

Aligner : un outil d'alignement et de mesure d'accord inter-annotateurs

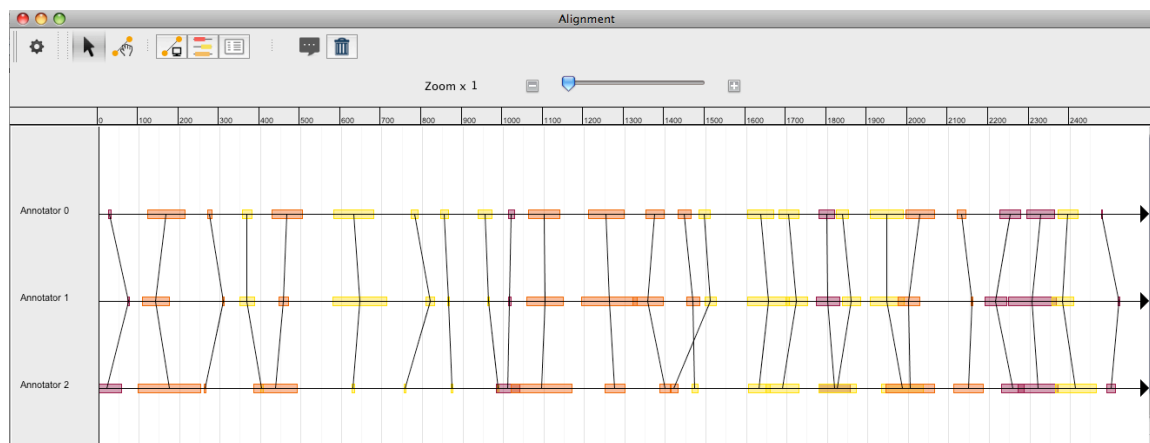
Yann Mathet¹, Antoine Widlöcher¹

(1) GREYC, UMR CNRS 6072, Université de Caen, 14032 Caen Cedex
{prenom.nom}@unicaen.fr

Une méthode unifiée d'alignement et de mesure d'accord inter-annotateurs a été développée par (Mathet&Widlöcher 2011), consistant à considérer les annotations concurrentes faites par plusieurs annotateurs comme un facteur de désordre que le choix du meilleur **alignement** va minimiser. Cette notion de désordre, appelée entropie, est par ailleurs considérée par rapport au désordre induit par un processus aléatoire sur les mêmes textes pour établir une **mesure d'accord**, suivant la formule (1) :

$$\text{accord} = (\text{entropieHasard} - \text{entropie}) / \text{entropieHasard} \quad (1)$$

Cette méthode a été implémentée (dans une version légèrement relaxée) et intégrée à la plateforme d'annotation GlozzQL sous forme d'un outil nommé Aligner, objet de la présente démonstration.



Lorsqu'un jeu d'annotations est chargé, l'outil crée une ligne horizontale pour chaque annotateur trouvé (3 annotateurs dans notre exemple ci-dessus), et empile ces dernières verticalement. Une ligne représente l'intégralité du texte (graduée en caractères), et porte, sous forme de segments colorés (selon leurs catégories), les différentes unités annotées par un annotateur donné. Il est alors possible de lancer le module automatique d'alignement qui crée, lorsqu'il les juge pertinents au regard de la méthode proposée, des alignements inter-annotateurs sous forme de lignes (relativement) verticales. Une valeur d'entropie correspondante est automatiquement calculée. S'il le souhaite, l'utilisateur peut modifier les alignements proposés directement à la souris. Par ailleurs, le système est capable de générer automatiquement des annotations aléatoires judicieusement disposées (en s'inspirant de ce qu'il constate en corpus), permettant de créer une référence d'entropie aléatoire de bon niveau pour un corpus donné. Pour cela, il suffit de placer un certain nombre d'exemples d'annotation du corpus concerné dans un répertoire et de le soumettre à l'application. Dès lors, l'utilisateur dispose, à chaque fois qu'il charge un jeu d'annotations du corpus en question, non seulement de la génération de ses alignements, mais aussi de la mesure d'accord telle que donnée en formule (1). Un exemple complet sur corpus réel sera montré lors de la démonstration, ainsi que les déductions qui peuvent en être tirées sur la qualité des annotations d'un annotateur par rapport à l'ensemble des annotateurs.

Références

MATHET Y. ,WIDLÖCHER A. (2011), Une approche holiste et unifiée de l'alignement et de la mesure d'accord inter-annotateurs. *TALN 2011*, à paraître (soumission 78).