

GREYC@TEXTMINE2023 : RECONNAISSANCE D'ENTITÉS NOMMÉES DANS LES SIGNATURES D'E-MAILS

Tanguy Gernot et Emmanuel Giguet¹

¹Normandie Univ, UNICAEN, ENSICAEN, CNRS, GREYC, 14000 Caen, FRANCE

emmanuel.giguet@unicaen.fr, tanguy.gernot@unicaen.fr



Objectif du défi TextMine'2023 :

- ▶ Reconnaître 13 types d'entité dans des signatures d'e-mails :
personne, organisation, fonction, projet, lieu, CEDEX, CS, code postal, numéro de téléphone, e-mail
- ▶ Structurer l'information ; La stocker en base de données

3 jeux de données :

- ▶ 2 jeux d'entraînement : Réaliste (JDR) et Factice (JDF)
- ▶ 1 jeu de validation : Authentique (JDA)
- ▶ Plusieurs langues, français majoritaire ; format texte brut

La mission :

- ▶ Analyser chaque signature du jeu de données
- ▶ Associer un type d'entité à une liste de tokens attendus

Table: Évaluation sur le jeu d'entraînement JDR

	precision	recall	f1-score	support
micro avg				
macro avg	0.98	0.98	0.98	6691
weighted avg	0.99	0.99	0.99	6691
F1	0.9912928493115661			

Table: Évaluation sur le jeu d'entraînement JDF

	precision	recall	f1-score	support
micro avg	1.00	1.00	1.00	5225
macro avg	0.46	0.46	0.46	5225
weighted avg	1.00	1.00	1.00	5225
F1	0.9997124612816258			

Table: Évaluation sur le jeu de validation JDA

	precision	recall	f1-score	support
micro avg	0.8243	0.8241	0.8242	8888
macro avg	0.7305	0.7249	0.7220	8888
weighted avg	0.8414	0.8241	0.8312	8888
F1	0.8311914814126119			

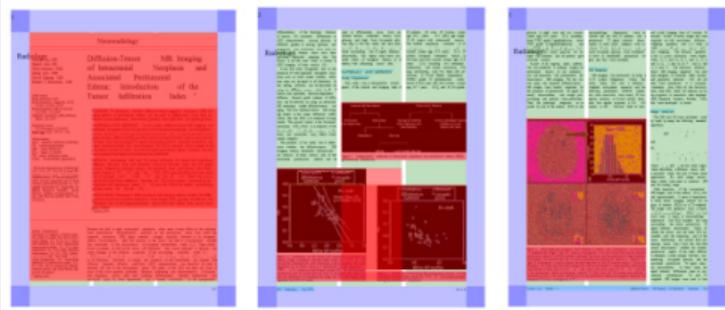
- ▶ Comment avons nous abordé le défi ?
- ▶ Pourquoi un écart de 17 points entre mise au point et validation ?
- ▶ Quelles pistes d'amélioration ?

D'où venons-nous ?

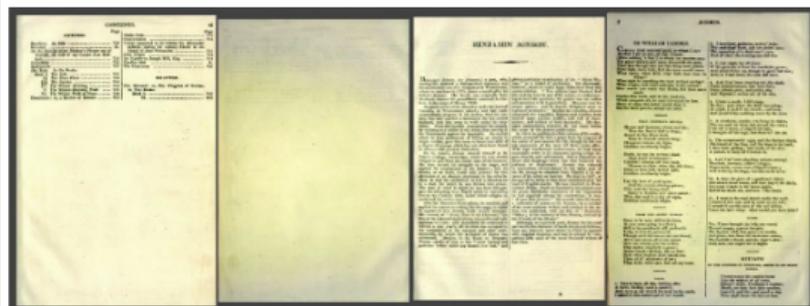


Équipe de recherche en cybersécurité, laboratoire GREYC UMR 6072, Caen, France

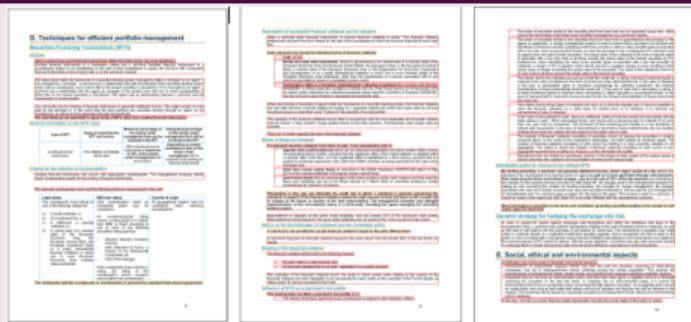
RÉSURGENCE: Analyse de la structure d'articles biomédicaux (2005)



Participations aux défis INEX/ICDAR "Book Structure Extraction" (2009-2011)



Challenge FinToc: Structure des documents financiers (2019-2022)



X-COTE – Extraction de Contenus Textuels du Web (TALN-RECITAL'2021)

- ▶ Identification du contenu principal des pages Web : "Web Scraping"
- ▶ Macro-segmentation du contenu des pages Web

GREYC Safe : Équipe de recherche en cybersécurité

- ▶ Axe de recherche en investigation numérique
 - ▶ Construction d'une plateforme logicielle pour l'investigation numérique
 - ▶ Évaluation de technologies existantes
 - ▶ Conception de composants à base de machine ou deep-learning
 - ▶ Analyse de vidéos, d'images, de textes
 - ▶ Projet interne de "Lutte contre le phishing et les courriers malveillants"
 - ▶ Montage en cours d'une thèse sur la détection des mails de phishing
 - ▶ Cohérence structurelle et textuelles
 - ▶ Macro-segmentation et extraction d'information
-
- ▶ Défi TextMine'2023 : une opportunité à saisir

Une démarche commune à toutes nos participations

- ▶ Concevoir notre propre chaîne d'analyse de bout en bout
 - ⇒ Maîtriser l'intégralité de la chaîne de traitement

La démarche pour le défi TextMine

- ▶ Traiter les énoncés textuels fournis au format brut
- ▶ Réaliser notre propre segmentation des signatures
- ▶ Procéder à l'identification des entités dans notre format
- ▶ Produire un produit dérivé : un format de sortie TextMine

Penser une segmentation en constituants logiques

- ▶ Viser une macro segmentation en constituants logiques :
 - ▶ personne, fonction, organisation, adresse, téléphone ...
- ▶ Utiliser la catégorie des constituants pour catégoriser les tokens internes
- ▶ Catégoriser les constituants par une analyse morpho-syntaxique
 - ▶ analyse morphologique
 - ▶ analyse contextuelle

Recourir à une segmentation en constituants physiques

- ▶ 2 types de constituant physique : phrastique et intra-phrastique
 - ▶ Délimiteurs dits "phrastiques" : saut de ligne
 - ▶ Délimiteurs intra-phrastiques : tiret long, barre oblique, ...
 - ▶ Présupposé : Segment intra-phrastique = unité minimale

Intérêt : Disposer d'une hiérarchie de constituants

- ▶ Se donner la possibilité de travailler à différents niveaux
- ▶ Faciliter les déductions contextuelles
- ▶ Réduire le nombre d'unités à considérer : "diviser pour régner"

Considérer 3 grands types de catégorie

1. Morphologiquement non ambigus : e-mail, numéro de téléphone, site internet
 - ▶ Identifiés à l'aide d'expressions régulières
2. Morphologiquement incertains (indices partiels) : fonction, adresse
 - ▶ Identifiés à l'aide d'expressions régulières partielles
 - + de lexiques spécialisés (liste de fonctions, types de voie)
 - + de liste de suffixes caractéristiques (-ogue, -iste)
3. Non catégorisables morphologiquement : personne, organisation, projet

Catégorisation contextuelle et positionnelle

- ▶ A base de règles contextuelles :
 - ▶ Nom du signataire : En début de signature = position 1 + présence obligatoire
 - ▶ Fonction : Position intermédiaire entre Nom et Organisation
 - ▶ Organisation : Obligatoire, à chercher dans les constituants non catégorisés

Calculer les chaînes de coréférence

- ▶ Idée : utiliser le fait qu'une signature a une cohérence textuelle
 - ▶ Mis en œuvre pour la détection du nom du signataire et du nom de l'organisation
- ▶ Calcul d'une distance (Jaccard) entre chaînes de caractères normalisées :
 - ▶ suppression des espaces, ponctuations, caractères spéciaux, accents, bascule en casse minuscule
- ▶ Coréférence sur nom de signataire :
 - ▶ Recherche des similarités graphiques entre le "local-name" d'une adresse mail (local-name@domain.tld) et un segment de l'adresse, idem pour les identifiants de réseaux sociaux
- ▶ Coréférence sur nom d'organisation :
 - ▶ Recherche des similarités graphiques entre le "domain-name" d'une adresse mail, d'un site internet et un segment de l'adresse

Alignement des segmentations

- ▶ Jointure entre notre segmentation en tokens et les tokens attendus

Contrôle qualité

- ▶ Vérification de la bonne formation et de la bonne indexation des tokens,
- ▶ Vérification et réétiquetage hors-contexte des catégories sûres : CEDEX, e-mail, téléphone, nom de domaine),
- ▶ Calcul des statistiques de bonne couverture,
- ▶ Calcul P/R/F1-score pour les jeux d'entraînement

Évaluation

- ▶ 99% à 100% de F1-score sur les données de mise au point
- ▶ 83% de F1-score sur les données de validation
- ▶ Toutes les catégories ne se valent pas :
 - ▶ certaines sont plus faciles que d'autres : URL, Téléphone, CEDEX
- ▶ La granularité de l'étiquetage sur-pénalise les erreurs :

Explication de la baisse de performance

- ▶ Le jeu de validation est très différent des jeux de mise au point
- ▶ La segmentation en macro-constituants n'est pas assez robuste sur le corpus de validation qui ne préserve pas la mise en forme originale
- ▶ La pseudonymisation affecte la cohérence textuelle et perturbe le calcul des chaînes de coréférence et les critères d'unicité

- ▶ Une participation très enrichissante,
- ▶ Des résultats très encourageants et améliorables significativement,
- ▶ Des résultats explicables et interprétables,
- ▶ Une gestion de plusieurs types d'unités pour raisonner à différents niveaux,
- ▶ Une utilisation originale du calcul des chaînes de coréférence,
- ▶ La mise en évidence des effets négatifs d'une pseudonymisation trop directe.

Nos sincères remerciements au comité d'organisation.

[thank you]

Any Questions ?

`emmanuel.giguet@unicaen.fr, tanguy.gernot@unicaen.fr`