

Des cascades Unitex pour la fouille bibliographique

Projet ANR Abliss sur les récepteurs biologiques

Denis Maurel, Sandy Chéry, Lifat

Présentation du projet Abliss

Présentation du projet

□ **Projet interdisciplinaire avec des collègues biologistes**

- Les récepteurs couplés aux *protéines G* sont des cibles de choix pour plus de 30% des médicaments
- Mieux les connaître la signalisation permettrait
 - D'augmenter l'efficacité de ces médicaments
 - De diminuer les effets secondaires
- Mais la littérature scientifique est trop abondante
- Et des résultats d'expériences réalisées restent cachés
 - Car ils ne concernent pas le sujet principal de l'article
 - Car ils ne figurent ni dans le titre, ni dans le résumé, ni dans les mots clés


Un cercle vertueux

(1) Décrire des expériences sous forme *prédicat-arguments*


(1)(4) Inrae
(Anne
Poupon)

(2) Lifat
(Denis
Maurel)

(3) LRI
(Christine
Froidevaux)




Un cercle vertueux




(2) Extraire des résultats expérimentaux dans les articles scientifiques par un module de traitement automatique des langues

Un cercle vertueux



(3) Inférer les réseaux à partir de ces données par une méthode de raisonnement à base de connaissances

Un cercle vertueux




(4) Tester expérimentalement une proposition de réseau de signalisation

Détail de l'analyse

La méthode

□ Utilisation de cascades de graphes (CasSys)

- Il s'agit de créer un nouveau texte à partir du texte d'origine en le transformant par des graphes successifs, dans un ordre précis.



Le corpus

□ Un article scientifique en biologie

1. Résumé
 - principaux résultats
2. Introduction
 - contexte de l'étude et état de l'art
3. Matériel et méthodes
 - mise en pratique des expériences
4. Résultats
 - liste et détail des expériences réalisées
5. Discussion
 - interprétation des expériences et perspectives
6. Conclusion

La chaine de traitement

□ script PHP

- Interrogation de la base de publication PubMed
 - 3 mots clés (deux protéines et une réaction chimique)
 - -> liste des identifiants PMCID correspondant à la requête
- Téléchargement de tous les articles à partir de la liste
- Préparation de l'environnement des scripts Unitex
 - Remplacement des *LF* par des *CRLF*
- Lancement de la 1^{ère} cascade Unitex


La chaine de traitement

□ 1^{ère} cascade Unitex

- Cette cascade ne retient que la partie *Résultats* de chaque article
 - Utilisation d'un fichier de normalisation
 - Pour harmoniser les espaces, les tirets, les apostrophes, les points de suspensions
 - Pour transformer les codages de caractères HTML (par exemple `β` ; → β)
 - Utilisation du *Preprocessing* (en mode *Merge*) pour marquer le titre de la partie *Résultats* et le titre de la partie suivante
 - Remarque : le *Preprocessing* ne permet pas l'utilisation du début et de la fin du texte
 - Suppression du résumé, de la partie précédant la partie *Résultats* et de la partie suivant la partie *Résultats*


La chaine de traitement

□ 1^{ère} cascade Unitex




La chaine de traitement

□ 1^{ère} cascade Unitex



La chaine de traitement

□ 1^{ère} cascade Unitex



La chaine de traitement

□ Script PHP

- Élimination des fichiers sans intérêt
 - Les fichiers sans partie *Résultats*
 - Les fichiers sans les 3 mots clés encore présents
- Lancement de la 2^{ème} cascade Unitex

La chaine de traitement

□ 2^{ème} cascade Unitex

- Cette cascade détaille, fichier par fichier, paragraphe par paragraphe, phrase par phrase, les structures prédicat-arguments correspondant à des résultats d'expérience
 - Pas de fichier de normalisation
 - Pas de *Preprocessing*

La chaine de traitement


□ 2^{ème} cascade Unitex

■ Prétraitements

- Balises Xml
- Phrases
- Verbes contractés
- Renvois (figures, bibliographie)
- Création de liste (par exemple : *S1P1 to S1P3* → *S1P1, S1P2, S1P3*)

La chaine de traitement

□ 2^{ème} cascade Unitex



La chaine de traitement

□ 2^{ème} cascade Unitex

■ Analyse biologique

- Entités
- Coordinations d'entités
- Verbes
- Prédicats simples
- Statut hypothétique pour les affirmations non expérimentées
- Prédicats complexes

■ Synthèse

- Mise en forme TEI

La chaine de traitement

□ Script PHP

- Création du fichier d'analyse (au format XML-TEI)

```
<teiCorpus>
```

```
<teiHeader>(entête présentant le projet Abliss)</teiHeader>
```

```
<tei>(premier texte)
```

```
<teiHeader>(entête contenant les métadonnées du premier fichier)</teiHeader>
```

```
<text>(texte du premier fichier et structures prédicat-arguments)</text>
```

```
</tei>
```

```
(textes suivants)
```

```
</teiCorpus >
```

- Lancement de la 3^{ème} cascade Unitex

La chaine de traitement

□ 3^{ème} cascade Unitex

- Cette cascade utilise l'option *standOff* pour donner des résultats quantitatifs
 - Un deuxième fichier de résultats est créé

```
<background>  
  <fact>protein("ERK")</fact>  
  <frequency value="2847"/>  
</background>
```

La chaîne de traitement

□ Quelques chiffres

- 5 141 articles après interrogation de PubMed
- 548 articles avec une partie Résultat et contenant encore les 3 mots clés
- 15 132 arguments (protéines, gènes...)
- 3 560 prédicats


Un exemple

PP1 also had a significant inhibitory effect on MAPK activation by EGF.

(Goparaju et al., 2005)

Détail de l'exemple

PP1 also had a significant inhibitory effect on MAPK activation by EGF.



Les métadonnées

```
<teiHeader>
  <titleStmt>
    <title>The S1P2 Receptor Negatively Regulates Platelet-Derived Growth Factor-Induced Motility
and Proliferation</title>
    <author>Goparaju SK, Jolly PS, Watterson KR, Bektas M, Alvarez S, Sarkar S, Mel Lshii I, Chun J,
Milstien S, Spiegel S</author>
  </titleStmt>
  <publicationStmt>
    <publisher>Molecular and Cellular Biology</publisher>
    <date>2005 May</date>
    <biblScope unit="vol">25</biblScope>
    <biblScope unit="issue">10</biblScope>
    <biblScope unit="pp">4237-4249</biblScope>
    <idno type="PMID">15870293</idno>
    <idno type="DOI">10.1128/MCB.25.10.4237-4249.2005</idno>
    <idno type="PMCID">PMC1087716</idno>
  </publicationStmt>
</teiHeader>
```

Les structures prédicat-arguments

```
<div type="sentence">
```

PP1 also had a significant inhibitory effect on MAPK activation by EGF.

```
<desc type="entity">protein("PP1")</desc>
```

```
<desc type="entity">protein("MAPK")</desc>
```

```
<desc type="entity">protein("EGF")</desc>
```

```
<desc type="predicate">modifiedForm("MAPK"_active,  
"MAPK"_inactive)</desc>
```

```
<desc type="predicate">associationModulation("PP1", "MAPK"_active,  
"MAPK"_inactive, "EGF", increase, confirmed, unknownCell,  
unknownMethod)</desc>
```

```
</div>
```

Détail de l'exemple

PP1 also had a significant inhibitory effect on MAPK activation by EGF.

```
protein("PP1")  
protein("MAPK")  
protein("EGF")
```


Détail de l'exemple

PP1 also had a significant inhibitory effect
on MAPK activation by EGF.

```
modifiedForm("MAPK"_active, "MAPK"_inactive)
```

modifiedForm("MAPK"_active, "MAPK"_inactive)

Détail de l'exemple



Détail de l'exemple

PP1 also had a significant inhibitory effect on MAPK activation by EGF.

```
associationModulation("PP1", "MAPK"_active, "MAPK"_inactive,  
"EGF", increase, confirmed, unknownCell, unknownMethod)
```

Poursuite du travail

Poursuite du travail

- Finalisation de la chaîne
- Évaluation de la création des prédicats sur des textes non étudiés
- Recherche sur le paragraphe (?) des informations manquantes
 - associationModulation("PP1", "MAPK"_active, "MAPK"_inactive, "EGF", increase, confirmed, *unknownCell*, *unknownMethod*)

Merci !