



**HAL**  
open science

## ParCoGLiJe Corpus parallèle pour l'étude des grands classiques de la littérature de jeunesse Objectif du projet

Dejan Stosic, Saša Marjanović, Aleksandra Miletic

### ► To cite this version:

Dejan Stosic, Saša Marjanović, Aleksandra Miletic. ParCoGLiJe Corpus parallèle pour l'étude des grands classiques de la littérature de jeunesse Objectif du projet. Journée d'étude CORLI : Traitements et standardisation des corpus multimodaux et web 2.0., May 2018, Paris, France. hal-01873830

**HAL Id: hal-01873830**

**<https://hal.science/hal-01873830>**

Submitted on 13 Sep 2018

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

# ParCoGLiJe

Corpus parallèle pour l'étude des grands classiques de la littérature de jeunesse

Dejan Stosic<sup>1</sup>, Saša Marjanović<sup>2</sup>, Aleksandra Miletic<sup>1</sup>

<sup>1</sup> CLLE, Université de Toulouse, CNRS, Toulouse, France | <sup>2</sup> Faculté de philologie de l'Université de Belgrade, Serbie


Journée d'étude CORLI  
Université Paris Diderot - Paris 7  
Traitements et standardisation des  
corpus multimodaux et web 2.0.  
25 mai 2018

## ParCoGLiJe: un dérivé de ParCoLab

ParCoLab est un corpus parallèle trilingue comportant des textes originaux et leurs traductions dans trois langues d'Europe: le français, le serbe et l'anglais. La ressource est développée et maintenue au sein du Laboratoire CLLE (UMR 5263, CNRS et Université Toulouse Jean Jaurès), en étroite collaboration avec la Faculté de philologie de l'Université de Belgrade (cf. Miletic et al. 2017).

### Contenu

Le corpus ParCoLab comporte 11.359.761 mots provenant essentiellement de textes littéraires, mais aussi de textes juridiques, de sites web, de la presse, de retranscriptions de films, de divers textes spécialisés... La lemmatisation et l'annotation en POS et en fonctions syntaxiques sont en cours.



### Accès et interrogation

Consultable gratuitement en ligne à l'adresse:  
<http://parcolab.univ-tlse2.fr/>

Doté d'une interface d'interrogation permettant d'effectuer des requêtes simples ou complexes en combinant différents types de critères (expressions, lemmes, annotations morpho-syntaxiques et syntaxiques, etc.)

Hébergé par:



## Objectif du projet

Fournir un premier corpus parallèle français-anglais de littérature de jeunesse à tous ceux qui en font leur objet d'étude ou d'intérêt (littéraires, linguistes, traductologues, didacticiens, enseignants, grand public). Bien que la littérature de jeunesse soit un des domaines fondamentaux de la littérature et en dépit de sa place dans l'enseignement, la traduction en littérature pour la jeunesse reste un champ d'investigation très peu exploré (Lévêque 2014).

## ParCoGLiJe

Huit grands classiques de littérature de jeunesse structurés au format XML (TEI-P5) alignés en français et en anglais au niveau des chapitres, des paragraphes et des phrases.

### 4 œuvres d'auteurs français

Auteur	Titre	Taille FR	Taille EN	Formats
Daudet, A.	<i>Lettres de mon moulin</i>	46 592	47 706	xml, tmx, parcolab, bi-text
Dumas, A.	<i>Les trois mousquetaires</i>	213 791	228 900	xml, parcolab
De Ségur	<i>Mémoires d'un âne</i>	54 662	42 040	xml, parcolab
Verne, J.	<i>Vingt mille lieues sous les mers</i>	142 959	141 936	xml, parcolab

### 4 œuvres d'auteurs anglais

Auteur	Titre	Taille FR	Taille EN	Formats
Hodgson Burnett, F.	<i>The Secret Garden</i>	76 940	80 558	xml, parcolab
Stevenson, R.L.	<i>Treasure Island</i>	69 827	68 996	xml, parcolab
Kipling, R.	<i>Jungle Book</i>	55 913	51 334	xml, parcolab
Dickens, Ch.	<i>Oliver Twist</i>	164 786	157 584	xml, parcolab

Taille du corpus: 1.644.524 mots

## Un corpus à usages multiples

Bi-textes	Lecture en L2 assistée	Interrogation ParCoLab	XML standardisé
✓ Grand public	✓ Apprenants L2	✓ Linguistes	✓ Spécialistes TAL
✓ Littéraires comparatistes	✓ Grand public	✓ Lexicographes	✓ TAO
✓ Traductologues		✓ Traducteurs	
		✓ Apprenants L2	
		✓ Enseignants FLE & ALE	

## Diffusion du corpus

✓ Disponible sur deux plateformes



- ✓ Diffusé en plusieurs formats (finalisation prévue pour septembre 2018)
- ✓ Diffusion de l'information (septembre 2018)

## Actions en cours et à venir

- ✓ Enrichissement de la ressource par d'autres œuvres, plus récentes
- ✓ Finalisation du formatage afin de rendre tous les textes disponibles dans tous les formats cités
- ✓ Annotations morphosyntaxiques et syntaxiques

## Références

Lévêque, M. (2014). « Panorama de la recherche en littérature de jeunesse en France, 2013-2014 ». In Scherer, L., Issler, L. (éds), *Kinder- und Jugendliteratur der Romania. Impulse für ein neues romanistisches Forschungsfeld*, Peter Lang.  
Miletic A., Stosic D., Marjanović S. (2017). « ParCoLab: A Parallel Corpus for Serbian, French and English ». In: Ekštejn K., Matoušek V. (eds) *Text, Speech, and Dialogue. TSD 2017. Lecture Notes in Computer Science book series*, vol 10415. Springer, Cham, p. 156-164.

## Remerciements et contacts

Nous remercions le consortium CORLI de la TGR HumaNum, l'Equipe ORTOLANG, la plate-forme COCOON et le service des documents sonore de la BnF pour le financement qui a permis la réalisation de la ressource.

### Contacts:

D. Stosic: [dejan.stosic@univ-tlse2.fr](mailto:dejan.stosic@univ-tlse2.fr)  
S. Marjanović: [sasa.marjanovic@fil.bg.ac.rs](mailto:sasa.marjanovic@fil.bg.ac.rs)  
A. Miletic: [aleksandramiletic1207@gmail.com](mailto:aleksandramiletic1207@gmail.com)