : types 11 : tokens 22]

VP-negative: bnc_coca-4

ambassador_[2] chaos_[1] coherent_[1] credible_[1] opt_[1] rocked_[1] senator_
testimony_[10] **undermine_[1]**

BNC-COCA-K5 Families: [fams 14 : types 16 : tokens 20]

VP-negative: bnc_coca-5

aide_[4] amplify_[1] butt_[1] convene_[1] delete_[1] electorate_[1] escalate_[2] f
sway_[1] testify_[3] vicious_[1] withhold_[1]

EXAM QUESTION

Text text text. Text text text
Text text text. Text text text
undermine* text text text
text...

** Undermine – try to secretly
weaken someone's plan or
strategy*

**Or 2% left to inference if
that was part of the course**

And teacher training?

[Home](#) > [Freq Home](#) > [Freq Train](#)

Freq Train v.2

Frequency intuitions trainer - BNC or
BNC-COCA frequency lists

- Teach use of DDCCD tools?
- T-Training AT LEAST should include more needs analysis
- But, even more,
AWARENESS
RAISING in word
frequency
 - Learners feel frequency effects,
NSs do not

Test your Frequency Intuitions: Guess the band for each word
Frequency Scheme : bnc_lists

1	CURRICULUM	☐ 1-2k	☒ 3-5k	☐ 6-10k	☐ 11-15k
2	SPEND	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
3	GRADE	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
4	ZEBRA	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
5	BAGPIPE	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
6	LIKEWISE	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
7	PREVIEW	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
8	LIBERATE	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
9	INTRUSIVE	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k
10	ASSURE	☐ 1-2k	☐ 3-5k	☐ 6-10k	☐ 11-15k

OK

Check

Score:

10%

Tries:

1

Reset

Unframe

So we have seen some pieces of research-supported DDL – that can be put together usefully

LEXTUTOR ROUTINES INVOLVED

- TESTS
- VP / VP-Cloze
- RANGE
- TL_COMPARE
- GROUP LEX

All @ www.lex tutor.ca/ xxx

Many of these ideas are validated

- Boulton & Cobb (2017)
 - DDL for learning
- Cobb Horst & Nicolae (2005)
 - Group Lex
- Laufer & Ravenhorst (2010)
 - the 95% and 98% cut-offs
- Cobb (2020) ‘Corpus for courses’
 - A published earlier version of this presentation

**QUESTIONS? COMMENTS?
MORE LIVE DEMOS?**

Corpus for courses: Data-driven course design

Further reading on
this topic

Earlier version:
2021 conference paper
at Swiss Conference of
Applied Linguistics

Download at
[Lextutor.ca/cv/](https://www.lex tutor.ca/cv/)

Thomas COBB

Université du Québec à Montréal (UQAM)

Faculté des sciences de l'éducation

1205, rue Saint-Denis, Montréal (Québec) H2X 3R9, Canada

cobb.tom@uqam.ca; www.lex tutor.ca

L'apprentissage sur corpus, en tant qu'ensemble de principes et de technologies, joue un rôle bien établi dans l'apprentissage des langues, et cet article montre comment ceux-ci peuvent s'appliquer également à la conception de cours ou de curriculum de langue. Si les supports de cours sont reformulés sous forme de corpus, on a alors à disposition un certain nombre de moyens pour amener la recherche sur l'apprentissage directement dans la salle de classe. Cet article commence par une définition des termes, un examen de la place de l'apprentissage sur corpus dans l'acquisition de la langue, et montre des moyens d'appliquer cette approche à la conception, au testing, et à l'évaluation de l'enseignement des langues. Le contexte est la refonte d'un cours de lecture en cours pour adultes en langue seconde basé sur une collection de documents authentiques trouvés sur Internet. Les principes et technologies de la conception de cours sur corpus ont été utilisés, premièrement, pour exposer les faiblesses de cette collection de matériels en tant que cours, et, deuxièmement, pour montrer des moyens concrets de les améliorer. Tous les logiciels impliqués dans ce travail sont accessibles au public.

Mots-clés:

apprentissage basé sur les consultations d'un corpus, conception pédagogique, analyse de besoins, vocabulaire.

Keywords:

corpus-based learning, data-driven learning, instructional design, needs analysis, text analysis, vocabulary.

1. Background & proposition

Data-driven learning (DDL) is an input and comprehension based approach to