



Depuis 80 ans, nos connaissances  
bâtissent de nouveaux mondes

# INTRODUCTION GÉNÉRALE SUR LES ENJEUX DU *TEXT ET DATA MINING*

PATRICE BELLOT

8 OCTOBRE 2019



cnrs

La Science Ouverte : une révolution nécessaire

8 oct. 2019 Paris (France)

CNRS – INS2I





# 1 QU'EST-CE QUE LE TDM ?

Domaines scientifiques et difficultés

# 1

## QU'EST-CE QUE LA FOUILLE DE DONNÉES / DE TEXTES ?

### Le croisement de plusieurs domaines

- L'analyse de données automatisée
- L'Intelligence Artificielle
- Le Traitement Automatique des Langues

### De la donnée vers l'information vers la connaissance

#### Données ?

Elles peuvent des nombres,  
des signaux, des mots, des  
images...

Elles peuvent être structurées  
ou non, liées ou non...

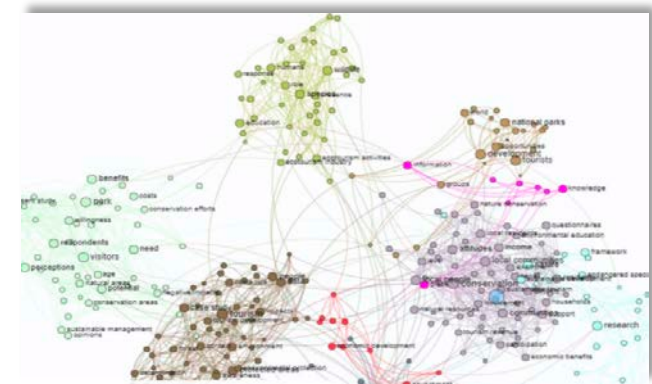
# 2

## DES APPLICATIONS

- Recherche de documents, d'images, de pages Web
- Recommandation automatique de contenus, veille
- Systèmes de questions-réponses
- Résumé automatique
- Cartographie et navigation guidées
- Détection de nouveauté, analyse de sentiments, de tendances...



<https://isidore.science>



Gargantext

# 3

## DES TRAITEMENTS GÉNÉRIQUES

- Extraction de termes, d'entités, d'informations, de relations
- Sélection de descripteurs, filtrage de données
- Calcul de similarités sémantiques
- Classification ou catégorisation automatiques
- Recherche d'information à partir de requêtes
- Structuration et segmentation
- Reconnaissance de formes, de caractères, d'images, de la parole...

# 4

## QUELQUES DIFFICULTÉS...

### Quelle que soit la nature des données :

- Structures peu normalisées, formats variés
- Les fameux V du Big Data : Volume, véracité, variabilité, valeur, vitesse

### Document, texte et langage :

- Données hétérogènes ou multimodales, ambiguës
- Multilinguisme (lexiques, terminologies, syntaxes)

### Le Droit et les bonnes pratiques pour la mise en œuvre du TDM :

Des difficultés  
génériques.

Des standards  
nécessaires.

Des solutions  
à partager.



*loi française Pour une République Numérique du  
7 octobre 2016 et la directive européenne sur le  
droit d'auteur dans le marché unique numérique  
du 26 mars 2019*



4

# Trump attaque l'Europe après le feu vert de l'OMC

Les Etats-Unis vont taxer à 10% les avions et à 25% une myriade de produits européens

**D**ans la foulée de sa victoire électorale, Donald Trump a annoncé mardi 1er octobre, le droit de lever des droits de douane de 10 milliards de dollars (8,3 milliards d'euros) sur les importations européennes. Un accord historique. Le département du Commerce a taxé au préalable les importations en provenance des quatre pays responsables de la fraude à Airbus, à savoir la France, le Royaume-Uni, l'Allemagne et l'Espagne. La ministre des Etats-Unis pour le commerce, Elaine Chao, a annoncé mardi 1er octobre, la levée de droits de douane de 10 % sur les avions et de 25 % sur une myriade de produits européens.

Les décisions, par les Etats-Unis, ont été publiées par le représentant au commerce Robert Lighthizer, figurant les vins français et espagnols, l'huile d'olive, le whisky écossais, les draps et les couvertures britanniques, le café, les conteneurs et les machines allemandes et des fromages de France. Trump a annoncé qu'il avait demandé aux agriculteurs américains d'être frappés par une crise tarifaire. Les produits en cuir et les vêtements ont été ajoutés à la liste. Les Etats-Unis ont également taxé les produits en cuir et les vêtements. Les Etats-Unis ont également taxé les produits en cuir et les vêtements.

La levée des droits de douane sur les avions et de 25 % sur une myriade de produits européens a été annoncée par le département du Commerce américain. Les Etats-Unis ont également taxé les produits en cuir et les vêtements. Les Etats-Unis ont également taxé les produits en cuir et les vêtements.

**La fraude est loin d'être close. Les Etats-Unis ont, eux aussi, été reconnus coupables de subventions illégales à Boeing.**

Imposer des sanctions, ce serait une erreur économique et politique. Nous serons prêts avec nos partenaires européens à y répondre de façon ferme. Les mesures américaines sont censées faire plier les Européens, qui n'ont jusqu'à présent pas flanché face à Donald Trump dans leurs négociations commerciales, ou en tout cas les amener à la table des négociations. La querelle aéronautique, qui a toujours été spécifique, arrive par un hasard du calendrier sur le devant de la scène, alors que le président américain hésite depuis des mois sur la stratégie globale à mener vis-à-vis des Européens durant l'année électorale 2020.

LES DATES  
**2004**  
Boeing dépose plainte en octobre et demande à l'OMC d'enquêter sur les aides publiques versées par l'Allemagne, la France, le Royaume-Uni et l'Espagne à Airbus depuis son lancement en 1990.  
**2005**  
Au mois de juin, Airbus se retourne à son tour contre Boeing, l'accusant de recevoir des subventions sous la forme de déductions fiscales.  
**2010**  
En juin, l'OMC conclut que les subventions versées à Airbus portent préjudice aux intérêts américains. L'avionneur européen fait appel. En septembre, un rapport préliminaire de l'OMC déclare que les subventions accordées à Boeing ont violé les règles de l'OMC et doivent être retirées.  
**2018**  
L'organe d'appel de l'OMC confirme, en mai, que les subventions européennes versées à Airbus ont porté un préjudice commercial à Boeing et constate que l'avionneur européen ne s'est pas mis en conformité.

Sur la liste figurent vins français et espagnols, huile d'olive espagnole, whisky écossais, draps britanniques.


La levée des droits de douane sur les avions et de 25 % sur une myriade de produits européens a été annoncée par le département du Commerce américain.

Un armistice avait été signé entre Américains et Européens à l'été 2018, mais l'administration Trump veut sans cesse remettre à l'ordre du jour le dossier automobile et y ajouter celui de l'agriculture (privés de débouchés en Chine, les fermiers veulent écouler leur production en Europe, mais la France s'y oppose). M. Trump est censé prendre des décisions sur le sujet d'ici au 13 novembre, pour savoir s'il taxe unilatéralement 100 milliards de dollars d'exportations européennes de biens et de services. Celles-ci ont déjà ailleurs insisté : « Nous souhaitons faire redescendre les tensions et éviter des sanctions tarifaires qui ne feront que nuire à nos deux économies, au moment où la Chine renforce son industrie aéronautique. [Mais s'ils] choisissent

de penser que même si l'organe de règlement des différends, choisit d'imposer des sanctions maintenant, ce sera contre-productif et de courte vue », a réagi mercredi soir la commissaire européenne au commerce, Cecilia Malmström.

Un armistice avait été signé entre Américains et Européens à l'été 2018, mais l'administration Trump veut sans cesse remettre à l'ordre du jour le dossier automobile et y ajouter celui de l'agriculture (privés de débouchés en Chine, les fermiers veulent écouler leur production en Europe, mais la France s'y oppose). M. Trump est censé prendre des décisions sur le sujet d'ici au 13 novembre, pour savoir s'il taxe unilatéralement 100 milliards de dollars d'exportations européennes de biens et de services. Celles-ci ont déjà ailleurs insisté : « Nous souhaitons faire redescendre les tensions et éviter des sanctions tarifaires qui ne feront que nuire à nos deux économies, au moment où la Chine renforce son industrie aéronautique. [Mais s'ils] choisissent

# STRUCTURE LOGIQUE ET CODAGE



**finansol & argent**  
organisent  
**LES GRANDS PRIX DE LA FINANCE SOLIDAIRE**  
**2019**  
**VOTEZ POUR LE PRIX DES TERRITOIRES**  
Les nominés 2019 sont  
**Ecoloc**, le lieu de vie qui redynamise son territoire rural. Vallée de la Méouge  
**Share-Wood**, l'atelier de menuiserie partagé qui réunit amateurs et professionnels.

**PERTES & PROFITS | BOEING-AIRBUS**  
PAR PHILIPPE ESCANDE  
**Je te tiens, tu me tiens...**  
Depuis qu'ils se font face, ces deux-là excellent dans l'interminable jeu de la barbiéte. Je te tiens, tu me tiens... Sans autre rival sur l'arène long courrou, ils se cherchent sur les produits et les clients, mais aussi sur la table verte. Depuis quinze ans, Boeing reproche à son concurrent d'avoir bénéficié de généreuses subventions de l'Etat américain. L'affaire est loin d'être close. Les Etats-Unis ont, eux aussi, été reconnus coupables de subventions illégales à Boeing.  
Depuis qu'ils se font face, ces deux-là excellent dans l'interminable jeu de la barbiéte. Je te tiens, tu me tiens... Sans autre rival sur l'arène long courrou, ils se cherchent sur les produits et les clients, mais aussi sur la table verte. Depuis quinze ans, Boeing reproche à son concurrent d'avoir bénéficié de généreuses subventions de l'Etat américain.



Depuis 80 ans, nos communaux balissent de nouveaux mondes

# ALLER AU-DELÀ DES MOTS CLEFS : PAS TOUJOURS FACILE...

Google Scholar search results for "neural network". The search bar contains "neural network" and the results show "Articles Environ 2650000 résultats (0,07 s)".

Google Scholar search results for "neural networks". The search bar contains "neural networks" and the results show "Articles Environ 2810000 résultats (0,04 s)".

## Date indifférente

- Depuis 2019
- Depuis 2018
- Depuis 2015
- Période spécifique...

## Trier par pertinence

Trier par date

## Toutes les langues

Rechercher les pages en Français

- inclure les brevets
- inclure les citations

Créer l'alerte

## Neural network ensembles

[LK Hansen, P Salamon](#) - IEEE Transactions on Pattern Analysis & ..., 1990 - computer.org  
ABSTRACT< p> Several means for improving the performance and training of **neural networks** for classification are proposed. Crossvalidation is used as a tool for optimizing **neural network** parameters and architecture. It is shown that the remaining residual generalization ...  
☆ 97 Cité 4055 fois Autres articles Les 20 versions

## Neural network-based face detection

[HA Rowley, S Baluja, T Kanade](#) - IEEE Transactions on pattern ..., 1998 - ieeexplore.ieee.org  
We present a **neural network**-based upright frontal face detection system. A retinally connected **neural network** examines small windows of an image and decides whether each window contains a face. The system arbitrates between multiple networks to improve ...  
☆ 97 Cité 5399 fois Autres articles Les 67 versions

## [PDF] A general regression neural network

[DF Specht](#) - IEEE transactions on neural networks, 1991 - Citeseer  
This paper describes a memory-based **neural network** that provides estimates of continuous variables and converges to the underlying (linear or nonlinear) regression surface. This general regression **neural network** (GRNN) is a one-pass learning algorithm with a highly ...  
☆ 97 Cité 4039 fois Autres articles Les 13 versions

## Recurrent neural network based language model

[T Mikolov, M Karafiát, L Burget, J Černocký](#), ... - ... annual conference of ..., 2010 - isca-speech.org  
A new recurrent **neural network** based language model (RNN LM) with applications to speech recognition is presented. Results indicate that it is possible to obtain around 50% reduction of perplexity by using mixture of several RNN LMs, compared to a state of the art ...  
☆ 97 Cité 3364 fois Autres articles Les 7 versions

## Recherches associées

**artificial neural network**      **neural network prediction**  
**convolutional neural network**      **fuzzy neural network**  
**recurrent neural network**      **neural network matlab**  
**deep neural network**      **neural network forecasting**

## Date indifférente

- Depuis 2019
- Depuis 2018
- Depuis 2015
- Période spécifique...

## Trier par pertinence

Trier par date

## Toutes les langues

Rechercher les pages en Français

- inclure les brevets
- inclure les citations

Créer l'alerte

## [LIVRE] Neural networks: a comprehensive foundation

[S Haykin](#) - 1994 - dl.acm.org  
This book represents the most comprehensive treatment available of **neural networks** from an engineering perspective. Thorough, well-organized, and completely up to date, it examines all the important aspects of this emerging technology, including the learning ...  
☆ 97 Cité 50331 fois Autres articles Les 8 versions

## [LIVRE] Neural networks and learning machines/Simon Haykin.

[SS Haykin](#) - 2009 - repository.fue.edu.eg  
Pearson Prentice Hall. All rights reserved. Printed in the United States of America. This publication is protected by Copyright and permission should be obtained from the publisher prior to any prohibited reproduction, storage in a retrieval system, or transmission in any ...  
☆ 97 Cité 6152 fois Autres articles Les 2 versions

## Imagenet classification with deep convolutional neural networks

[A Krizhevsky, I Sutskever, GE Hinton](#) - Advances in neural ..., 2012 - papers.nips.cc  
We trained a large, deep convolutional **neural network** to classify the 1.3 million high-resolution images in the LSVRC-2010 ImageNet training set into the 1000 different classes. On the test data, we achieved top-1 and top-5 error rates of 39.7% and 18.9% which is ...  
☆ 97 Cité 47095 fois Autres articles Les 95 versions

## Reducing the dimensionality of data with neural networks

[GE Hinton, RR Salakhutdinov](#) - science, 2006 - science.sciencemag.org  
High-dimensional data can be converted to low-dimensional codes by training a multilayer **neural network** with a small central layer to reconstruct high-dimensional input vectors. Gradient descent can be used for fine-tuning the weights in such "autoencoder" **networks** ...  
☆ 97 Cité 10174 fois Autres articles Les 20 versions

## Recherches associées

**artificial neural networks**      **fuzzy neural networks**  
**convolutional neural networks**      **neural networks delays**  
**deep neural networks**      **neural networks forecasting**  
**recurrent neural networks**      **neural networks time-varying delays**



Google Scholar  
arbre feuille

Articles Environ 108000 résultats (0,06 s)

Date indifférente  
Depuis 2019  
Depuis 2018  
Depuis 2015  
Période spécifique...

Trier par pertinence  
Trier par date

Toutes les langues  
Rechercher les pages en Français

inclure les brevets  
 inclure les citations

Créer l'alerte

[LIVRE] **Arbres, arbustes et lianes des zones sèches d'Afrique de l'Ouest**  
M Arbonnier - 2009 - books.google.com  
... à la richesse de leur vocabulaire puisque, pour une seule espèce, il peut y avoir un nom spécifique pour désigner l'**arbre**, sa **feuille**, sa fleur ... En revanche, en milieu fermé — galerie forestière, forêt claire —, où la concurrence avec les **arbres** voisins est grande, l'**arbre** a ten ...  
☆ 97 Cité 687 fois Autres articles Les 13 versions

[LIVRE] **Les arbres du Canada**  
JL Farrar - 1996 - books.google.com  
... résinifère nervure médiane Chaque description de genre débute par quelques renseignements généraux : importance du genre, forme des **arbres** et région(s) ... **Feuilles** La **feuille** est l'organe que la plupart des lecteurs examineront tout d'abord pour identifier un **arbre** ...  
☆ 97 Cité 92 fois Autres articles Les 4 versions

[PDF] **Un procédé itératif de dénombrement d'arbres binaires et son application à leur génération aléatoire**  
JL Rémy - RAIRO. Informatique théorique, 1985 - numdam.org  
... (A, v) = DÉFINITION 4 (**arbres** binaires pointés) : Un **arbre** binaire pointé A\* est la donnée d'un **arbre** binaire à **feuilles** numérotées A', d'un nœud ou d'une **feuille** x de cet **arbre** et d'une marque ce (g, d). Le nombre B\*n d'**arbres** binaires pointés de taille n est égal à 2\*(2n-1)\*B ...  
☆ 97 Cité 121 fois Autres articles Les 3 versions

[LIVRE] **Les arbres de connaissances**  
M Authier, L Pierre - 2017 - books.google.com  
... On verra tout au long de l'ouvrage que le système des **arbres** de connaissances respecte les individus, n'impose rien, fonctionne sur ... La petite fille sort de son cartable une grande **feuille** qu'elle ... On peut y voir en couleurs un **arbre** aux multiples branches et au beau feuillage vert ...  
☆ 97 Cité 215 fois Autres articles

[PDF] **Arbres de décision**  
R Rakotomalala - Revue Modulad, 2005 - modulad.fr  
... d'utiliser des règles plus efficaces pour définir la taille adéquate de l'**arbre** de décision ... lorsqu'elle est pure, quelle est la règle de décision optimale lorsque qu'une **feuille** contient des ... Répondre à ces questions permet de définir une méthode d'induction des **arbres** de décision ...  
☆ 97 Cité 79 fois Autres articles Les 10 versions

**Les glycosides flavoniques foliaires de quelques arbres, au cours du cycle végétatif**  
M Tissut, K Egger - Phytochemistry, 1972 - Elsevier  
... L.es glycosides flavoniques foliaires de quelques **arbres** ... complexes qui libèrent du glucosyl-3 kaempferol par hydrolyse alcaline; les flavonols de la **feuille** adulte sont ... glucosides et les 3-arabinosides apparaissent sur les chromatogrammes des extraits de **feuilles** jeunes, les 3 ...  
☆ 97 Cité 30 fois Autres articles Les 2 versions

# CONTEXTES ET CONNAISSANCES

Indexation par mots, par terme, par domaine...

Google Scholar  
méthane

Articles Environ 61100 résultats (0,08 s)

Date indifférente  
Depuis 2019  
Depuis 2018  
Depuis 2015  
Période spécifique...

Trier par pertinence  
Trier par date

Toutes les langues  
Rechercher les pages en Français

inclure les brevets  
 inclure les citations

Créer l'alerte

**Methane emissions from cattle**  
KA Johnson, DE Johnson - Journal of animal ecology  
Increasing atmospheric concentrations of **methane** are a major concern because of its role as a greenhouse gas. Ruminant livestock can produce a significant amount of **methane** through enteric fermentation. This paper reviews the current state of knowledge on the sources of origin. Ruminant livestock can produce a significant amount of **methane** through enteric fermentation. This paper reviews the current state of knowledge on the sources of origin. Ruminant livestock can produce a significant amount of **methane** through enteric fermentation. This paper reviews the current state of knowledge on the sources of origin.  
☆ 97 Cité 2309 fois Autres articles

**Biogeochemical aspects of atmospheric methane**  
RJ Cicerone, RS Oremland - Global biogeochemical cycles and air quality  
**Methane** is the most abundant organic chemical in the atmosphere and is increasing with time, as a variety of independent sources contribute to its growth. Photochemical reactions oxidize **methane** in the atmosphere to form carbon monoxide and formaldehyde.  
☆ 97 Cité 1901 fois Autres articles

**Methane production by ruminants**  
AR Moss, JP Jouany, J Newbold - Annales de la recherche vétérinaire  
The aim of this paper is to review the role of **methane** in the rumen and to examine the contribution to atmospheric **methane** emissions from ruminants. Agricultural emissions of **methane** are a significant component of the greenhouse effect.  
☆ 97 Cité 1152 fois Autres articles

CH4

Environ 1160000 résultats (0,08 s)

**PRODUCTION OF CO AND CH4, CO2 AT METAL ELECTRODES IN AQUEOUS SOLUTION**  
Y Hori, K Kikuchi, S Suzuki - Chemistry Letters  
The total analysis of gaseous and soluble products from the reduction of CO2 (current density 5 mA cm<sup>-2</sup>) was predominantly produced at Cd, In, Sn, and Fe electrodes.  
☆ 97 Cité 707 fois Autres articles

**Soil microorganisms as controllers of atmospheric methane, OCS, N2O, and NO).**  
R Conrad - Microbiol. Mol. Biol. Rev., 1996 - microbiolmbr.asm.org  
Production and consumption processes in soils and sediments of various **methane** (CH4), CO, OCS, H2, N2O, and NO) in the atmosphere. Soil microbial processes contribute to the greenhouse effect.  
☆ 97 Cité 1758 fois Autres articles

**CO2 Reforming of CH4**  
MCJ Bradford, MA Vannice - Catalysis Reviews: Science and Technology  
Although technological practice should minimize **methane** emissions, the use of **methane** as a feedstock for the production of syngas and other chemicals is increasing.

# 4

## MULTILINGUISME, CITATIONS, FORMULES, RESULTATS...

The screenshot shows the OpenEdition website interface. At the top, there are navigation links for 'OpenEdition Books', 'OpenEdition Journals', 'Calenda', 'Hypothèses', 'Lettre', and 'OpenEdition Freemium'. Below this is a search bar and social media icons. The main header features the journal title 'γαῖα' in large white letters on a dark red background, with the subtitle 'Revue interdisciplinaire sur la Grèce archaïque'. A search bar is visible on the left. The main content area displays the issue '21 | 2018' and 'Varia'. The featured article is titled 'Ἰν'ἀμνήμων τύχη γένοιτο πολλῶν δεομένη σοφισμάτων (Phéniciennes, 64-65). La souveraineté brisée de la famille d'Œdipe et la crise de la parole dans le mythe tragique des Phéniciennes'. Below the title, there are three lines of text in Greek, English, and Italian, providing a summary of the article's content.

AVEZZÙ Guido, *Il mito sulla scena. La tragedia ad Atene*, Venise, Marsilio, 2003.

AVEZZÙ Guido, « Emulazione e antagonismo nella produzione tragica ateniese », *Dionysus ex machina*, 6 (1), 2015, p. 137-156.

BATTEZZATO Luigi, « An Introduction to Tragedy. G. Avezù: *Il mito sulla scena. La tragedia ad Atene* », *The Classical Review*, 55 (1), 2005, p. 29.

DOI : [10.1093/clrevj/bni019](https://doi.org/10.1093/clrevj/bni019)

BEARZOT Cinzia, « Perdonare il traditore? La tematica amnistiale nel dibattito sul richiamo di Alcibiade », dans M. Sordi (éd.), *Amnistia, perdono e vendetta nel mondo antico*, Milan, Vita e Pensiero, 1997, p. 29-52.

BELTRAMETTI Anna, « Antigone o della questione morale. Elaborazione tragica della sovranità democratica », dans D. Ambaglio (éd.), « Συγγραφή ». *Materiali e appunti per lo studio della storia e della letteratura antica*, vol. 4, Como, Edizioni New Press, 2002, p. 33-49.



Table 6. The NDCG and Hit Ratio (HT) Results of AARM and Its Variants on Five Datasets for RQ3

Measures (%)	Movies		CDs		Clothings		Cell Phones		Beauty	
	NDCG	HT	NDCG	HT	NDCG	HT	NDCG	HT	NDCG	HT
AARM	<b>5.020</b>	<b>15.187</b>	7.252	<b>20.749</b>	1.957	<b>4.915</b>	<b>4.976</b>	<b>11.568</b>	5.314	<b>13.648</b>
A_Static	4.376	13.318	6.794	19.567	1.898	4.590	4.728	11.181	4.918	12.735
No-UserAtt	4.290	13.104	6.700	19.108	1.310	3.217	4.685	10.786	4.739	12.297
Impr A_static	14.717	14.034	6.741	6.041	3.109	7.081	5.245	3.461	8.052	7.169
Impr No-UserAtt	17.016	15.896	8.239	8.588	49.389	52.782	6.211	7.250	12.133	10.986

We follow the short form convention adopted in Table 4 to name the datasets. The best performance of each measure on each dataset is highlighted in bold. The last block shows the percentage of improvements (or decrements for negative values) achieved by AARM compared with A\_static (Impr A\_static) and No-UserAtt (Impr No-UserAtt).

Table 7. The Corresponding Precision and Recall Results of AARM and Its Variants on Five Datasets for RQ3

## 5 CONCLUSION AND FUTURE WORK

In this article, we presented an AARM, which carefully captures the interactions between extracted from reviews for recommendation. AARM first calculates the interactions between aspect embeddings to estimate how a product fits a user's requirements on each aspect, and then estimates the user's overall satisfaction on the product by synthesizing the product's performance on each aspect. To deal with the problem that the number of shared aspects between a user and a product is often limited, AARM takes the interactions between different aspects into consideration. With a well-designed aspect-level attention module, not only the shared aspects but also other related aspect pairs can be selected and assigned higher attention values. In addition, we hold the assumption that a user's interests toward aspects are varied when examining different products. To achieve the goal, an attention module which simultaneously considers user and product information is designed in AARM. In the experiments on five real-world datasets, AARM outperforms the state-of-the-art methods on the top-N recommendation task. In particular, compared with multimodal (textual reviews, product images, and numerical ratings) methods JRL and eJRL, AARM can still achieve better results in all datasets. To demonstrate the effectiveness of each component in AARM, a lot of quantitative experiments and qualitative case studies are conducted.

Figure 3 shows an exemplary 6-step route for an intermediate of a drug candidate synthesis reported in 2015, which has been found by our algorithm in 5.4 s. It matches the published route.[45]




Figure 3: An exemplary 6-step route for an intermediate of a drug candidate synthesis reported in 2015, which has been found by our algorithm in 5.4 s. It matches the published route.[45]

Aspect to product  $v$ , the interactions between  $a_i$  and all the aspects  $i$  published first up:  
 autonomously  $v$

$$\mathbf{x}_{v,i} = \mathbf{g}_v \odot \mathbf{c}_i,$$

$$\mathbf{g}_v = \sum_{j \in \mathcal{A}_v} \mathbf{c}_j.$$

interaction between two aspects represents their similarity,  $\mathbf{x}_{v,i}$  represents the interaction between the aspect  $a_i$  and the product  $v$ . To measure the importance of  $\mathbf{x}_{v,i}$  is used as aspect  $a_i$ 's input to the user-level attention layer as

$$\hat{\alpha}_{u,v,i} = \mathbf{w}_{att_2}^T \mathbf{x}_{v,i},$$

$$\alpha_{u,v,i} = \frac{\exp(\hat{\alpha}_{u,v,i})}{\sum_{j \in \mathcal{A}_u} \exp(\hat{\alpha}_{u,v,j})}.$$

$\mathbf{w}_{att_2} \in \mathbb{R}^{d_a}$  is a learnable vector, and  $\alpha_{u,v,i}$  represents the importance of  $\mathbf{x}_{v,i}$  with regard to product  $v$ . This attention layer is different





## 2 L'EXISTANT

De nombreux acteurs

1

## DE NOMBREUX ACTEURS INDUSTRIELS

(et de très nombreux laboratoires publics)

xerox.fr  
Transformation digitale des entreprises - Xerox

À propos Services Produits Fournitures Support Client Où acheter

Partager  
Twitter  
Lien  
Courrier électronique  
Imprimer  
Plus

### Analyse documentaire : l'arme secrète pour être en première ligne de la transformation numérique

Pour la plupart des entreprises, les ambitions numériques restent lettres mortes, comme le montre une enquête Xerox réalisée auprès de responsables IT. Le désir d'abandonner le papier pour

Elsevier R&D Solutions  
FOR PHARMA & LIFE SCIENCES

## Pathway Studio®

Fact Sheet

Linguamatics  
an IQVIA company

Technology Products Solu



AI Siblings: NLP and Machine Learning for Better Drug Discovery

SINEQUA

Insight Platform Industry Focus Use Cases Resources Customers Partners Company News Blog

### Instant Insights in Your Work Conte

With Cognitive Search and Powerful Analytics

Synapse

BESOINS SOLUTIONS PR

## SYNAPSE DÉVELOPPEMENT

Les experts de l'Intelligence Artificielle appliquée au texte

MONDECA

MAKING SENSE OF CONTENT

## COMPRENDRE ET INTERPRETER

Comprendre le texte, l'image, la vidéo. Identifier ce qui est significatif. Catégoriser. Evaluer. Trouver des relations. Désambigüiser. Enrichir. Annoter. Gérer la connaissance pour nourrir les solutions d'intelligence artificielle: Classification automatique, bots, gestion d'alertes.

syllabs

Accueil Immobilier Nos offres d'emploi Contact EN ES

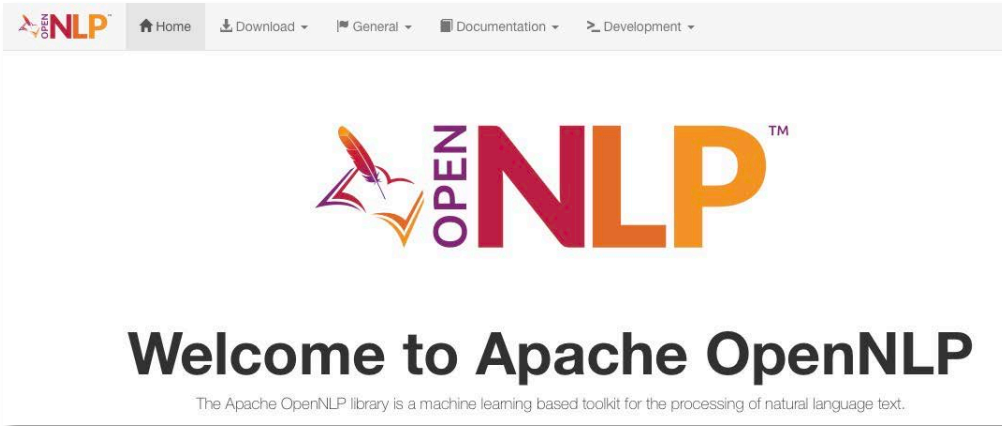
### Entrez dans le futur de la création de contenu.

Syllabs propose des solutions automatisées de création de textes et d'optimisation de:



# 2

## DES PROJETS OUVERTS



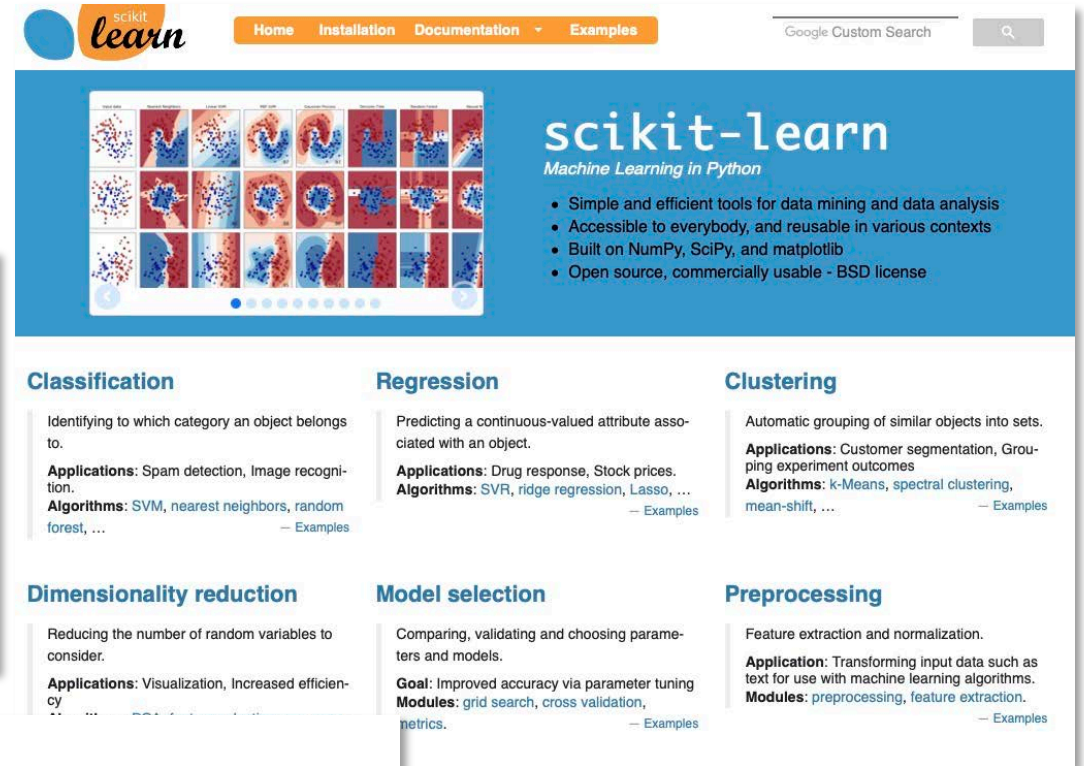
OPEN NLP

Home Download General Documentation Development

# OPEN NLP™

## Welcome to Apache OpenNLP

The Apache OpenNLP library is a machine learning based toolkit for the processing of natural language text.



scikit-learn

Home Installation Documentation Examples

Google Custom Search

# scikit-learn

Machine Learning in Python

- Simple and efficient tools for data mining and data analysis
- Accessible to everybody, and reusable in various contexts
- Built on NumPy, SciPy, and matplotlib
- Open source, commercially usable - BSD license

### Classification

Identifying to which category an object belongs to.  
**Applications:** Spam detection, Image recognition.  
**Algorithms:** SVM, nearest neighbors, random forest, ...

### Regression

Predicting a continuous-valued attribute associated with an object.  
**Applications:** Drug response, Stock prices.  
**Algorithms:** SVR, ridge regression, Lasso, ...

### Clustering

Automatic grouping of similar objects into sets.  
**Applications:** Customer segmentation, Grouping experiment outcomes  
**Algorithms:** k-Means, spectral clustering, mean-shift, ...

### Dimensionality reduction

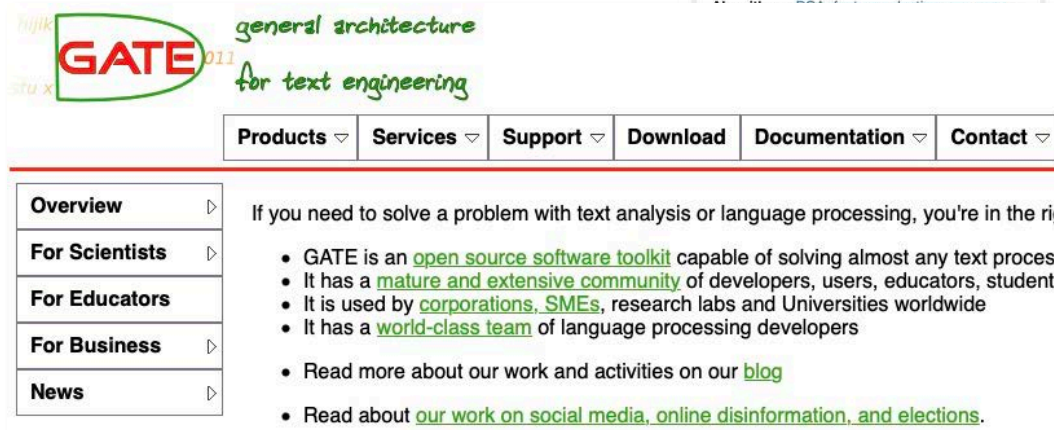
Reducing the number of random variables to consider.  
**Applications:** Visualization, Increased efficiency

### Model selection

Comparing, validating and choosing parameters and models.  
**Goal:** Improved accuracy via parameter tuning  
**Modules:** grid search, cross validation, metrics.

### Preprocessing

Feature extraction and normalization.  
**Application:** Transforming input data such as text for use with machine learning algorithms.  
**Modules:** preprocessing, feature extraction.



general architecture  
for text engineering

Products Services Support Download Documentation Contact

### Overview

If you need to solve a problem with text analysis or language processing, you're in the right place.

- GATE is an **open source software toolkit** capable of solving almost any text processing problem
- It has a **mature and extensive community** of developers, users, educators, students
- It is used by **corporations, SMEs**, research labs and Universities worldwide
- It has a **world-class team** of language processing developers

- Read more about our work and activities on our **blog**
- Read about **our work on social media, online disinformation, and elections.**



# 2

## DES LOGICIELS OUVERTS POUR L'IST : EXEMPLE *BILBO*

The screenshot shows the 'cybergegeo' website, which is the 'European Journal of Geography' / 'revue européenne de géographie'. The page is titled 'Systèmes, Modélisation, Géostatistiques' and is dated '2013'. The main article is '643 Modélographie multi-agents de la simulation des interactions sociétés-environnement et de l'émergence des villes' by Clara Schmitt et Denise Pumain. The article title is translated as 'Agent-based Modelography of the simulation of society - environment interactions and the emergence of cities'. Below the article title, there is a navigation menu with options: Résumé, Index, Plan, Texte, Bibliographie, Notes, Illustrations, Citation, Cité par, and Auteurs. The 'Bibliographie' option is highlighted with a red box, and a red arrow points from it to a list of references. The references include:

- Banos A., Sanders L., 2012, « Vers une cartographie sémantique des modèles urbains : des individus aux systèmes de villes », colloque *Modélisation urbaine : de la représentation au projet*, Coll. Références, Commissariat Général au Développement Durable.
- Bretagnolle A., Pumain D., 2010, « Simulating urban networks through multiscalar space-time dynamics (Europe and United States, 17th -20th centuries) », *Urban Studies*, vol. 47, No.13, 2819-2839. DOI : 10.1177/0042098010377366
- Bura S., Guerin-Pace F., Mathian H., Pumain D., Sanders L., 1996, « Multiagent systems and the dynamics of a settlement system », *Geographical Analysis*, vol. 28, No.2, 161-178. DOI : 10.1111/j.1538-4632.1996.tb00927.x
- Crooks A., Castle C., Batty M., 2008, « Key challenges in agent-based modelling for geo-spatial simulation », *Computers, Environment and Urban Systems*, vol. 32, No.6, 417-430. DOI : 10.1016/j.compenvurbsys.2008.09.004

<https://lab.hypotheses.org/category/bilbo-bibliographical-robot>

Lier et citer les publications scientifiques.



# 2

## UNE INITIATIVE PUBLIQUE : ISTE<sup>X</sup>

Un moteur de recherche en texte intégral, une chaîne de traitements, des enrichissements, des APIs et des services



<https://www.istex.fr/>



23 millions de documents  
9 279 revues

autisme

Affiner votre recherche

Corpusname

- Edp-sciences 196
- Elsevier 129
- Wiley 109
- Springer-journals
- Cambridge 45 105
- Sage 23
- Lavoisier 16
- Bmj 8
- Springer-ebooks 7
- Brill-hacco 4

Categories.inist

- 1 - sciences humaines et so... 92
- 1 - sciences appliquées, te... 52
- 2 - sciences biologiques et... 52
- 3 - sciences médicales 52
- 2 - art et archéologie 5
- 2 - linguistique 5

Announcement

Pas de résumé disponible pour cet article

Journal of Autism and Developmental Disorders vol.23, page 427 - 427

Fulltext Metadata Enrichissements

**Harnessing Different Dimensions of Space: The Built Environment**

Abstract: An understanding of diversity is a key principle in the development of theories, tools and techniques. Inclusive design, we want to gain a more accurate insight into the diversity o...  
S. Baumers. A. Heylighen.

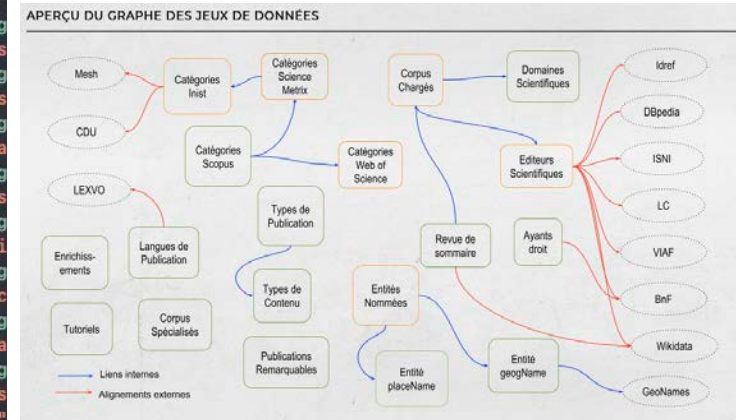
Designing Inclusive Interactions vol., page 13 - 23

Fulltext Metadata Enrichissements

**Sclérose tubéreuse de Bourneville et autisme**

Résumé: La sclérose tubéreuse de Bourneville comporte un grand polymorphisme dans sa symptomatologie et du comportement incluant des syndromes autistiques caractéristiques ou partiels. Les di...

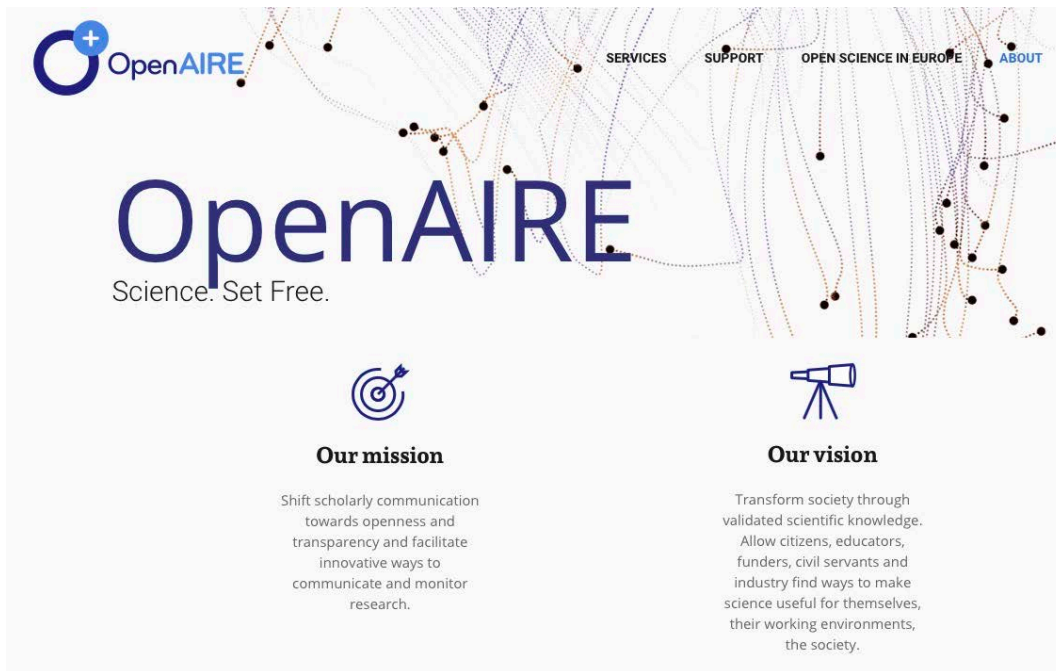
```
.0-alpha" resp="istex-rd"
r"><term>orient</term><fs type="statistics"><f name="
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>Paris</term><fs type="statis
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>Nancy</term><fs type="statis
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>Gillberg</term><fs type="statis
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>Lagos</term><fs type="statis
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>France</term><fs type="statis
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>YS</term><fs type="statistic
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>New-York</term><fs type="statis
lock><annotationBlock corresp="text"><placeName chang
ity.data.istex.fr"><term>Tours</term><fs type="statis
lock>/listAnnotation<listAnnotation type="persName"
0-alpha" resp="istex-rd" scheme="https://persname-ent
ency"><numeric value="1"/></f></fs></persName></annot
```



<https://data.istex.fr>

# 2

## DES INITIATIVES POUR UN COUPLE IST / TDM OUVERT



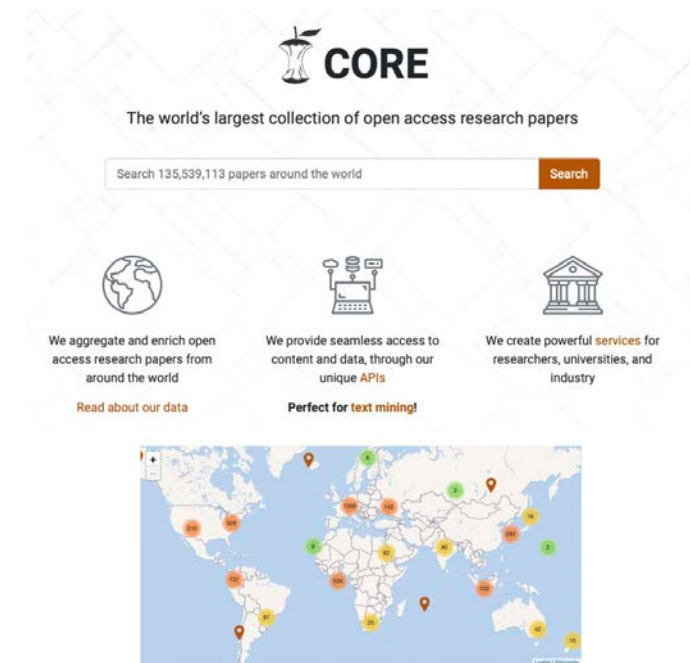
The image shows the OpenAIRE website header and two main sections: 'Our mission' and 'Our vision'. The header features the OpenAIRE logo and navigation links for SERVICES, SUPPORT, OPEN SCIENCE IN EUROPE, and ABOUT. The 'Our mission' section includes a target icon and text about shifting scholarly communication. The 'Our vision' section includes a telescope icon and text about transforming society through validated scientific knowledge.

**OpenAIRE**  
Science. Set Free.

**Our mission**  
Shift scholarly communication towards openness and transparency and facilitate innovative ways to communicate and monitor research.

**Our vision**  
Transform society through validated scientific knowledge. Allow citizens, educators, funders, civil servants and industry find ways to make science useful for themselves, their working environments, the society.

<https://www.openaire.eu>



The image shows the CORE website header and three main features. The header includes the CORE logo and the text 'The world's largest collection of open access research papers'. Below the header is a search bar with the text 'Search 135,539,113 papers around the world' and a 'Search' button. The three features are: 1) 'We aggregate and enrich open access research papers from around the world' with a globe icon and a 'Read about our data' link. 2) 'We provide seamless access to content and data, through our unique APIs' with a laptop icon and the text 'Perfect for text mining!'. 3) 'We create powerful services for researchers, universities, and industry' with a building icon.

**CORE**  
The world's largest collection of open access research papers

Search 135,539,113 papers around the world **Search**

**We aggregate and enrich open access research papers from around the world**  
[Read about our data](#)

**We provide seamless access to content and data, through our unique APIs**  
Perfect for text mining!

**We create powerful services for researchers, universities, and industry**





## Project mining details

Provide your **UTF-8** encoded text, on the current URL using the HTTP POST method.

You may also choose among the available mining processes.

HTTP POST parameters:

- **document:** UTF-8 encoded text
- **projects:** Project processing (on/off)
- **data citations:** Data citation processing (on/off)
- **classification:** Classification processing (on/off)

The service will return a **JSON** encoded result containing the following fields:

- **funding\_info:** Result category
- **fund:** Funder name (e.g., *FP7*, *Wellcome Trust*)
- **acronym:** The project acronym (only for FP7 projects)
- **grantid:** The project grant identifier
- **confidence:** Confidence weight

Result example:

```
{"funding_info": [{"fund": "fp7", "acronym": "CORONET", "grantid": "269459", "confidence": 0.96}]}
```

Lorem ipsum dolor sit amet, consectetur adipiscing elit, sed do eiusmod tempor incididunt ut labore et dolore magna aliqua. Ut enim ad minim veniam, quis nostrud exercitation ullamco laboris nisi ut aliquip ex ea commodo consequat. Duis aute irure dolor in reprehenderit in voluptate velit esse cillum dolore eu fugiat nulla pariatur. Excepteur sint funded by fp7 project OpenAIREplus occaecat cupidatat non proident,fp7 project with grant agreement number 318338 sunt in culpa qui officia deserunt mollit anim id est laborum.

Pellentesque habitant morbi tristique senectus et netus et malesuada fames ac turpis egestas. In posuere felis nec tortor. Pellentesque faucibus. Ut accumsan ultricies elit. Maecenas at justo id velit placerat molestie. Donec dictum lectus non odio. Cras a ante vitae enim iaculis aliquam. Mauris nunc quam, venenatis nec, euismod sit amet, egestas placerat, est. Pellentesque habitant morbi tristique senectus et netus et malesuada fames ac turpis egestas. Cras id elit. Integer quis urna. Ut ante enim, dapibus malesuada, fringilla eu, condimentum quis, tellus. Aenean porttitor eros vel dolor. Donec convallis pede venenatis nibh. Duis quam. Nam eget lacus. Aliquam erat volutpat. Quisque dignissim congue leo.

Mauris vel lacus vitae felis vestibulum volutpat. Etiam est nunc, venenatis in, tristique eu, imperdiet ac, nisl. Cum sociis natoque penatibus et magnis dis parturient montes, nascetur ridiculus mus. In iaculis facilisis massa. Etiam eu urna. Sed porta. Suspendisse quam leo, molestie sed, luctus quis, feugiat in, pede. Fusce tellus. Sed metus augue, convallis et, vehicula ut, pulvinar eu, ante. Integer orci tellus, tristique vitae, consequat nec, porta vel, lectus. Nulla sit amet diam. Duis non nunc. Nulla rhoncus dictum metus. Curabitur tristique mi condimentum orci. Phasellus pellentesque aliquam enim. Proin dui lectus, cursus eu, mattis laoreet, viverra sit amet, quam. Curabitur vel dolor ultrices ipsum dictum tristique. Praesent vitae lacus. Ut velit enim, vestibulum non, fermentum nec, hendrerit quis, leo. Pellentesque rutrum malesuada neque.

References:

Sieger, Rainer; (2012): PanGet - downloads multiple data sets from PANGAEA; PANGAEA - Data Publisher for Earth & Environmental Science.

Grobe, Hannes; (2005): Description and user manual of the information system PANGAEA; PANGAEA - Data Publisher for Earth & Environmental Science. <http://dx.doi.org/10.1594/PANGAEA.319947>

Appendix:

Pellentesque habitant morbi tristique senectus et netus et malesuada fames ac turpis egestas. In posuere felis nec tortor. Pellentesque faucibus. Ut accumsan ultricies elit. Maecenas at justo id velit placerat molestie. Donec dictum lectus non odio. Cras a ante vitae enim iaculis aliquam. Mauris nunc quam, venenatis nec, euismod sit amet, egestas placerat, est. Pellentesque habitant morbi tristique senectus et netus et malesuada fames ac turpis egestas. Cras id elit. Integer quis urna. Ut ante enim, dapibus malesuada, fringilla eu, condimentum quis, tellus. Aenean porttitor eros vel dolor. Donec convallis pede venenatis nibh. Duis quam. Nam eget lacus. Aliquam erat volutpat. Quisque dignissim congue leo.

Projects  Data citations  Classification

```
{"funding_info": [{"fund": "EC", "acronym": "OPTIQUE", "grantid": "318338", "confidence": 0.92}], "classification_info": [], "datacitation_info": [{"organization": "datacite", "related_doi": "10.1594/PANGAEA.319947", "confidence": 1, "resource_type": "Dataset"}, {"organization": "datacite", "related_doi": "10.1594/PANGAEA.804562", "confidence": 0.69, "resource_type": "Dataset"}]}
```

# 2

## DES INITIATIVES EUROPEENNES : L'ERIC CLARIN



Members	National Consortium (NC)	Leading NC partner
Austria	Digital Humanities Austria	ACDH-OEAW
Bulgaria	CLADA-BG	Bulgarian Academy of Sciences
Croatia	HR-CLARIN	University of Zagreb
Cyprus	CLARIN-CY	Digital Heritage Research Lab (Cyprus University of Technology)
Czech Republic	LINDAT/CLARIN	Charles University Prague
Denmark	CLARIN-DK	University of Copenhagen
Estonia	CLARIN Estonia	Center of Estonian Language Resources
Finland	FIN-CLARIN	University of Helsinki
Germany	CLARIN-D	University of Tuebingen
Greece	clarin-el	ILSP-ATHENA Research Center
Hungary	HunCLARIN	Research Institute for Linguistics, Hungarian Academy of Sciences
Italy	CLARIN-IT	Institute for Computational Linguistics A. Zampolli, Italian National Research Council
Latvia	CLARIN-LV	Institute of Mathematics and Computer Science, University of Latvia
Lithuania	CLARIN-LT	Vytautas Magnus University
The Netherlands	CLARIAH-NL	Utrecht University
Norway	CLARIN-O	University of Bergen
Poland	CLARIN-PL	Wroclaw University of Technology
Portugal	PORTUGAL CLARIN	University of Lisbon
Slovenia	CLARIN-SI	Jozef Stefan Institute
Sweden	SWE-CLARIN	Språkbanken
Observer	National Consortium (NC)	Leading partner NC
France	Huma-Num	the National Center for Scientific Research (CNRS)
Iceland	CLARIN Iceland	The Árni Magnússon Institute for Icelandic Studies
South Africa	SADiLaR	North-West University
United Kingdom	CLARIN-UK	Oxford University



<https://www.clarin.eu>



# 2

## DES INITIATIVES EUROPÉENNES : L'INFRASTRUCTURE *OPENMINTED* 2015-2018

openMINTeD  
Opening Infrastructure for Text & Data

SERVICES JOIN ABOUT NEWS CONTACT US

**OpenMinTeD**  
FOR RESEARCHERS  
[services.openminded.eu](http://services.openminded.eu)





## Resource Type

Applications (41) 

## Refine

### Licence

- Affero General Public License v1.0 (1)
- BSD-2-Clause (Simplified) License (1)
- Creative Commons Attribution Share Alike 3.0 Unported (1)
- GNU Lesser General Public License v3.0 (1)
- Non standard Licence or Terms of use (2)
- [View more...](#)

### Rights Statement

- Open Access (41)

### Language

- Bulgarian (1)
- Catalan; Valencian (1)
- Czech (1)
- Danish (1)
- German (1)
- Spanish; Castilian (1)
- Irish (1)
- Galician (1)
- Croatian (1)
- Latvian (1)
- [View more...](#)

### Function

- Extraction of funding information

Showing 1 - 10 of 41 results

< Previous

PAGE 1 OF 5



## GeoPolitical Extractor App

Extracts geopolitical terms.



## IXA pipes for Basque for PDF files

IXA pipes for Basque with PDF reader. eu-ixa-pipes-omtd prov tokenizer, POS tagger, lemmatizer, NER tagger, Chunking and C Classification. It reads from an input folder containing XML doc and outputs the added annotations in XML format to an output directory.



## Leica Model Annotation App

The application annotates a corpus with Leica Microsystems p



## MADIS FUNDING MINING

The Funding Mining application mines the fulltext of publicatic extracts links to projects. Currently, projects from EC (FP7/H2 (National Science Foundation, USA), NIH (National Institute of I USA), Wellcome Trust, FCT (Fundação para a Ciência e a Tecnc Portuga), ARC (Australian Research Council), NHMRC (National and Medical Research Council, Australia), CSF/HRZZ (Hrvatska Za Znanost, Croatia), MSES-MZOS (Ministarstvo Znanosti, Obr: športa, Croatia), SFI (Science foundation Ireland), NWO (Neder Organisatie voor Wetenschappelijk Onderzoek, Netherlands) ar supported, but new funders are added regularly.

### Function

- Analyzer (1)
- Annotator of semantic role labels (1)
- Chunker (1)
- Co-reference annotator (1)
- Constituency parser (1)
- Information extraction (1)
- Parser (1)
- Variables dectector (1)
- Document classifier (2)
- [View more...](#)

### Component Distribution

- Medium**
- Executable Code (28)
- Docker Image (35)

### Processing Resource Type

- Lexical Conceptual Resource (6)
- Document (28)
- Corpus (29)

### Data Format

- Binary CAS (1)
- Binary format (1)
- CoNLL-U (1)
- CSV (1)
- GATE format (1)
- TSV (1)
- UIMA CAS format (1)
- ALVIS Enriched Document format (3)
- XML (4)
- [View more...](#)

### Annotation Type

- Citation (1)
- Constituent (1)
- Coreference (1)
- Dependency tree (1)
- Discourse annotation type (1)
- Event (1)
- Funding (1)
- Grape variety (1)

Recognizes phenotypes, genes, markers, and wheat-related taxa. It categorizes the phenotypes with the Wheat Trait Ontology.



## Alvis Arabidopsis Gene Regulation Extractor

Recognizes Gene, Protein and RNA of Arabidopsis thaliana. It normalizes them with Gene Locus and identifies interacts\_with relationships between Gene and Protein.



## Lancaster Stemmer (DKPro Core)

This Paice/Husk Lancaster stemmer implementation only works with the English language so far.



## Variable Disambiguator

Assign variable IDs to sentences based on calculating the similarity between the sentence text and the description of the variable.



## ClearNLP Segmenter (DKPro Core)

Tokenizer using Clear NLP.



## de-ixa-pipes-omtd

IXA pipes for German. It provides tokenizer, POS tagger, lemmatizer and NER tagger. It reads from an input folder containing XML documents and outputs the added annotations in XML format to an output directory.

## CONCLUSION : LE TDM...

### Nécessite :

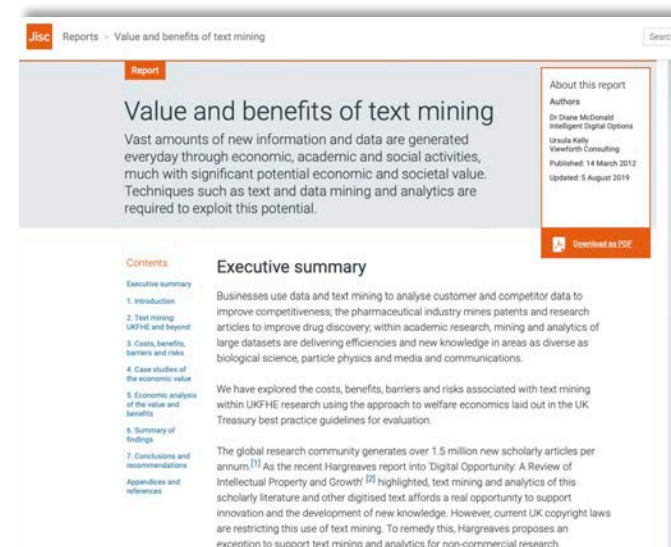
- un corpus cible, des ressources de spécialité
- d'intégrer différents composants logiciels
- un scénario et une référence pour évaluer la chaîne de traitements

### Faisable si :

- les composants sont interopérables, les métadonnées compatibles
- une infrastructure ouverte de services de fouille de textes est disponible...
- l'exception TDM sur la directive du droit d'auteur / copyright est soutenue

### Concerne et impacte :

- La recherche scientifique dans son ensemble
- La société au travers d'applications du quotidien



<https://www.jisc.ac.uk/reports/value-and-benefits-of-text-mining>



Depuis 80 ans, nos connaissances  
bâtissent de nouveaux mondes

## MERCI DE VOTRE ATTENTION

# Visa TM Day le 15 novembre : vers une infrastructure de services avancés en text-mining

Dans le cadre du projet Visa TM du Comité pour la Science Ouverte, un « **Visa TM Day** » sera organisé **vendredi 15 novembre 2019** au ministère de l'Enseignement supérieur, de la Recherche et de l'Innovation à **Paris**.

Le projet Visa TM a pour objectif l'étude d'une e-infrastructure de recherche pour la création d'une offre de service en fouille de textes pour la recherche, basée sur l'analyse sémantique et s'appuyant sur le potentiel de combinaison et d'adaptation offert par la plateforme européenne OpenMinTeD.

Autour de conférences et d'ateliers prospectifs, cette journée est destinée à dresser un état des lieux et discuter des perspectives concrètes ouvertes par les résultats du projet.

**Les inscriptions sont ouvertes jusqu'au 15 octobre.**

Programme et inscriptions sur <https://journées.inra.fr/visa-tm-day/>