

# An analysis of a French as a Foreign Language Corpus for Readability Assessment

Thomas François

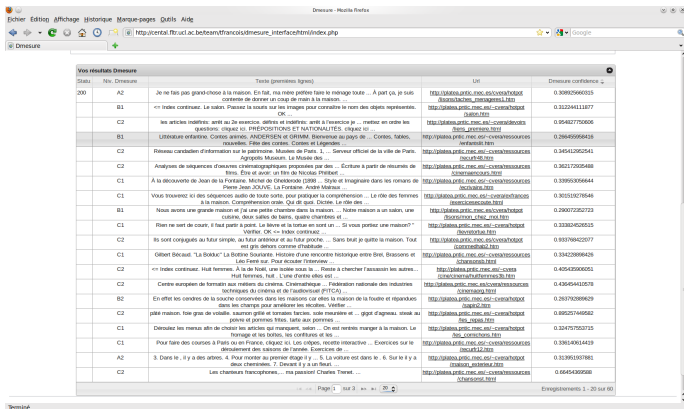
NLP4CALL, Uppsala

13-11-2014

# Context

## Readability models have roles to play in iCALL:

### 1 Find educational material of a given level, on the web

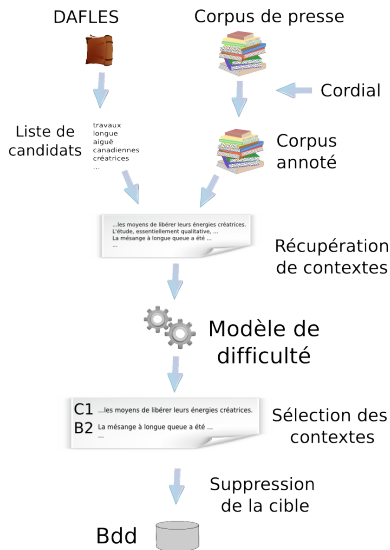


The screenshot shows a web browser window displaying a table titled "Vos résultats Dmesure". The table lists various educational materials with columns for ID, Title, URL, and Dmesure confidence. The materials are organized into groups (A2, B1, C2) and include titles in French such as "Je ne fais pas grand-chose à la maison", "Les articles indiféris: arreté au 2e essai...", and "Vous trouvez ici des séquences audio de toute sorte...". The browser's address bar shows the URL "http://central.frz.ucl.ac.be/learn/francais/dmesure\_interface.html/index.php".

ID	Titre	URL	Dmesure confidence
A2	Je ne fais pas grand-chose à la maison. En fait, ma mère préfère faire le ménage toute ... à part ça, je suis content de diriger ce club de tennis à la maison.	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens1.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens1.htm</a>	0.30965660025
B1	« Index continué. Le salon. Placez la souris sur les images pour connaître le nom des objets représentés. ... »	<a href="http://librairie.pedagogie.ac-cyprus.org/.../index1.htm">http://librairie.pedagogie.ac-cyprus.org/.../index1.htm</a>	0.32244111877
C2	les articles indiféris: arreté au 2e essai... défréris et indiféris: arreté à l'essai... mettez en ordre les questions: cliquez ici. PREPOSITIONS ET NATIONALITES cliquez ici ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens2.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens2.htm</a>	0.95482775006
B1	Lireuseur enfantin: Contes arabes, ANCIENS ET MODERNES, bonhomme au pays de ... Contes, fables, nouvelles, Fable des contes, Contes et Légendes ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens3.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens3.htm</a>	0.29445996438
C2	Revueur candidat d'information sur le patrimoine. Musée de Paris 1. ... Siteur officiel de la ville de Paris. Agropolis Muséum. La Musée des ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens4.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens4.htm</a>	0.34541205251
C2	Analyses de séquences d'écrites chronologiques proposées par des ... Écrite à partir de résumés de films. Éty et avér: un film de Nicolas Philbert ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens5.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens5.htm</a>	0.96217200488
C1	À la découverte de Jean de La Fontaine. Michel de Craonville (1685) - Signe et imagine dans le roman de Pierre Jean JOUVE. La Fontaine. André Malraux ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens6.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens6.htm</a>	0.33995336444
B1	Vous trouvez ici des séquences audio de toute sorte, pour pratiquer la compréhension ... Le rôle des femmes à la maison. Compréhension orale. Qui de qui. Dicitte. Le rôle des ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens7.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens7.htm</a>	0.30251027648
C2	Nous avons une grande maison et j'ai une petite chambre dans la maison ... Notre maison a un salon, une cuisine, deux salles de bain, quatre chambres et ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens8.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens8.htm</a>	0.29007220723
C1	Rien ne sert de courir, il faut partir à point. Le lèvre et la tonne en sont un ... Si vous partez une maison? ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens9.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens9.htm</a>	0.33302403015
C2	Ils sont corrigés au futur simple, de leur arreté et au futur proche ... Sans être je quite la maison. Tout est prêt, allez, c'est parti. Chérisse ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens10.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens10.htm</a>	0.93779842207
C1	Olbert Becard. "La Bouque" La Bouque Souvante. Histoire d'une rencontre historique entre Brel, Brassens et Les Femmes qui Peut étre réécrite. Interme ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens11.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens11.htm</a>	0.33423898428
C2	« Index continué. Huit femmes. À la de Noël, une soite sous le ... Reste à chercher l'assassin les autres... Huit Femmes, huit ... L'une d'entre elles est ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens12.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens12.htm</a>	0.40542990005
C2	Centre européen de formation aux métiers du cinéma. Cinéma - Fédération nationale des industries techniques du cinéma et de l'audiovisuel (FITCA) ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens13.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens13.htm</a>	0.43645410578
B2	En effet les centres de la poche connexives dans les maisons car elles la toudre et répandues dans des champs pour analyser les écrites. Verifier ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens14.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens14.htm</a>	0.28973898629
C2	pléte maison, four grand volé, saumon grillé et tomates farcies, sole meuvaine et ... gige d'agneau, steak au poivre et pommes frites. faite aux pommes ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens15.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens15.htm</a>	0.89521446582
C1	Demain les menss alle de chez les articles qui mangent, manger ... On est tenté manger à la maison. Le mariage et les boites, les confitures et les ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens16.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens16.htm</a>	0.32475703715
C1	Pour faire des courses à Paris ou en France, cliquez ici. Les écrites, recette interactive ... Exercices sur le déroulement des saisons de l'année. Exercices de ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens17.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens17.htm</a>	0.33614061449
A2	3. Dans le, il y a des arbres. 4. Pour monter au premier étage il y ... 5. La voiture est dans le 6. Sur le il y a deux chaises. 7. Deux et j'a un feu ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens18.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens18.htm</a>	0.35396195786
C2	Les chanteurs hétérophones ... ma passion Charles Trenet. ...	<a href="http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens19.htm">http://librairie.pedagogie.ac-cyprus.org/.../Boutique/achat_moyens19.htm</a>	0.645430958

# Context

- 2 Enhance systems for automatic exercise generation (proposal based on ALFALEX) [Verlinde et al., 2003]



# Problematic

- Many formulas “available” for L1, especially for English  
[Collins-Thompson and Callan, 2005, Feng et al., 2010, Vajjala and Meurers, 2012]
- Limited amount of models “available“ for L2  
[Heilman et al., 2007, Schwarm and Ostendorf, 2005]
- AND only two formulas use the CEFR scale (current standard)  
[François and Fairon, 2012, Pilán et al., 2014]
- **Problem:** Large amount of efforts required to collect the annotated data to train a readability model!

# Objectives of the paper

- ➊ Gathering a corpus of texts annotated for difficulty, as large as possible
  - ▶ Critical review of 5 common annotation approaches in readability
  - ▶ We opt for the extraction of texts from textbook series (with some conditions) and giving the textbook level to all texts extracted from it.
  - ▶ We report the collect process of about 2,000 texts for French as a Foreign Language (FFL)
- ➋ Investigate the shortcomings of this criterion (which is mainstream in the field)
  - ▶ Produce unbalanced corpus
  - ▶ Homogeneity of annotations across textbook series is questionable

## 2 experiments

### Class imbalanced effect

- We compared the results of models either based on a balanced or an unbalanced corpus
- The ordinal logistic models used includes two well-acknowledged features (mean number of words/sentence and of letters/word)
- It confirmed that majority class may deform the prediction space

### Homogeneity of the annotations

- We compared the lexical and syntactic difficulty of textbook series among them (for each levels)
- We used ANOVA and MANOVA and noticed significant homogeneity issues in the corpus
- A relation between the type of pedagogical approach and homogeneity issues also appeared.

Take-home message: Test the homogeneity of annotations when using texts from educational sources (just as we would do for human annotators).

# References I



Collins-Thompson, K. and Callan, J. (2005).  
Predicting reading difficulty with statistical language models.  
*Journal of the American Society for Information Science and Technology*, 56(13):1448–1462.



Feng, L., Jansche, M., Huenerfauth, M., and Elhadad, N. (2010).  
A Comparison of Features for Automatic Readability Assessment.  
*In COLING 2010: Poster Volume*, pages 276–284.



François, T. and Fairon, C. (2012).  
An “AI readability” formula for French as a foreign language.  
*In Proceedings of the 2012 Conference on Empirical Methods in Natural Language Processing (EMNLP 2012)*, pages 466–477.



Heilman, M., Collins-Thompson, K., Callan, J., and Eskenazi, M. (2007).  
Combining lexical and grammatical features to improve readability measures for first and second language texts.  
*In Proceedings of NAACL HLT*, pages 460–467.



Pilán, I., Volodina, E., and Johansson, R. (2014).  
Rule-based and machine learning approaches for second language sentence-level readability.  
*In Proceedings of the Ninth Workshop on Innovative Use of NLP for Building Educational Applications*, pages 174–184.

## References II



Schwarm, S. and Ostendorf, M. (2005).

Reading level assessment using support vector machines and statistical language models.  
*Proceedings of the 43rd Annual Meeting on Association for Computational Linguistics*, pages 523–530.



Vajjala, S. and Meurers, D. (2012).

On improving the accuracy of readability classification using insights from second language acquisition.  
*In Proceedings of the Seventh Workshop on Building Educational Applications Using NLP*, pages 163–173.



Verlinde, S., Selva, T., and Binon, J. (2003).

Alfalex: un environnement d'apprentissage du vocabulaire français en ligne, interactif et automatisé.  
*Romanesque*, 28(1):42–62.